

استفاده از شبکه‌ی UNet با نظارت عمیق برای تخمین فشار خون

پیوسته از سیگنال فوتوپلتیسموگرافی

معصومه خالقیان^۱، سیده سمانه شجاعی لنگری^{۲*}، مریم بیگ زاده^۲

۱- کارشناسی ارشد، گروه مهندسی برق و کامپیوتر، دانشکده هوش مصنوعی، دانشگاه خوارزمی، تهران، ایران

۲- استادیار، گروه مهندسی پزشکی، پژوهشکده برق و فناوری اطلاعات، سازمان پژوهش‌های علمی و صنعتی ایران، تهران،

ایران

* صندوق پستی ۳۳۵۳۵۱۱۱، تهران، ایران

s.shojaie@irost.ir

پذیرش: ۱۴۰۳/۰۷/۱۰

دریافت: ۱۴۰۲/۱۰/۳۰

چکیده

پایش فشار خون، یکی از مؤلفه‌های حیاتی برای حفظ سلامتی است. فشار خون بالا، به‌عنوان یک عامل خطر می‌تواند منجر به بروز حمله قلبی، سکته، نارسایی قلبی و کلیوی شود. همچنین، فشار خون پایین نیز می‌تواند خطرناک باشد و منجر به گیجی، ضعف، غش و اختلال در اکسیژن رسانی به اندام‌ها و آسیب به مغز و قلب شود. بنابراین، پایش مداوم میزان فشار خون در افراد با ریسک بالا بسیار حائز اهمیت است، به طوری که استفاده از دستگاه هولتر فشارخون به دلیل قابلیت ثبت بلند مدت و ارزشمند اطلاعات فشارخون برای بسیاری از بیماران تجویز می‌شود. تلاش برای دستیابی به تکنیک‌های نرم افزاری و توسعه دستگاه‌های اندازه‌گیری فشارخون بدون کاف، با حفظ آسایش و راحتی بیمار، از مهم‌ترین چالش‌های ذهنی پژوهشگران است. در این پژوهش یک چهارچوب یادگیری عمیق بر مبنای شبکه UNet یک‌بعدی با نظارت عمیق برای تخمین فشار خون پیوسته از روی سیگنال فوتوپلتیسموگرافی بدون استفاده از روش کالیبراسیون فردی ارائه شده است. مدل ارائه شده بر روی بانک داده UCI برای ۹۴۲ بیمار بستری در بخش مراقبت ویژه، به میانگین خطای مطلق ۸/۸۸، ۴/۴۳ و ۳/۳۲ و انحراف معیار ۱۱/۰۱، ۶/۱۸ و ۴/۱۵ میلی‌متر جیوه به ترتیب برای فشار خون سیستول، دیاستول و فشار خون میانگین دست یافت. طبق استاندارد بین‌المللی BHS، روش پیشنهادی، درجه‌ی A برای فشار خون دیاستول و میانگین و نیز درجه‌ی C برای فشار خون سیستول را برآورده می‌کند. نتایج حاصل از این پژوهش نشان می‌دهد که چهارچوب یادگیری عمیق پیشنهادی، پتانسیل لازم را برای تخمین کاربردی فشار خون بر پایه سیگنال PPG دارد.

کلید واژگان: سیگنال فوتوپلتیسموگرافی، تخمین فشار خون، روش غیرتهاجمی، هوش مصنوعی،

یادگیری عمیق، یادگیری ماشین

۱- مقدمه

فشارخون یکی از مهم‌ترین سیگنال‌های حیاتی بدن است. اندازه‌گیری آن با توجه به دربرگیری اطلاعات فیزیولوژیکی مربوط به عملکرد قلب دارای اهمیت بسیار در جامعه پزشکی است. با توجه به اینکه فشار خون غیرطبیعی عموماً عارضه یا علامت آنی ندارد، بسیاری از افراد از مشکل خود بی‌خبر هستند. به همین دلیل پایش مستمر فشارخون و ساخت هر چه دقیق‌تر و کاربردی‌تر دستگاه‌های هولتر برای اندازه‌گیری فشار خون در دنیای امروز از اهمیت بالایی برخوردار است. استفاده‌ی طولانی مدت از دستگاه هولتر فشار خون با کاف ممکن است با برخی مشکلات همچون ایجاد محدودیت در فعالیت‌های روزمره، آسیب به شریان، ایجاد ناراحتی و مزاحمت برای خواب بیماران و ... همراه باشد. با توجه به مشکلات مطرح شده، توسعه‌ی دستگاه‌های اندازه‌گیری فشار خون بدون استفاده از کاف و با حفظ آسایش بیمار یکی از چالش‌های مهم در حوزه پزشکی است. تاکنون تلاش‌های فراوانی در جهت ارائه روش‌های غیرتهاجمی برای اندازه‌گیری فشار خون انجام شده است [۱ و ۲].

روش‌های غیرتهاجمی برای اندازه‌گیری فشار خون معمولاً بر پایه‌ی اندازه‌گیری و تحلیل سیگنال‌های حیاتی مانند الکتروکاردیوگرافی (ECG)^۱ و فوتوپلتیسموگرافی (PPG)^۲ تمرکز دارند [۳]. فوتوپلتیسموگرافی یک روش نورسنجی است که برای اندازه‌گیری تغییرات حجم خون در عروق سطحی استفاده می‌شود. این روش بر اساس اصل تغییرات نوری بر اثر جذب و پراکندگی نور توسط بافت‌های بیولوژیکی کار می‌کند. هنگامی که نور از منبع نور به پوست می‌تابد، بخشی از این نور توسط بافت‌های پوستی جذب می‌شود و بخشی دیگر بازتاب می‌شود. این نور بازتاب شده توسط دیود نوری دریافت و به سیگنال الکتریکی تبدیل می‌شود. سیگنال ECG نیز بیان‌گر فعالیت

الکتریکی قلب است و به کمک الکترودهای فلزی از سطح پوست ثبت می‌شود [۴]. مطالعات نشان می‌دهد که این دو سیگنال می‌توانند به‌عنوان نماینده‌هایی از فعالیت قلبی و عروقی استفاده شوند و فشار خون را نیز تخمین بزنند. برخی از محققین برای تخمین دقیق‌تر فشار خون از این دو سیگنال به‌صورت هم‌زمان استفاده می‌کنند.

با توجه به اینکه تخمین فشار خون براساس به‌کارگیری دو سیگنال ECG و PPG نیازمند دستگاهی با قابلیت ثبت هم‌زمان دو سیگنال می‌باشد، ترجیح ما در این پژوهش، استفاده از تنها یک سیگنال برای ارتقای کارایی ابزارهای موجود بدون تحمیل هزینه‌ی اضافی برای حل معضل اندازه‌گیری فشار خون به‌صورت مداوم می‌باشد. دستگاه‌های PPG به‌دلیل مقرون به صرفه بودن و قابل حمل بودن، مدت‌ها است که برای اندازه‌گیری میزان ضربان قلب و میزان اشباع اکسیژن خون استفاده می‌شوند. با توجه به آنکه ثبت PPG به‌صورت غیرتهاجمی و با استفاده از یک سنسور ساده انجام می‌شود، استفاده از آن در ابزارهای سنجش سلامت (به‌ویژه تجهیزات پرتابل و گجت‌های پوشیدنی) بسیار متداول است. همچنین، در مقایسه با سیگنال ECG که ثبت آن نیاز به تجهیزات پیچیده و نصب الکتروود در شرایط آزمایشگاهی دارد، PPG به سادگی و در هر شرایطی قابل ثبت است.

در پژوهش‌های اخیر در حوزه‌های مرتبط، استفاده از الگوریتم‌های یادگیری ماشینی و شبکه‌های عصبی عمیق برای تحلیل سیگنال‌های زیستی بسیار مورد توجه قرار گرفته است. نتایج این تحقیقات به‌طور کلی نشان می‌دهد که با انتخاب و آموزش صحیح این الگوریتم‌ها و در اختیار داشتن داده‌ی کافی و مناسب، می‌توان به تخمین دقیق‌تری از فشار خون بیماران رسید. برای تخمین فشار خون از روی سیگنال PPG، روش‌های متنوعی وجود دارد که

² Photoplethysmography

¹ Electrocardiography

عمدتاً به دو دسته‌ی، روش‌های تحلیلی و روش‌های مبتنی بر داده تقسیم می‌شوند.

از مهم‌ترین روش‌های تحلیلی تخمین فشارخون، محاسبه شاخص‌هایی مانند زمان گذار پالس^۱ (PTT) و زمان رسیدن موج نبض^۲ (PAT) است. در عمل، برای تخمین پارامترهای PTT و PAT می‌توان از دو سیگنال PPG استفاده کرد [۵-۷]. همچنین، می‌توان از ترکیبی از سیگنال PPG با سیگنال ECG و یا سیگنال حاصل از حسگرهای مغناطیسی و حسگر امپدانس سنجی استفاده کرد [۸]. با این حال، استفاده از دو سیگنال ورودی و دو حسگر در دو نقطه مختلف بدن نیازمند محدودیت حرکت فرد است و این مسئله باعث محدودیت کاربردهای عملی این تکنیک می‌شود. از سویی، نتایج حاصل از این روش‌ها دقت لازم در تخمین فشارخون را ندارند و نمی‌توانند به خوبی پیچیدگی سیستم قلب و عروق، گردش خون و تولید فشارخون در بدن را مدل کنند. همچنین، تعداد ویژگی‌های به کار رفته به‌عنوان ورودی در این مدل‌ها بسیار محدود و ناکافی هستند.

روش‌های مبتنی بر داده معمولاً با به‌کارگیری الگوریتم‌های یادگیری ماشین و فنون تحلیل داده، اطلاعات موجود در سیگنال PPG را برای تخمین فشارخون بررسی و تحلیل می‌کنند [۹-۱۱]. روش‌های سنتی یادگیری ماشین شامل الگوریتم‌های استخراج ویژگی از سیگنال PPG و تخمین زنده‌های^۳ کلاسیک همچون ماشین‌های بردار پشتیبان، درخت تصمیم، جنگل تصادفی و ... می‌باشند [۱۲ و ۱۳]. اما از آنجا که سیگنال PPG بسیار آغشته به نویز بوده، استخراج ویژگی به‌صورت دستی از آن دشوار می‌باشد. از طرفی سیگنال PPG تحت تأثیر تغییرات فیزیولوژیکی مانند ضربان قلب، فشارخون و رفتار عروق قرار می‌گیرد که ممکن است باعث تغییر در الگوهای سیگنال و ایجاد

مشکل در استخراج ویژگی‌ها شوند. به همین دلیل، در مطالعات اخیر از روش‌های نوین هوش مصنوعی که مبتنی بر استخراج خودکار ویژگی‌ها است، برای استخراج ویژگی‌های مفید از سیگنال PPG برای تخمین فشارخون استفاده شده است [۱۴]. در روش‌های نوین هوش مصنوعی همچون یادگیری عمیق، الگوریتم‌های یادگیری بدون این که صراحتاً برنامه‌ریزی شوند، ارتباط بین متغیرها را آموخته و مدل را می‌سازند.

به‌طور خلاصه، می‌توان گفت استفاده از سیگنال‌های حیاتی مانند ECG و PPG برای تخمین فشارخون بدون استفاده از کاف امیدوارکننده است، اما برای دستیابی به روش‌های دقیق و قابل اعتمادتر برای اندازه‌گیری فشارخون بدون کاف، همچنان به پژوهش‌های بیشتری در این حوزه و توسعه‌ی فناوری‌های نوین نیاز است.

در این پژوهش یک مدل یادگیری ماشین با عنوان UNet یک‌بعدی با نظارت عمیق^۴ برای تخمین فشارخون پیوسته طراحی شده است. نظارت عمیق تکنیکی است که با هدایت فرایند یادگیری لایه‌های مخفی، خطاهای کلی را کاهش می‌دهد. اصل این روش بر این اساس استوار است که علاوه بر خروجی نهایی مدل، خروجی‌های میانی نیز برای محاسبه زیان^۵ شبکه استفاده می‌شوند و این زیان‌ها در محاسبه وزن‌های کاهش‌یافته‌ی شبکه در نظر گرفته می‌شوند. این خروجی‌های میانی ممکن است در لایه‌های مختلف مدل قرار گیرند و باعث شوند که فرایند یادگیری بهتر هدایت شود و خطاهای کلی در مدل کاهش یابد [۱۵]. روش نظارت عمیق قابل استفاده در انواع معماری‌ها و مدل‌های عمیق مانند شبکه‌های عصبی کانولوشنی (CNN)^۶، شبکه‌های بازگشتی (RNN)^۷ و شبکه‌های مولد متخاصم (GAN)^۸ است [۱۶].

^۵ Loss

^۶ Convolutional Neural Network

^۷ Recurrent Neural Network

^۸ Generative Adversarial Network

^۱ Pulse Transit Time (PTT)

^۲ Pulse Arrival Time (PAT)


^۳ Pulse Arrival Time (PAT)

^۴ Deep supervision-based 1D-UNet

در ادامه، در بخش ۲، روش تحقیق شامل پیش پردازش داده و روش رگرسیون اعمال شده برای تخمین فشار خون به تفصیل شرح داده خواهد شد. در بخش ۳ نتایج این پژوهش را با معیارهای ارزیابی مختلف مورد بررسی قرار داده و در نهایت در بخش ۴ به بحث و نتیجه‌گیری و مقایسه با دیگر پژوهش‌های این حوزه می‌پردازیم.

۲- روش‌ها

چهارچوب کلی روش پیشنهادی برای تخمین فشارخون در شکل ۱ نمایش داده شده است. در این بخش ابتدا به معرفی مجموعه داده‌ی به کار رفته برای آموزش مدل پرداخته می‌شود و سپس روش به کار برده شده برای پیش‌پردازش داده‌ها و حذف نویز از داده‌ها را شرح می‌دهیم. در پایان نیز به توضیح مدل به کار برده شده برای پیش‌بینی فشارخون می‌پردازیم.



شکل ۱ چهارچوب کلی روش پیشنهادی برای تخمین فشار خون پیوسته و پارامترهای آن. * ABP: سیگنال فشار خون شریانی.

۲-۱ مجموعه داده‌ها

در این مطالعه، از مجموعه داده‌ی UCI که به نام Cuff-Less Blood Pressure Estimation نیز شناخته می‌شود و در پایگاه داده‌ی فیزیونت قابل دسترسی است، استفاده کردیم [۱۷]. این مجموعه داده در حقیقت نسخه‌ی فیلتر شده‌ی داده‌های MIMIC-III است که شامل ۱۲۰,۰۰۰ نمونه از اطلاعات همزمان PPG، ECG و فشار خون شریانی (ABP) می‌باشد و از ۹۴۲ بیمار بستری در بخش مراقبت‌های ویژه با نرخ نمونه‌برداری ۱۲۵ هرتز گردآوری شده است. خلاصه‌ای از اطلاعات آماری مربوط به فشار خون این بانک داده در جدول ۱ آمده است. قابل ذکر است که فشار خون سیستول (SBP)^۱، حداکثر فشار درون سرخرگ در زمان انقباض قلب و فشارخون دیاستول (DBP)^۲ حداقل فشار درون عروق بدن در زمان استراحت

قلب است. فشار خون میانگین (MAP)^۳ طبق رابطه‌ی ۱ بر حسب فشار خون سیستول و دیاستول محاسبه می‌شود.

$$MAP = \frac{(SBP + 2DBP)}{3} \quad (1)$$

۲-۲ پیش پردازش داده‌ها

لازم به ذکر است که داده مورد استفاده در این پژوهش پیشتر توسط آقای کاجویی و همکاران [۱۸] مورد پیش پردازش اولیه قرار گرفته است و ما تنها از چند مرحله‌ی تکمیلی برای آماده‌سازی داده‌ها برای پردازش‌های بعدی استفاده کرده‌ایم که این مراحل شامل قطعه‌بندی سیگنال، حذف نویز و نرمال‌سازی داده‌ها می‌باشد. مراحل کار به صورت خلاصه در شکل ۲ نمایش داده شده است که در ادامه به توضیح مختصری از آن می‌پردازیم.


³ Mean Atrial Pressure

¹ Systolic Blood Pressure

² Diastolic Blood Pressure

جدول ۱ اطلاعات آماری از بانک داده UCI شامل مقادیر میانگین و انحراف معیار کمیت‌های SBP، DBP و MAP.

	Min (mmHg)	Max (mmHg)	Mean (mmHg)	Std (mmHg)
SBP	71.81	199.98	141.03	25.64
DBP	50	148.24	57.80	9.31
MAP	57.37	160.56	85.54	11.95



شکل ۲ مراحل پیش پردازش

فشار خون انجام شد تا مقایسه در حالت واقعی انجام شود.

پس از پایان مراحل پیش پردازش، برای هر پنجره‌ی زمانی (هر قطعه از سیگنال) یک تخمین از فشارخون سیستولیک و یک تخمین از فشارخون دیاستولیک بر اساس سیگنال ABP (خروجی) استخراج می‌شود. این اعداد در نهایت در ارزیابی و گزارش نتایج تخمین در بخش نتایج استفاده می‌شوند. لازم به یادآوری است که در سیگنال ABP، قله‌ها فشارخون سیستولیک و دره‌ها فشارخون دیاستولیک را نشان می‌دهند.

۲-۳ مدل رگرسیون

در این پژوهش از مدل رگرسیون تخمین‌گر سیگنال به سیگنال^۱ استفاده شده است. لازم به ذکر است که مدل سیگنال به سیگنال شامل مدل‌هایی است که از سیگنال PPG، سیگنال ABP را تخمین می‌زنند. شبکه‌ی UNet یک مدل رگرسیون سیگنال به سیگنال می‌باشد که برای تخمین سیگنال فشار خون از روی سیگنال PPG، استفاده

در ابتدای مرحله‌ی پیش پردازش، سیگنال‌های PPG و ABP به صورت مستقل به بخش‌های ۱۰۲۴ نمونه‌ای (با توجه به نرخ نمونه‌برداری ۱۲۵ هرتز، معادل ۸/۱۹۲ ثانیه)، تقسیم‌بندی می‌شوند. سپس، برای حذف نویز از سیگنال، از یک فیلتر باتروث با فرکانس قطع ۰/۱ و ۳۰ هرتز استفاده می‌شود [۱۳].


در ادامه‌ی فرایند پیش‌پردازش، نرمال‌سازی داده‌ها انجام می‌شود. نرمال‌سازی داده‌ی ورودی و خروجی در شبکه‌های عمیق یکی از مراحل مهم پیش‌پردازش داده است. این فرایند شامل تبدیل داده‌های ورودی و خروجی به یک مقیاس مشخص است که بهینه‌سازی عملکرد شبکه را تسهیل می‌کند. برای بهبود و تسریع روند آموزش و جلوگیری از مشکل "غرق شدن در وزن‌های بزرگ" نرمال‌سازی داده‌ها در بازه‌ی [۰، ۱] برای هر دو سیگنال ABP و PPG انجام شد. البته لازم ذکر است که در ارزیابی نتایج، عمل عکس نرمال‌سازی بر روی مقادیر تخمینی

^۱ Signal to Signal

نمونه برداری در دیکودر، یک خروجی میانی محاسبه می کنیم که نسخه‌ی زیرنمونه برداری^۳ شده‌ای از سیگنال خروجی واقعی است. زیان‌ها^۴ با وزن‌های کاهش‌ی تدریجی محاسبه می شوند. این زیان‌های کمکی، یادگیری لایه‌های مخفی را راهبری می کنند و خروجی نهایی بهتری را تولید می کنند.

در طراحی مدل UNet، تعداد فیلترها به صورت ضرب‌های ۶۴ انتخاب شدند، به این معنا که از مقادیر (۶۴، ۱۲۸، ۲۵۶، ۵۱۲) بهره برده ایم. برای طراحی شبکه از پیکربندی‌های استاندارد لایه‌های کانولوشن و ادغام استفاده کرده ایم. در لایه‌های کانولوشن، اندازه‌ی فیلتر برابر با ۳ انتخاب شده است، در حالی که طول گام برابر با ۱ تنظیم شده است. پس از هر لایه‌ی کانولوشن، از تابع فعال ساز غیرخطی ReLU استفاده شده است. لایه‌ی ادغام حداکثری^۵ در این معماری دارای اندازه فیلتر ۲×۱ با اندازه گام ۲ است.

می شود. معماری UNet از مجموعه‌ای از شبکه‌های عصبی کانولوشنال تشکیل شده است که شامل یک انکدر (برای کاهش نمونه برداری) و یک دیکودر (برای افزایش نمونه برداری) با اتصالات پرش می باشد. اگرچه معماری UNet در اصل برای تقسیم بندی معنایی تصاویر طراحی شده است، اما در هدف ما، از آن برای بازسازی سیگنال‌های یک بعدی استفاده می کنیم که در اصل یک وظیفه‌ی رگرسیون یک به یک است. بنابراین، در اینجا تمام عملیات کانولوشن دو بعدی، ادغام^۱ و افزایش نمونه برداری^۲ با نسخه‌ی یک بعدی خود جایگزین می شوند. برای تولید خروجی رگرسیونی، لایه‌ی کانولوشن نهایی از تابع فعال سازی خطی استفاده می کند. علاوه بر این، ما در شبکه‌ی UNet خود همان طور که در شکل ۳ مشاهده می شود، نظارت عمیق را اعمال می کنیم. نظارت عمیق تکنیکی است که با هدایت فرایند یادگیری لایه‌های مخفی، خطاهای کلی شبکه را کاهش می دهد. در UNet یک بعدی طراحی شده با نظارت عمیق، قبل از هر عملیات افزایش



شکل ۳ معماری شبکه‌ی UNet پیشنهادی

^۴ Losses

^۵ Max Pooling

^۱ Pooling

^۲ Upsampling

^۳ Sub-sampled

$$L = L_0 + \alpha \sum_{i=1}^3 L_i \quad (2)$$

یافته‌های تحقیق ۳- نتایج

در این پژوهش از نرم‌افزارهای Matlab2021a برای پیش پردازش داده و python 3.11 برای آموزش و تست مدل استفاده شد. پیاده‌سازی پروژه بر روی یک سیستم مجهز به کارت گرافیک RTX3090 انجام شد.

شایان ذکر است طریقه‌ی تقسیم‌بندی مجموعه داده به صورت ۷۰ درصد متعلق به مجموعه داده‌ی آموزش شی، ۱۵ درصد متعلق به مجموعه داده‌ی اعتبارسنجی و ۱۵ درصد متعلق به مجموعه داده‌ی تست انجام شده است. در این روش تقسیم‌بندی، هیچگونه نشر اطلاعاتی بین داده‌های آموزش و آزمون وجود ندارد تا مطمئن شویم که روش بدون کالیبراسیون فردی اجرا شده است.

۲-۱ معیارهای ارزیابی

در رگرسیون، معیارهای ارزیابی مختلفی استفاده می‌شوند تا کیفیت مدل رگرسیونی را ارزیابی کنند. در این مقاله از معیارهای ارزیابی میانگین مربعات خطا (MSE)^۶، میانگین خطای مطلق (MAE)^۵، انحراف معیار خطای مطلق (SD)^۶، ضریب تعیین R^2 ^۷، نمودار رگرسیون، نمودار Bland-Altman، معیار استاندارد BHS^۸، معیار AAMI^۹ برای مقایسه‌ی روش اعمال شده با دیگر پژوهش‌های این حوزه و ارائه‌ی نتایج گرفته شده از مدل، بهره گرفته شده است.

نتایج تخمین فشار خون پیوسته

از آنجا که هدف اولیه‌ی این پژوهش، ارائه‌ی تخمین فشار خون پیوسته از سیگنال ورودی PPG است، در اولین گام از آزمایش‌های انجام شده، دقت تخمین سیگنال ABP را

به طور مشابه، در لایه‌های افزایش نمونه‌برداری، اندازه‌ی پنجره برابر با ۲ انتخاب شد. در تعلیم مدل مورد نظر از میانگین خطای مطلق (MAE)^۱ به عنوان تابع هزینه استفاده شده است. برای کاهش هزینه از بهینه‌ساز ADAM با پارامترهای پیش فرض در مقاله‌ی اصلی استفاده کردیم [۱۹].

در روش ADAM، نرخ یادگیری به صورت تطبیقی تنظیم می‌شود، به این معنی که این الگوریتم در طول فرایند آموزش نرخ یادگیری را برای هر کدام از پارامترها به طور مستقل و بر اساس تخمین‌های گرادین‌ها تنظیم می‌کند. مدل با ۱۰۰ دوره‌ی آموزشی^۲ و برای اندازه‌ی دسته^۳ ۲۵۶ و با توقف زود هنگام برای هر ۱۰ دوره آموزش دیده است. همان‌طور که اشاره شد، در تعلیم مدل، از مکانیزم نظارت عمیق استفاده شد. به این معنا که ضرر لایه‌های میانی و نهایی به منظور بازگشت گرادین ترکیب شده و به طرز موثری تأثیر محو گرادین را کاهش داده و کارایی یادگیری را بهبود می‌بخشد و بهینه‌سازی را تسریع می‌کند.

معادله‌ی ۲ تابع زیان هر تکرار از نظارت عمیق را به شرح زیر ارائه می‌دهد که در آن L_0 تابع زیان اصلی است و نمایانگر مقدار زیانی است که توسط دیکودر نهایی خروجی می‌شود. L_1 ، L_2 و L_3 به عنوان تابع‌های زیان کمکی تعریف شده‌اند، به معنای مقدار زیانی که توسط دیکودرهای میانی خروجی می‌شود. پارامتر α ضریب نظارت عمیق است. از آنجا که لایه‌های عمیق معمولاً ویژگی‌های پیچیده‌تری نسبت به لایه‌های کم عمق دارند، ما می‌توانیم با تخصیص وزن بالاتر به زیان خروجی شبکه عمیق، دقت تخمین خروجی را بهبود بخشیم. در این مقاله، پارامتر α هر ۱۰ دوره بر اساس فرمول $\alpha = 0.8 \times \alpha$ به روز رسانی می‌شود [۲۰].

^۶ Standard Deviation

^۷ Coefficient of Determination - R-squared

^۸ British Hypertension Society

^۹ Association for the Advancement of Medical Instrumentation

^۱ Mean Absolute Error

^۲ Epoch

^۳ Minibatch Size

^۴ Mean Squared Error


^۵ Mean Absolute Error

۲-۳ نتایج تخمین فشار خون سیستول و دیاستول

با توجه به اینکه خروجی شبکه‌ی طراحی شده، سیگنال ABP است، برای ارزیابی مدل می‌بایست مقادیر سیستول و دیاستول برای هر بخش از سیگنال ABP حاصل، محاسبه می‌شد. برای این منظور، مقادیر بیشینه و کمینه سیگنال ABP به ترتیب به عنوان مقادیر سیستول و دیاستول محاسبه شدند.

همان‌طور که در جدول ۲ گزارش شده است، مقدار خطا بر حسب شاخص‌های مختلف در تخمین فشار سیستول بیشتر از خطای تخمین فشار دیاستول و میانگین می‌باشد.

به صورت کیفی و کمی در این بخش ارائه می‌کنیم. شکل موج PPG و ABP یکی از نمونه‌های ورودی و سیگنال خروجی تولید شده از شبکه‌ی UNet در شکل ۴ نمایش داده شده است. همان‌طور که این شکل نشان می‌دهد، سیگنال فشار خون تخمینی از شبکه‌ی UNet، توانسته تقریب خوبی از سیگنال ABP مبنا را به عنوان خروجی نهایی تولید کند. البته در تخمین فشار خون ماکزیمم یعنی فشار سیستول دقت کمتری مشاهده می‌شود. از لحاظ کمی، میانگین خطای مطلق سیگنال فشار خون ۶/۳۳ با انحراف میانگین ۱۲/۴۵ میلی‌متر جیوه است که بیان‌گر موفقیت نسبی روش به کار برده شده در این پژوهش می‌باشد.




شکل ۴ نمایش خروجی شبکه در هر مرحله در معماری UNet پیشنهادی. نمودارها از بالا به پایین به ترتیب نمایش دهنده سیگنال PPG ورودی، خروجی شبکه در تخمین ABP، سیگنال ABP مرجع و مقایسه خروجی شبکه و سیگنال مرجع می‌باشد.

جدول ۲ نتایج تخمین فشار سیستول و دیاستول در معماری UNet پیشنهادی.


	MAE	SD	MSE	R2-score
SBP	8.88	11.01	112.62	0.44
DBP	4.43	6.18	32.51	0.94
MAP	3.32	4.15	15.93	0.91

در ادامه به نمایش خطای مطلق هریک از مقادیر سیستول و دیاستول و فشار خون میانگین برای نمونه‌های تست در شکل ۵ پرداختیم تا درک بهتری از نحوه‌ی توزیع خطای مطلق حاصل شود. همچنین، تعداد نمونه‌های دارای خطای کمتر از ۵، ۱۰، و ۱۵ میلی‌متر جیوه برای محاسبه استاندارد BHS در این نمودارها مشخص شده است. همان‌طور که مشاهده می‌شود، برای فشار خون میانگین و دیاستول، تعداد بسیار محدودی از نمونه‌ها دارای خطای بالاتر از ۱۵ میلی‌متر جیوه هستند.

در شکل ۶ به بررسی یکی دیگر از معیارهای آماری برای ارزیابی مدل پیشنهادی به نام معیار Bland-Altman خواهیم پرداخت تا بهتر بتوانیم پراکندگی و اختلاف بین مقادیر تخمینی فشار خون از نمونه‌های مختلف را بررسی کنیم. همان‌طور که در شکل ۶ ملاحظه می‌شود، خطای تخمین فشار دیاستول، میانگین و سیستول برای ۹۵ درصد نمونه‌ها به ترتیب در بازه $[-10; 15]$ ، $[-8; 8]$ و $[-29; 13]$ میلی‌متر جیوه قرار دارد. این مقادیر حاکی از آن است که پراکندگی بین مقادیر تخمینی در فشار خون سیستول بیش از دیاستول و میانگین می‌باشد.



شکل ۵ هیستوگرام خطای مطلق نمونه‌های تست در معماری UNet پیشنهادی. نمودارها به ترتیب از چپ به راست خطای مطلق در تخمین فشار خون سیستول، دیاستول و میانگین را نشان می‌دهد. فراوانی نمونه‌های دارای خطای کمتر از ۵، ۱۰، و ۱۵ میلی‌متر جیوه در این نمودارها با خط چین مشخص شده است.



شکل ۶ نمودار بلند-آلتمن برای تخمین پارامترهای فشار خون در معماری UNet. شکل‌ها به ترتیب از چپ به راست نمودار بلند-آلتمن در تخمین فشار خون دیاستول، میانگین و سیستول را نشان می‌دهند.


طبق استاندارد BHS، فشار خون دیاستول و میانگین به درجه‌ی A و فشارخون سیستول به درجه‌ی C دست پیدا کرده است. این بدان معناست که مدل پیشنهادی دارای دقت خوبی برای تخمین فشار خون دیاستول و میانگین بوده و می‌تواند برای کاربرد بالینی استفاده شود، اما در مورد تخمین فشار خون سیستول برای استفاده در بالین نیاز به بهبود دارد.

در خصوص استاندارد AAMI شرط لازم برای کسب این استاندارد، داشتن داده از حداقل ۸۵ نفر و حداکثر سه بار از یک فرد است. به عبارت دیگر حداقل به ۲۵۵ نمونه داده نیاز است. بر مبنای این استاندارد، دستگاه‌های اندازه‌گیری فشار خون می‌بایست نتایجی را ارائه کنند که در آنها میانگین خطا و انحراف معیار به ترتیب کمتر از ۵ و ۸ میلیمتر جیوه باشد. مطابق جدول ۴، مدل پیشنهادی ما برای فشارخون دیاستول و میانگین الزامات استاندارد AAMI را برآورده می‌کند. برای درک بهتر توزیع خطا در تخمین فشار خون سیستول و دیاستول، هیستوگرام خطای نمونه‌های تست در شکل ۸ نمایش داده شده است. مطابق با این شکل، میانگین خطا در هر سه شاخص تقریباً صفر بوده مقدار واریانس خطا در فشار خون سیستول اندکی بالاتر از فشار دیاستول و میانگین است.

شکل ۷ نمودار رگرسیون در تحلیل داده‌های تخمینی فشار دیاستول، میانگین و سیستول را نشان می‌دهد که بیان‌گر وجود همبستگی بین مقادیر واقعی و مقادیر تخمینی است. در حقیقت شیب خط رگرسیون نشان می‌دهد که چقدر تغییرات در متغیر وابسته را می‌توان به تغییرات متغیر مستقل نسبت داد. در این نمودار، شیب خط رگرسیون برای تخمین فشار خون دیاستول، میانگین و سیستول به ترتیب برابر ۰,۵۳، ۰,۸۳ و ۰,۸۴ می‌باشد. خطای استاندارد از دیگر مولفه‌های تحلیل نمودار رگرسیون می‌باشد که نشان می‌دهد چقدر داده‌ها از خط رگرسیون پراکنده هستند. اگر خطای استاندارد کم باشد، نمودار به خوبی با خط رگرسیون هماهنگ است و داده‌ها نزدیک به خط قرار دارند. همان‌طور که از شکل ۷ پیداست، خطای تخمین فشار میانگین کمتر از فشار سیستول و دیاستول است.

ارزیابی نتایج با استانداردهای بین‌المللی

استاندارد BHS عملکرد مدل را برحسب درصد تجمعی خطا درجه بندی می‌کند. این معیار که برای ارزیابی دقت دستگاه‌های اندازه‌گیری فشار خون استفاده می‌شود، برای روش پیشنهادی این مقاله در جدول ۳ نشان داده شده است. همان‌طور که در این جدول گزارش شده است، مقدار خطای سیستول بیشتر از خطای دیاستول بوده و




شکل ۷ نمودار رگرسیون برای پیش‌بینی پارامترهای فشارخون در معماری UNet. شکل‌ها به ترتیب از چپ به راست نمودار رگرسیون فشار خون دیاستول، میانگین و سیستول را نشان می‌دهند.

جدول ۳ گزارش نتایج عددی در قالب استاندارد BHS در معماری UNet پیشنهادی.

Cumulative Error Percentage		<=5 mmHg	<=10mmHg	<=15mmHg
Our Results	SBP	58.8%	80.2 %	88.7%
	DBP	83.9%	95.0%	97.7%
	MAP	88.2%	97.0%	98.9%
BHS Metric	Grade A	60%	85%	95%
	Grade B	50%	75%	90%
	Grade C	40%	65%	85%

جدول ۴ گزارش نتایج عددی در قالب استاندارد AAMI در معماری UNet پیشنهادی.

		ME	STD
Our Results	SBP	6.66	8.26
	DBP	3.32	4.63
	MAP	2.49	3.11
AAMI Metric		<=5	<=8



شکل ۸ هیستوگرام خطای نمونه‌های تست در معماری UNet پیشنهادی برای تخمین فشار خون دیاستول (سمت چپ)، فشار خون میانگین (وسط) و فشار خون سیستول (سمت راست).

در پایان این بخش، برای بررسی بیشتر نتایج به‌دست آمده از مدل UNet، به طبقه‌بندی فشار خون سیستول و دیاستول به سه گروه فشار خون طبیعی^۱، فشار بالا مستعد

۳-۳ بررسی عملکرد مدل بر اساس گروه‌های مختلف فشارخون


^۱ Normotension

بیماری^۱، و فشار خیلی بالا^۲ تقسیم‌بندی کردیم که در جدول ۵ به محدوده‌ی فشار خون مورد نظر اشاره شده است. نتایج این ارزیابی در شکل ۹ به نمایش درآمده است. در تخمین فشار خون دیاستول، مدل با دقت خوبی (۹۸ درصد) قادر به تفکیک طبقه‌ی نرمال شده است، درحالی‌که دقت طبقه‌بندی فشار خون در افراد مستعد

بیماری و افراد دارای فشار خون بالا تقریباً در یک محدوده قرار دارد (۴۳ درصد در مقابل ۵۰ درصد). از سوی دیگر، در تخمین فشار خون سیستول، بهترین دقت طبقه‌بندی مربوط به افراد با فشار خون بالا (۹۹ درصد) بوده، و دقت طبقه‌بندی در افراد مستعد بیماری و افراد نرمال به ترتیب در جایگاه‌های بعدی قرار دارند (۴۳ و ۵۶ درصد).

جدول ۵ محدوده فشار خون سیستول و دیاستول در سه طبقه

وضعیت فشار خون	دیاستول (میلی‌متر جیوه)	سیستول (میلی‌متر جیوه)
نرمال	بین ۶۰ تا ۸۰	بین ۸۰ تا ۱۲۰
مستعد فشار خون بالا	بین ۸۰ تا ۹۰	بین ۱۲۰ تا ۱۴۰
فشار خون بالا	بالاتر از ۹۰	بالاتر از ۱۴۰



شکل ۸ طبقه‌بندی فشار خون دیاستول و سیستول به سه طبقه نرمال، فشار خون مستعد بیماری، فشار خون بالا در معماری UNet پیشنهادی.

۴- بحث

فشار خون یکی از شاخص‌های مهم سلامتی است که اندازه‌گیری و نظارت مداوم بر آن برای تشخیص و کنترل بیماری‌های قلبی و عروقی ضروری است. روش‌های سنتی اندازه‌گیری فشار خون از طریق فشارسنج‌ها، نیازمند تجهیزات پیچیده و مزاحم هستند. به همین دلیل، استفاده از روش‌های غیرتهاجمی و غیرمستقیم برای تخمین فشار

خون مورد توجه قرار گرفته است. سیگنال PPG یکی از روش‌های غیرتهاجمی است که با استفاده از نورسنجی، به اندازه‌گیری تغییرات حجم خون در عروق پیرامونی به صورت غیرمستقیم می‌پردازد. این سیگنال به صورت ضربانی بوده و الگوها و اطلاعات موجود در آن می‌تواند اطلاعاتی درباره‌ی فشار خون فرد را ارائه دهد. در این مقاله، ما به بررسی استفاده از سیگنال PPG برای تخمین

² Hypertension

¹ Prehypertension

فشار خون پیوسته با استفاده از شبکه‌های عصبی یادگیری عمیق پرداختیم. تخمین شکل موج سیگنال فشار خون نسبت به تخمین مقادیر کلی فشار سیستولیک و دیاستولیک ارجحیت دارد؛ زیرا شکل موج سیگنال فشار خون، اطلاعات دقیق‌تری درباره‌ی عملکرد قلب و عروق و تغییرات آن در طول زمان در اختیار پزشک قرار می‌دهد که می‌تواند در تشخیص بیماری‌ها و پیگیری وضعیت فشار خون مفید باشد.

در این پژوهش یک مدل یادگیری ماشین با عنوان UNet یک‌بعدی با نظارت عمیق برای تخمین فشار خون پیوسته به کار گرفته شد. استفاده از روش نظارت عمیق معمولاً منجر به افزایش دقت و عملکرد مدل‌ها می‌شود. علت این امر این است که با داشتن خروجی‌های میانی و محاسبه‌ی زیان برای آن‌ها، فرایند یادگیری بهتر هدایت می‌شود و لایه‌های مخفی مدل به طور مستقل نیز آموزش می‌بینند. این امر می‌تواند موجب استفاده‌ی بهینه‌تر از اطلاعات درون داده‌ها و استخراج ویژگی‌های مفیدتر شود. همچنین، زیان‌های کمکی که از لایه‌های پایین‌تر تا لایه‌های بالاتر با وزن‌های کاهش‌یافته محاسبه می‌شوند، به مدل اجازه می‌دهند به طور متوازن و پیوسته در کل ساختار آموزش ببینند. این مسئله معمولاً باعث افزایش قابل توجه دقت و کاهش خطاهای کلی مدل می‌شود. با این حال، موفقیت استفاده از نظارت عمیق بستگی به ویژگی‌ها و معماری مدل دارد و در برخی موارد ممکن است تأثیر آن کمتر باشد یا نتایج بهبود چشمگیری نداشته باشند.

مدل ارائه شده بر روی بانک داده‌ی UCI به خطای مطلق میانگین ۸/۸۸، ۴/۴۳ و ۳/۳۲ و انحراف معیار ۱۱/۰۱، ۶/۱۸ و ۴/۱۵ میلی‌متر جیوه به ترتیب برای فشار خون سیستول، دیاستول و میانگین دست یافت. نتایج نشان داد اگرچه تخمین فشار سیستول نسبت به دیاستول با خطای بیشتری همراه است، اما ضریب رگرسیون فشار دیاستول کمتر است. این امر می‌تواند ناشی از وجود نقاط پرت در

فشار دیاستولی بالا (حدود بالاتر از ۱۰) باشد و در صورتی که این نقاط حذف شوند، نتایج قطعاً تغییر خواهد کرد. شکل ۹، که نتایج طبقه‌بندی گروه‌های فشار خون مختلف را ارائه می‌دهد، این واقعیت را تأیید می‌کند که مدل در تخمین فشار خون دیاستولی در گروه فشار خون بالا (hypertension) از دقت کافی برخوردار نیست.

همان‌طور که در بخش نتایج به آن اشاره شد، براساس استاندارد BHS، فشار خون سیستول به رتبه C، دیاستول به رتبه A و فشار خون میانگین به رتبه A دست پیدا کرد. این نتیجه نشان می‌دهد که مدل مورد پیشنهاد قابلیت قابل توجهی در پیش‌بینی دقیق فشار خون دیاستول و میانگین را دارا است و از این‌رو برای کاربردهای بالینی مناسب به نظر می‌رسد. با این حال، برای ارزیابی دقیق‌تر فشار خون سیستول، نیازمند تحقیقات بیشتر هستیم.

جدول ۶ نتایج روش پیشنهادی ما را در مقایسه با مطالعات قبلی که روی یک بانک داده‌ی یکسان گزارش شده‌اند، ارائه می‌کند. با توجه به تعداد داده‌ی مورد استفاده در تحقیقات گذشته، تفاوت در روش‌های پیش پردازش سیگنال PPG و تکنیک‌های ارزیابی نتایج، مقایسه‌ی مستقیم روش‌های پردازشی منصفانه نیست. اما می‌توان یک جمع‌بندی از کلیات روش‌های اعمال شده در پژوهش‌های مختلف و موفقیت نسبی آنها در تخمین فشار خون از روی سیگنال PPG به عنوان ورودی مدل داشت. همان‌طور که در این جدول ملاحظه می‌شود، در تحقیقات مبتنی بر کالیبراسیون فردی، که بخشی از داده‌ی یک شخص در تعلیم مدل رگرسیون استفاده می‌شود، نتایج به صورت چشمگیری بهبود پیدا می‌کند. مطالعات بسیاری بر تأثیر کالیبراسیون فردی در بهبود نتایج تأکید کرده‌اند [۲۱ و ۲۲] اما با توجه به محدودیت استفاده از چنین تکنیکی در کاربردهای بالینی، بسیاری از پژوهش‌ها سعی در افزایش دقت تخمین پارامترهای فشار خون بدون تکیه بر کالیبراسیون فردی داشته‌اند.

در مقاله‌ی [۲۳] که مشابه کار ما از تمام داده‌های بانک داده UCI استفاده کرده و نتایج آن بر اساس عدم کالیبراسیون فردی بوده است، محدوده‌ی خطای گزارش شده مشابه نتایج ما بوده است. البته در مقاله‌ی مذکور از روش‌های شناسایی نقاط کلیدی سیگنال PPG، استخراج ویژگی و مدل سنتی رگرسیون استفاده شده است که به طور کلی ممکن است در مقایسه با تکنیک‌های یادگیری عمیق (مدل پیشنهادی این پژوهش) قدرت انعطاف‌پذیری کمتری در مواجهه با داده‌های جدید داشته باشد. در حقیقت روش‌های سنتی یادگیری ماشین به شدت به مشخصات ساختاری داده‌ها وابسته هستند و در صورت

تغییر ساختار داده، ممکن است نیاز به تنظیم مجدد و حتی طراحی مجدد ویژگی‌ها داشته باشند. در مقاله‌ی [۱۳] نیز که تمام داده‌های بانک داده UCI مورد تحلیل قرار گرفته‌اند، نتایج مطلوبی گزارش شده است. در این مقاله از دو شبکه‌ی UNet به‌عنوان شبکه‌های تخمین و تصحیح استفاده شده است. به این ترتیب، که شبکه‌ی UNet در ابتدا با بهره‌گیری از سیگنال PPG به‌عنوان ورودی، یک تخمین اولیه از سیگنال فشار خون ارائه می‌دهد. در مرحله‌ی بعد، یک شبکه‌ی MultiResUNet با استفاده از سیگنال فشار خون واقعی به‌عنوان ورودی، شکل سیگنال فشار خون تخمینی را اصلاح می‌کند.

جدول ۶ خلاصه‌ای از اطلاعات مهم پژوهش‌های پیشین روی بانک داده UCI (NA به معنی در دسترس نبودن اطلاعات می باشد).

کالیبراسیون	معیار BHS		خطا (MAE)		تعداد داده	مرجع
	DBP	SBP	DBP (mmHg)	SBP (mmHg)		
NA	NA	NA	10.77	17.08	8380	[۲۴]
No	A	B	3.45	5.73	12000	[۱۳]
No	A	C	2.43	3.97	1323	[۲۵]
Yes	A	B	3.38	5.32	1912	[۲۶]
NA	A	A	2.30	3.97	1557	[۲۷]
No	A	C	4.17	8.22	12000	[۲۳]
No	A	B	3.36	5.59	11546	[۲۸]
Yes	A	A	2.81	3.70	1216	[۲۹]
NA	A	A	1.58	3.05	NA	[۳۰]
NA	A	A	2.23	3.21	9000	[۳۱]
Yes	NA	NA	5.57	7.15	1620	[۲۱]
NA	A	A	2.39	3.96	3183	[۳۲]
NA	A	A	2.41	4.05	5289	[۳۳]
No	A	C	4.43	8.88	120000	تحقیق ما

Analysis and Applications, Academic Press, 2022, pp. 359–400.

[5] X. DUAN, "The Analysis of Photoplethysmography Signal: Investigating the Current Methods of Cuff-Less Blood Pressure Monitoring," Vrije Universiteit Brussel & Universiteit Gent, 2021.

[6] C. Landry, S. Peterson, and A. Arami, "Nonlinear Dynamic Modelling of the Blood Pressure Waveform: Towards an Accurate Cuffless Monitoring System," IEEE Sens J, vol. 20, pp. 5368–5378, 2020.

[7] م. شهابی، و. نفیسی، "تخمین بدون کاف فشارخون مبتنی بر ویژگی‌های زمانی سیگنال نبض"، پردازش علائم و داده‌ها، صفحات ۱۰۳–۱۱۳، ۱۳۹۷.

[8] S. S. Mousavi, M. Charimi, M. Firouzmand, and M. Hemmati, "Design and Manufacturing a Mobile-Based Ambulatory Monitoring of Blood Pressure Using Electrocardiogram and Photoplethysmography Signals," University of Zanjan, Zanjan, 2018.

[9] S. Mahmud et al., "A Shallow U-Net Architecture for Reliably Predicting Blood Pressure (BP) from Photoplethysmogram (PPG) and Electrocardiogram (ECG) Signals," sensors, vol. 22, 2022.

[10] D. U. Jeong and K. M. Lim, "Combined deep CNN – LSTM network based multitasking learning architecture for noninvasive continuous blood pressure estimation using difference in ECG PPG features," Sci Rep, no. 0123456789, pp. 1–8, 2021, doi: 10.1038/s41598-021-92997-0.

[11] Y. H. Li, L. N. Harfiya, K. Purwandari, and Y. Der Lin, "Real-time cuffless continuous blood pressure estimation using deep learning model," Sensors (Switzerland), vol. 20, no. 19, pp. 1–19, 2020, doi: 10.3390/s20195606.

[12] S. González, W. Hsieh, and T. P. Chen, "A benchmark for machine-learning based non-invasive blood pressure estimation using photoplethysmogram," Sci. Rep., vol. 10, no. 149, pp. 1–16, 2023.

[13] N. Ibtehaz et al., "PPG2ABP: Translating Photoplethysmogram (PPG) Signals to Arterial Blood Pressure (ABP) Waveforms," Bioengineering, vol. 9, no. 11, 2022.

[14] S. Lee, M. Lee, and J. Y. Sim, "DSE-NN: Deeply Supervised Efficient Neural Network for Real-Time Remote

از نظر شباهت مدل پیشنهادی ما به مدلی که در این مقاله ارائه شده است، باید اشاره کرد که در پژوهش ما از یک شبکه‌ی عمیق UNet با تعداد لایه‌های کمتر نسبت به مقاله‌ی مذکور استفاده شده است، در حالی که در مقاله‌ی [۱۳] از دو شبکه‌ی UNet با تعداد لایه‌های بیشتر بهره‌گیری شده است. همچنین، در روش پیشنهادی ما تغییراتی در طراحی تابع ضرر مدل اعمال شده است (که در بخش ۲–۳ به آن اشاره شد) که در بهبود دقت نهایی مؤثر بوده است. بنابراین، مدل پیشنهادی ما دارای پیچیدگی محاسباتی کمتر و سرعت بالاتری است.

به علاوه، در مقایسه با سایر مقالات، که بعضاً نتایج بهتری را گزارش کرده‌اند، به نظر می‌رسد با توجه به کاهش تعداد نمونه‌های داده، حذف داده‌های پرت انجام شده باشد. همچنین، تعدادی از آنان دارای کالیبراسیون فردی بوده‌اند که باعث بهبود دقت می‌شود.

در مجموع، همان‌طور که در جدول ۶ مشاهده می‌شود، نتایج این پژوهش با توجه به استفاده از حجم بالای داده و عدم استفاده از تکنیک کالیبراسیون فردی، به نتایج مطلوبی در قیاس با نتایج سایر محققین دست پیدا کرده است.

۵- منابع

[1] L. Peter, N. Noury, and M. Cerny, "A review of methods for non-invasive and continuous blood pressure monitoring: Pulse transit time method is promising?," IRBM, vol. 35, no. 5, pp. 271–282, 2014.

[2] K. Qin, W. Huang, T. Zhang, and S. Tang, "Machine learning and deep learning for blood pressure prediction: a methodological review from multiple perspectives," in Artificial Intelligence Review, Springer, 2022, pp. 8095–8196.

[3] س. س. موسوی، "طراحی و ساخت هولتر فشارخون مبتنی بر تلفن همراه با به کارگیری سیگنال‌های الکتروکاردیوگرام و فوتوپلتیسموگرافی"، زنجان، ۱۳۹۷.

[4] R. Mukkamala, J. Hahn, and A. Chandrasekhar, "Photoplethysmography in noninvasive blood pressure monitoring," in Photoplethysmography Technology, Signal

- [24] S. Bose S and A. Kandaswamy, "Sparse characterization of PPG based on K- SVD for beat-to-beat blood pressure prediction," *Biomedical Research*, vol. 29, no. 4, pp. 835–843, 2018.
- [25] S. S. Mousavi et al., "Blood pressure estimation from appropriate and inappropriate PPG signals using a whole-based method," *Biomed Signal Process Control*, vol. 47, pp. 196–206, 2019.
- [26] S. Baek et al., "End-to-End Blood Pressure Prediction via Fully Convolutional Networks," *IEEE Access*, vol. 7, pp. 185458–185468, 2019.
- [27] M. Panwar, A. Gautam, D. Biswas, and A. Acharyya, "PP-Net: a deep learning framework for PPG-based blood pressure and heart rate estimation," *IEEE Sens. J.*, vol. 20, no. 17, pp. 10000–10011, 2020.
- [28] M. Rong and K. Li, "A multi-type features fusion neural network for blood pressure prediction based on photoplethysmography," *Biomed Signal Process Control*, vol. 68, p. 102772, 2021, vol. 68, 2021.
- [29] Y. Qiu et al., "Blood pressure estimation based on composite neural network and graphics information," *Biomed. Signal Process. Control*, vol. 70, no. 103001, 2021.
- [30] A. B. Malayeri and M. B. Khodabakhshi, "Concatenated convolutional neural network model for cuffless blood pressure estimation using fuzzy recurrence properties of PPG signals," *Sci. Rep.*, vol. 12, no. 6633, 2022.
- [31] Y-C. Hsu, Y-H. Li, C-C. Chang, and L. N. Harfiya, "Generalized deep neural network model for cuffless blood pressure estimation with photoplethysmogram signal only," *Sensors*, vol. 20, no. 19, 2020.
- [32] Z. Li and W. He, "A continuous blood pressure estimation method using photoplethysmography by GRNNbased model," *Sensors*, vol. 21, no. 21, 2021.
- [33] L. N. Harfiya, C-C. Chang, and Y-H. Li, "Continuous blood pressure estimation using exclusively photoplethysmography by LSTM-based signal-to-signal translation," *Sensors*, vol. 21, no. 9, 2021.
- Photoplethysmography," *Bioengineering*, vol. 10, no. 12, 2023.
- [15] S. Ali, J. Li, Y. Pei, and K. U. Rehman, "A Multi-module 3D U-Net Learning Architecture for Brain Tumor Segmentation A Multi-module 3D U-Net Learning Architecture for Brain Tumor," in *Data Mining and Big Data*, Springer, 2022, pp. 57–69.
- [16] Y. Li, K. Li, and X. Wang, "Deeply-Supervised CNN Model for Action Recognition with Trainable Feature Aggregation," in *Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence(IJCAI)*, 2017, pp. 807–813.
- [17] G. Dheeru and D. Casey, "UCI Machine Learning Repository."
- [18] M. Kachuee, M.M. Kiani, H. Mohammadzade, and M. Shaban, "Cuffless blood pressure estimation algorithms for continuous health-care monitoring," *IEEE Trans. Biomed. Eng.*, vol. 64, pp. 859–869, 2016.
- [19] D. P. Kingma and L. Ba, "Adam: A method for stochastic optimization," in *3rd International Conference for Learning Representations*, San Diego, 2015.
- [20] P. Lv2, J. Wang, X. Zhang, and Ch. Shi3, "Deep supervision and atrous inception based U Net combining CRF for automatic liver segmentation from CT," *Sci. Rep.*, vol. 12, no. 16995, 2022.
- [21] J. Cheng, Y. Xu, R. Song, Y. Liu, Ch. Li, and X. Chen, "Prediction of arterial blood pressure waveforms from photoplethysmogram signals via fully convolutional neural networks," *Comput. Biol. Med.*, vol. 138, 2021.
- [22] م. قنواتی، س. ف. مولایی زاده، و م. نویدی، "یک روش شخصی‌سازی شده برای تخمین فشارخون بدون کاف از یک سنسور PPG مبتنی بر یادگیری انتقالی عمیق" سی‌امین کنفرانس ملی و هشتمین کنفرانس بین‌المللی مهندسی زیست پزشکی ایران، تهران، ۱۴۰۲.
- [23] N. Hasanzadeh and M.M. Ahmadi, "Blood pressure estimation using photoplethysmogram signal and its morphological features," *IEEE Sens. J.*, vol. 20, no. 8, pp. 4300–4310, 2019.

Using Deep Supervised UNet Network for Continuous Estimation of Blood Pressure Based on Photoplethysmography Signal

Masume Khaleghiana¹, Seyedehsamaneh Shojailangarib^{2*}, Maryam Beigzadeh²

1. Department of Electrical and Computer Engineering, Faculty of Artificial Intelligence, Kharazmi University, Tehran, Iran.

2. Biomedical Engineering group, Department of Electrical and Information Technology, Iranian Research Organization for Science and Technology (IROST), 33535111, Tehran, Iran.

s.shojaie@irost.ir

Receipt: 2024/01/20

Accepted: 2024/10/01

Abstract

Blood pressure monitoring is a vital component of maintaining overall health. High blood pressure values, as a risk factor, can lead to heart attacks, strokes, and heart and kidney failures. Similarly, low blood pressure values can also be dangerous, causing dizziness, weakness, fainting, and impaired oxygen delivery to organs, resulting in brain and heart damage. Consequently, continuous monitoring of blood pressure levels in high-risk individuals is very important. A Holter blood pressure monitoring device is prescribed for many patients due to its ability to provide long-term and valuable blood pressure data. The pursuit of software techniques and the development of cuffless blood pressure measurement devices, while ensuring patient comfort and convenience, are among the significant challenges that researchers are focusing on. In this study, a deep learning framework based on the UNet network is proposed for continuous blood pressure estimation from photoplethysmography signals. The proposed model was evaluated on the UCI database, involving 942 patients under intensive care, and achieved mean absolute errors of 8.88, 4.43, and 3.32, with standard deviations of 11.01, 6.18, and 4.15, respectively, for systolic, diastolic, and mean arterial blood pressure values. According to the international BHS standard, the proposed method meets grade A criteria for diastolic and mean blood pressure estimations and grade C for systolic blood pressure estimation. The results of this study demonstrate that the suggested deep learning framework has the necessary potential for blood pressure estimation from PPG signals in real-world applications.

Keywords: Photoplethysmography signal, Blood pressure estimation, Non-invasive technique, Artificial intelligence, Deep learning, Machine learning