



A Personalized Method for Cuff-less Blood Pressure Estimation from Single PPG Sensor based on Deep Transfer Learning

Ghanavaty, Marziyeh¹ / Molaezadeh, Seyyede Fatemeh^{2*} / Navidi, Mojtaba¹

¹ - M.Sc. Student, Department of Electrical and Computer Engineering, Jundi-Shapur University of Technology, Dezful, Iran

² - Assistant Professor, Department of Electrical and Computer Engineering, Jundi-Shapur University of Technology, Dezful, Iran

ARTICLE INFO

DOI: 10.22041/ijbme.2024.2015090.1869

Received: 6 November 2023

Revised: 9 January 2024

Accepted: 13 January 2024

KEYWORDS

Bidirectional Long Short-Term Memory (BiLSTM)
Personalizing
Convolutional Neural Network (CNN)
Blood Pressure
Photoplethysmography
Transfer Learning

ABSTRACT

Hypertension is the leading cause of death worldwide. Continuous blood pressure (BP) measurement is crucial for the elderly and people with myocardial infarction, cardiovascular disease, kidney disease and gestational hypertension. Cuff-based blood pressure Holters are the most common method for continuous blood pressure measurement, but due to the use of an inflatable cuff, they often cause discomfort, particularly during sleep. A solution to such problems is the optical measurement of blood pressure using the photoplethysmogram (PPG) signal. This paper introduces a transfer deep learning framework for estimating systolic BP (SBP) and diastolic BP (DBP) using a single PPG signal. The proposed framework consists of three main parts: 1) downsampling by a factor of 4 aimed at reducing model complexity, 2) designing a pre-trained model including CNN and BiLSTM layers, and 3) personalizing the pre-trained model for each patient through transfer learning. We carry out Bland-Altman and correlation analysis to compare our method to the invasive arterial catheter (the gold-standard BP measurement method). Our model was validated on a wide range of BP signals acquired from 100 patients in MIMIC-III database. Results showed that the error and Pearson correlation coefficient of our model are 0.14 ± 7.38 mmHg (mean \pm standard deviation) and 0.95 for SBP, and 0.00 ± 4.67 mmHg and 0.92 for DBP. The proposed method satisfies the requirements the AAMI and IEEE-1708a standard and receives a grade A according to the BHS standard. This research has shed light on long-term BP monitoring and the prevention of cardiovascular events.

*Corresponding Author

Address: Department of Electrical and Computer Engineering, Jundi-Shapur University of Technology, Dezful, Iran

Postal Code: 64615-334

E-Mail: fnolae@jsu.ac.ir

Tel: +98-61-42418500



۱- مقدمه

طبق آمارهای منتشر شده توسط سازمان بهداشت جهانی، بیماری‌های قلبی عروقی مهم‌ترین عامل مرگ و میر در جهان هستند. اندازه‌گیری پیوسته‌ی فشار خون برای تشخیص و پیش‌بینی بیماری‌های قلبی عروقی ضرورت دارد. روش مرسوم برای اندازه‌گیری غیرتهاجمی و پیوسته‌ی فشار خون استفاده از هولترهای فشار خون مبتنی بر کاف است. این روش مشکلاتی از جمله آسیب بافت زیرین در اثر استفاده‌ی طولانی مدت از کاف، عدم صحت اندازه‌گیری فشار خون به دلیل تطبیق وضعیت رگ‌ها با فشار ناشی از کاف و همچنین مزاحمت شخص در اثر صدای ناشی از پر و خالی شدن کاف در طی شب را به دنبال دارد. یک راه حل برای این مشکلات استفاده از سیگنال‌های زیستی هم‌چون فوتوپلتیسموگرام (PPG) است.

فوتوپلتیسموگرافی یک روش نوری است که با تاباندن نور از یک منبع نور به قسمتی از بافت بدن و دریافت نور منعکس شده توسط یک آشکارساز نوری، تغییرات حجم خون را در بستر عروق شریانی اندازه‌گیری می‌کند [۱]. از آن‌جا که ثبت سیگنال PPG یک روش کم‌هزینه و با کاربری آسان بوده توجه محققان را در زمینه‌ی تخمین فشار خون به خود جلب کرده است.

یکی از روش‌های متداول در تخمین فشار خون استفاده از زمان گذار نبض (PTT) است. در بسیاری از مطالعات برای تخمین فشار خون ویژگی PTT از دو سیگنال PPG و ECG استخراج شده [۲-۶] اما از آن‌جا که ثبت صحیح سیگنال ECG حداقل به سه الکتروود در نقاط مختلف بدن نیاز دارد در برخی از مطالعات دیگر دو سیگنال PPG برای استخراج PTT به کار گرفته شده است [۷، ۸]. استفاده از دو سیگنال ورودی به دو حسگر در دو نقطه‌ی مختلف بدن نیاز دارد و آزادی حرکت شخص را محدود می‌کند. هم‌چنین وجود دو سیگنال در ورودی، پیچیدگی محاسباتی مدل تخمین فشار خون را افزایش می‌دهد [۹-۱۱]. به این ترتیب در مطالعات اخیر روی تخمین فشار خون از یک سیگنال PPG تمرکز شده است.

در تعدادی از مطالعات پیشین با استخراج ویژگی‌های دستی از سیگنال PPG به تخمین فشار خون به کمک الگوریتم‌های یادگیری ماشین پرداخته شده است [۱۰-۱۷]. در مطالعه‌ی [۱۳] به منظور تخمین فشار خون با استفاده از یک شبکه‌ی عصبی مصنوعی، ۲۱ ویژگی از شکل موج سیگنال PPG استخراج شده است. در مقاله‌ی [۱۴] نیز از ویژگی‌های مورفولوژیکی سیگنال PPG برای آموزش یک مدل GPR^۱ نمایی استفاده شده است. در تحقیق [۱۵] مشتقات اول و دوم

سیگنال PPG برای استخراج ویژگی‌های دستی به کار گرفته شده و با استفاده از تکنیک‌های انتخاب ویژگی، ویژگی‌های مفیدتر در تخمین فشار خون انتخاب شده است. علاوه بر این در پژوهش [۱۶] فواصل بین برآمدگی‌ها و فرورفتگی‌ها^۲ (IBI) به عنوان ویژگی‌های حاصل از تغییرات دینامیکی سیگنال PPG در کنار سایر ویژگی‌های مورفولوژیکی سیگنال PPG مورد استفاده قرار گرفته اما با توجه به حساس بودن سیگنال PPG به منابع نویز، استخراج ویژگی‌های دستی از آن دشوار بوده و ممکن است برخی از نقاط مهم در شکل موج سیگنال PPG قابل تشخیص نباشد. هم‌چنین تکنیک‌های انتخاب ویژگی بار محاسباتی اضافی را در فرایند تخمین فشار خون ایجاد می‌کنند. به همین دلیل در برخی مطالعات از پتانسیل الگوریتم‌های یادگیری عمیق برای استخراج خودکار ویژگی‌ها از سیگنال PPG استفاده شده است [۹، ۱۸-۲۰].

در سال‌های اخیر ترکیب شبکه‌های عصبی کانولوشن و شبکه‌های عصبی بازگشتی به دلیل مدل‌سازی وابستگی‌های کوتاه‌مدت و بلندمدت در داده‌های زمانی مورد توجه محققان قرار گرفته است. در تحقیق [۹] یک مدل CNN-LSTM برای تخمین هم‌زمان ضربان قلب، فشار خون سیستولیک و دیاستولیک از سری زمانی PPG و بدون نیاز به استخراج ویژگی ارائه شده است. در مقاله‌ی [۱۸] یک شبکه‌ی عصبی چندمرحله‌ای مبتنی بر CNN و LSTM برای تخمین جداگانه‌ی فشار خون سیستولیک و دیاستولیک طراحی شده و تقطیع سری زمانی PPG بر اساس آشکارسازی کمپلکس QRS از سیگنال ECG انجام شده است. در پژوهش [۲۰] یک مدل CNN-GRU برای تخمین هم‌زمان فشار خون سیستولیک و دیاستولیک از سری زمانی PPG پیشنهاد شده است.

با توجه به مورفولوژی اختصاصی سیگنال PPG برای هر فرد، مدل‌های شخصی‌سازی شده می‌توانند امکان اندازه‌گیری دقیق و قابل اعتماد فشار خون را فراهم کنند. یادگیری انتقالی معمولاً زمانی که تعداد داده‌ی کمی برای آموزش یک مدل در دسترس باشد به کار گرفته می‌شود [۲۱]. بنابراین برای این که شخصی‌سازی مدل تخمین فشار خون به تعداد داده‌ی کم‌تری نیاز داشته باشد، یادگیری انتقالی یک راه حل مناسب است. در این راستا در مطالعه‌ی [۲۰] یک مدل شخصی‌سازی شده با یادگیری انتقالی و بدون یادگیری انتقالی برای تخمین فشار خون سیستولیک و دیاستولیک آموزش داده شده است. نتایج تحقیق [۲۰] برتری روش شخصی‌سازی مبتنی بر یادگیری انتقالی را نسبت به روش بدون یادگیری انتقالی نشان داده است.

^۲ Interbeat Intervals^۱ Exponential Gaussian Process Regression

مختلف فشار خون با در نظر گرفتن گروه فشار خون پایین، نمودار جعبه‌ای مقادیر تخمین زده شده و مرجع و آنالیز پیچیدگی مدل یادگیری عمیق ارائه شده است. همچنین علاوه بر استانداردهای AAMI و BHS، عمل کرد مدل بر اساس استاندارد IEEE-1708a که در سال‌های اخیر برای دستگاه‌های پوشیدنی فشار خون ارائه شده، بررسی گشته است.

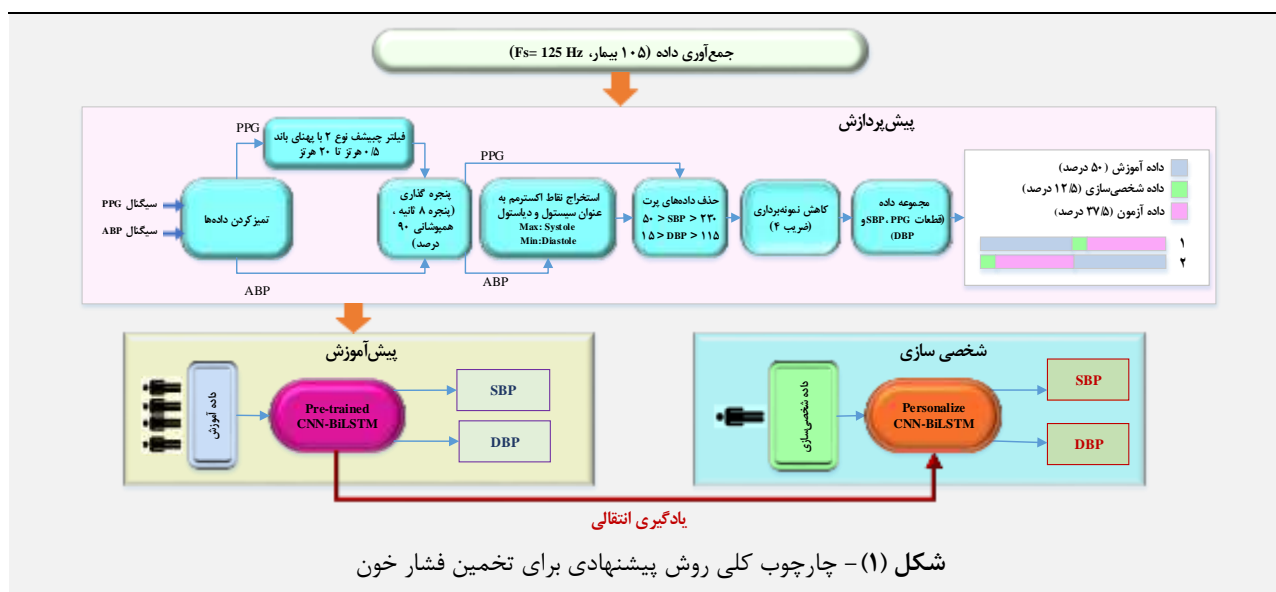
در ادامه در بخش ۲ مراحل انجام تحقیق به تفصیل شرح داده شده است. در بخش ۳ نتایج حاصل از این پژوهش ارائه شده، روش پیشنهادی با سایر مطالعات مقایسه گردیده و با الزامات استانداردهای AAMI، BHS و IEEE 1708-2019 تطبیق داده شده است. در بخش ۴ نیز نتیجه‌گیری ارائه شده است.

۲- مواد و روش‌ها

چارچوب کلی روش پیشنهادی برای تخمین فشار خون در شکل (۱) نشان داده شده که شامل چهار مرحله جمع‌آوری داده، پیش‌پردازش، پیش‌آموزش و شخصی‌سازی است. در ادامه هر یک از مراحل روش پیشنهادی شرح داده شده است.

در این پژوهش یک الگوریتم یادگیری عمیق شامل شبکه‌ی عصبی کانولوشن و حافظه‌ی طولانی کوتاه‌مدت دوجهته (CNN-BiLSTM) برای تخمین فشار خون سیستولیک و دیاستولیک از سیگنال PPG طراحی شده است. در این روش با الهام از تحقیق [۲۰] از یادگیری انتقالی برای شخصی‌سازی مدل برای هر فرد استفاده شده است. علاوه بر این برای کاهش حجم مدل یادگیری عمیق پیشنهادی جهت استفاده در پلتفرم‌های دارای منابع محدود همچون تلفن همراه، کاهش نمونه‌برداری^۱ انجام شده است.

این روش پیشنهادی نخستین بار در ۳۰-امین کنفرانس ملی و ۸-امین کنفرانس بین‌المللی مهندسی زیست پزشکی ایران ارائه شده است. مطالعه‌ی حاضر نسخه‌ی توسعه یافته و کامل‌تری از پژوهش پیشین [۲۲] بوده و در آن تحلیل‌های جامع‌تری نظیر بررسی دقت مدل به ازای هر ۱۰ میلی‌مترجیوه از فشار خون سیستولیک و دیاستولیک، بررسی دقت مدل تخمین فشار خون به تفکیک بیماران، تحلیل گرافیکی مقادیر فشار خون تخمین زده شده و مرجع، بررسی دقیق‌تر عمل کرد مدل برای طبقات



شکل (۱) - چارچوب کلی روش پیشنهادی برای تخمین فشار خون

۲-۱- مجموعه‌ی داده

در این پژوهش از دو سیگنال فوتوپلتیسموگرام و فشار خون شریانی مربوط به ۱۰۵ بیمار از مجموعه‌ی داده‌ی MIMIC-III^۲ در پایگاه داده‌ی فیزیونت^۳ که بیش از ۱۱ ساعت داده از هر دو سیگنال ABP و PPG برای آن‌ها موجود بوده، استفاده شده است. فرکانس نمونه‌برداری داده‌ها ۱۲۵ هرتز است [۲۳]. فشار خون شریانی از یک شریان رادیال با یک کاتتر ته‌اجمی و داده‌ی PPG از یک حس‌گر نوری نوک انگشت ثبت شده است.

۲-۲- پیش‌پردازش

در این مرحله ابتدا بخش‌های دارای مقادیر ناموجود^۴، کم‌دامنه یا خطوط صاف از هر دو سیگنال PPG و ABP حذف شده است. چنین شکل موج‌هایی در اثر آرتیفکت حرکتی یا عدم استفاده‌ی صحیح از حس‌گر توسط بیمار یا جدا شدن حس‌گر از بیمار به وجود می‌آید. برای حذف نویزهای سیگنال PPG، یک فیلتر چبیشف نوع ۲ مرتبه‌ی ۴، فرکانس قطع پایین ۰/۵۵ هرتز و فرکانس قطع بالای ۲۰ هرتز روی سیگنال PPG اعمال

^۲ Physionet

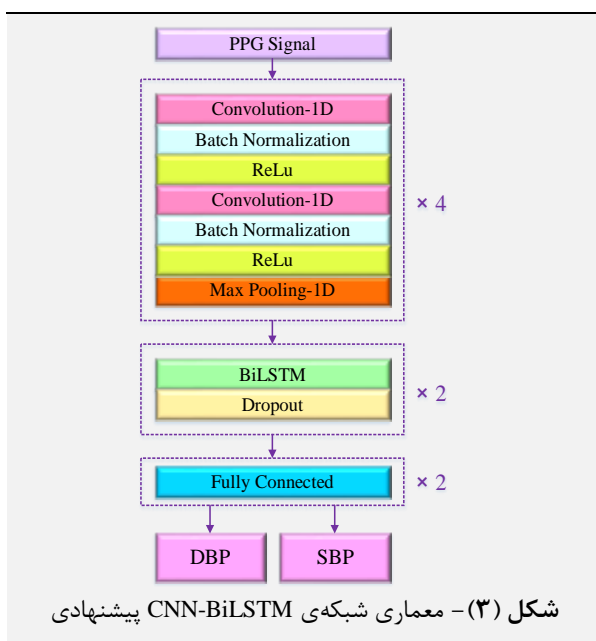
^۴ Nan

^۱ Downsampling

^۲ Multiparameter Intelligent Monitoring in Intensive Care III

۲-۳- پیش‌آموزش

در مرحله‌ی پیش‌آموزش یک مدل یادگیری عمیق پیشنهادی CNN-BiLSTM آموزش داده شده که معماری آن در شکل (۳) نشان داده شده است. برای تمام لایه‌های کانولوشن اندازه‌ی فیلتر 3×1 (عرض ۱، ارتفاع ۳) با اندازه‌ی گام ۱ مورد استفاده قرار گرفته است. لایه‌ی ادغام حداکثری^۳ در این معماری دارای اندازه‌ی فیلتر 3×1 (عرض ۱، ارتفاع ۳) با اندازه‌ی گام ۳ است. تعداد فیلترهای دو لایه‌ی کانولوشن اول ۶۴، دو لایه‌ی کانولوشن دوم ۱۲۸، دو لایه‌ی کانولوشن سوم ۲۵۶ و دو لایه‌ی کانولوشن چهارم ۵۱۲ است. دو لایه‌ی BiLSTM نیز به ترتیب تعداد ۱۲۵ و ۱۰۰ سلول حافظه دارند که پس از هر کدام یک لایه‌ی حذفی^۴ با ضریب $0/2$ قرار گرفته است. در لایه‌های انتهایی معماری پیشنهادی نیز دو لایه‌ی تماماً متصل به ترتیب با ۶۴ و ۲ نورون وجود دارد. تعداد ۲ نورون در لایه‌ی خروجی برای تعیین فشار خون سیستولیک و دیاستولیک وجود دارد.



برای آموزش شبکه در مرحله‌ی پیش‌آموزش از دوره^۵ با اندازه‌ی دسته^۶ ۲۵۰ و بهینه‌ساز^۷ RMSProp استفاده شده است. نرخ یادگیری^۸ در تمام طول آموزش $0/001$ بوده و میانگین مربعات خطا^۹ (MSE) به عنوان تابع هزینه برای ارزیابی مدل پیشنهادی در نظر گرفته شده است. تعیین مقادیر ابرپارامترها در این پژوهش بر اساس مطالعه‌ی [۲۰] و همچنین مقادیر پیش‌فرض نرم‌افزار MATLAB2022b بوده است.

^۵ Minibatch Size

^۷ Optimizer

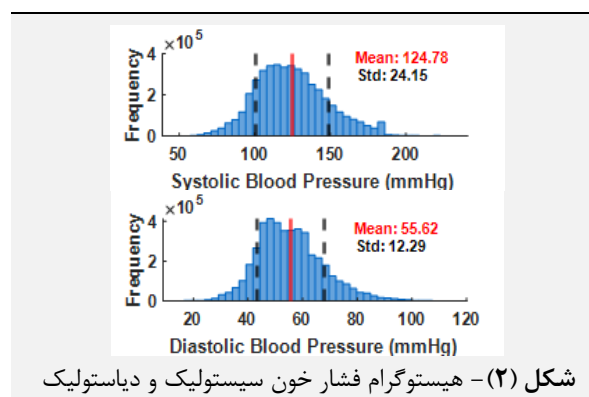
^۸ Learning Rate

^۹ Mean Squared Error

شده [۲۴] و در ادامه سیگنال‌های PPG و ABP به پنجره‌هایی با طول ۸ ثانیه (۱۰۰۰ نمونه در هر پنجره) با 90% هم‌پوشانی تقسیم شده است [۹]. برای هر پنجره، بزرگ‌ترین پیک^۱ و بیش‌ترین فرورفتگی^۲ در سیگنال ABP به عنوان مقادیر مرجع فشار خون سیستولیک و دیاستولیک انتخاب شده است.

در ادامه‌ی فرایند پیش‌پردازش، حذف داده‌های پرت صورت گرفته است. در این راستا داده‌های فشار خون سیستولیک بین ۵۰ تا ۲۳۰ میلی‌مترجیوه و مقادیر فشار خون دیاستولیک در بازه‌ی ۱۵ تا ۱۱۵ میلی‌مترجیوه حفظ شده و تمام مقادیر خارج از این بازه‌ها حذف گردیده است. داده‌های بیمارانی که پس از مراحل پیش‌پردازش، مشابه با تحقیق [۲۰] حداقل ۱۰ ساعت از هر دو سیگنال PPG و ABP برای آن‌ها وجود داشته باشد ذخیره گشته و برای هر پنجره کاهش نمونه‌برداری با ضریب ۴ انجام شده است [۲۵]. کاهش نمونه‌برداری با حفظ اطلاعات مهم سیگنال، به کاهش پیچیدگی محاسباتی مدل یادگیری عمیق کمک کرده و پیاده‌سازی مدل روی پلتفرم‌های دارای منابع محدود را امکان‌پذیر می‌کند [۹].

پس از انجام پیش‌پردازش، ۵ بیمار که دارای کم‌تر از ۱۰ ساعت داده بودند حذف شده و تعداد بیماران از ۱۰۵ به ۱۰۰ کاهش یافته است. با روش اعتبارسنجی عرضی دولایه، ۵۰ درصد از بیماران برای آموزش مدل و از میان ۵۰ درصد دوم، ۲۵ درصد از داده‌های هر بیمار (در مجموع $12/5$ درصد از داده‌ی تمام بیماران) برای شخصی‌سازی و 75 درصد از داده‌های هر بیمار (در مجموع $37/5$ درصد از داده‌ی تمام بیماران) برای ارزیابی مدل مورد استفاده قرار گرفته است. بر اساس تحقیق [۲۰] تعداد ۵۰ بیمار برای آموزش انتخاب شده است. در شکل (۲) پراکندگی فشار خون‌های سیستولیک و دیاستولیک مربوط به ۱۰۰ بیمار توسط دو نمودار هیستوگرام نشان داده شده است.



^۱ Peak

^۲ Valley

^۳ Max Pooling

^۴ Dropout

^۵ Epoch



۲-۴- شخصی سازی

در این مرحله شبکه‌ی آموزش دیده در مرحله‌ی قبل با استفاده از روش یادگیری انتقالی با بخشی از داده‌های هر بیمار به طور جداگانه برای هر نفر آموزش داده شده است. در این مرحله ضریب یادگیری پنج لایه‌ی کانولوشن ابتدایی برابر با صفر قرار داده شده است تا در حین آموزش وزن‌ها و بایاس‌های آن تغییر نکند. آموزش مدل در مرحله‌ی شخصی سازی برای ۵۰ دوره با اندازه‌ی دسته‌ی ۲۵۰ و نرخ یادگیری ۰/۰۰۱ و با استفاده از بهینه‌ساز RMSProp برای ۱۰۰ نفر انجام شده و در نهایت برای هر نفر یک مدل اختصاصی به دست آمده است.

۳- یافته‌ها و بحث

مدل یادگیری عمیق پیشنهادی روی سیستمی با پردازنده‌ی Intel Core i7-8700 ۳/۲۰ گیگاهرتز با ۳۲ گیگابایت رم و پردازنده‌ی گرافیکی NVIDIA RTX3050 اجرا شده است.

۳-۱- تخمین فشار خون بدون شخصی سازی

برای تخمین فشار خون بدون شخصی سازی، مدل پیشنهادی CNN-BiLSTM یک بار با مجموعه‌ی داده‌ی ۵۰ بیمار اول و بار دیگر با مجموعه‌ی داده‌ی ۵۰ بیمار دوم آموزش داده شده و دو مدل به دست آمده که با آزمایش هر یک از این دو مدل با ۷۵ درصد از ثبت‌های هر بیمار از مجموعه‌ی داده‌ای که در مرحله‌ی آموزش نبوده، خطای شبکه‌ی CNN-BiLSTM بدون شخصی سازی به دست آمده است. میانگین خطای این دو مدل معادل خطای کلی شبکه‌ی CNN-BiLSTM است.

جداسازی ۷۵ درصد از داده‌های هر فرد برای ارزیابی شبکه به این دلیل است که بخشی از داده‌های هر فرد برای شخصی سازی مدل استفاده شده و فقط ۷۵ درصد از داده‌های هر بیمار برای آزمون باقی می‌ماند. بنابراین جهت مقایسه‌ی نتایج تخمین فشار خون با و بدون شخصی سازی، داده‌های یکسانی برای ارزیابی شبکه در هر دو حالت در نظر گرفته شده است.

میانگین و انحراف معیار خطای مدل CNN-BiLSTM بدون شخصی سازی برای فشار خون سیستولیک برابر با $2/88 \pm 2/05$ و برای فشار خون دیاستولیک برابر با $2/88 \pm 14/09$ میلی‌مترجیوه به دست آمده است.

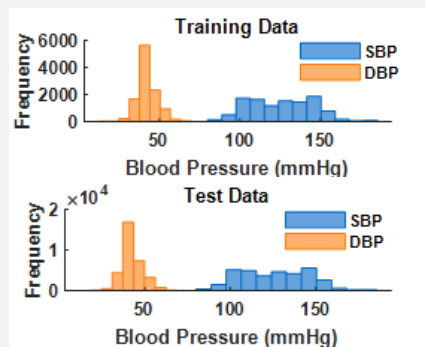
۳-۲- تخمین فشار خون با شخصی سازی

برای شخصی سازی مدل، شبکه‌ی پیش‌آموزش با ۲۵ درصد از داده‌های هر بیمار و به صورت جداگانه برای هر نفر ۵۰ دوره از

دیگر آموزش داده شده است. برای شخصی سازی و آزمایش شبکه‌ی از پیش آموزش دیده با مجموعه‌ی داده‌ی اول، از مجموعه‌ی داده‌ی دوم استفاده شده است (و برعکس). در نهایت برای هر شخص یک مدل اختصاصی متناسب با مشخصات فیزیولوژیکی او به دست آمده و شبکه‌ی شخصی سازی شده برای هر فرد با ۷۵٪ از داده‌های همان فرد آزمایش شده است. با انجام شخصی سازی، میانگین و انحراف معیار خطای تمام بیماران برای فشار خون سیستولیک برابر با $14 \pm 7/38$ و برای فشار خون دیاستولیک برابر با $0/00 \pm 4/67$ میلی‌مترجیوه به دست آمده است. مقایسه‌ی نتایج تخمین فشار خون با و بدون شخصی سازی در جدول (۱) ارائه شده است. با انجام شخصی سازی، میانگین قدرمطلق خطا^۱ (MAE) برای فشار خون سیستولیک ۸۰/۲ درصد و برای فشار خون دیاستولیک ۷۷/۹ درصد نسبت به حالت بدون شخصی سازی بهبود یافته است. در شکل (۴) هیستوگرام داده‌های آموزش و آزمون برای یک بیمار ترسیم شده است که نشان می‌دهد تنوع داده در هر دو مرحله‌ی آموزش و آزمون برای شخصی سازی وجود دارد.

جدول (۱) - نتایج تخمین فشار خون با و بدون شخصی سازی

| MAE (mmHg) | STD (mmHg) | ME (mmHg) | | |
|------------|------------|-----------|-----|----------------|
| ۲۱/۳۲ | ۲۸/۰۵ | -۲/۰۰ | SBP | بدون شخصی سازی |
| ۱۱/۱۸ | ۱۴/۰۹ | -۲/۸۸ | DBP | بدون شخصی سازی |
| ۴/۲۱ | ۷/۳۸ | ۰/۱۴ | SBP | با شخصی سازی |
| ۲/۴۷ | ۴/۶۷ | ۰/۰۰ | DBP | با شخصی سازی |

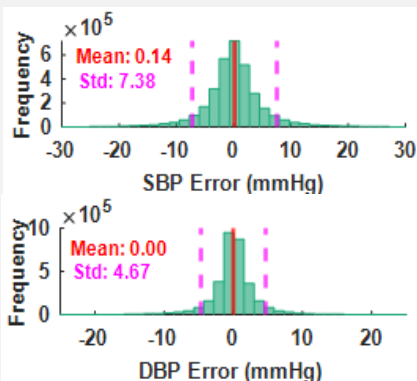


شکل (۴) - هیستوگرام داده‌های آموزش و آزمون برای یک بیمار در مرحله‌ی شخصی سازی

ضریب همبستگی پیرسون^۲ معیاری است که نشان می‌دهد دو مجموعه‌ی داده تا چه حد به صورت خطی همبستگی دارند. نمودار همبستگی پیرسون بین مقادیر تخمین زده شده و مقادیر مرجع مربوط به تمام بیماران در شکل (۵) نشان داده شده است. ضریب همبستگی پیرسون برای فشار خون سیستولیک ۰/۹۵ و برای فشار خون دیاستولیک ۰/۹۲ است.

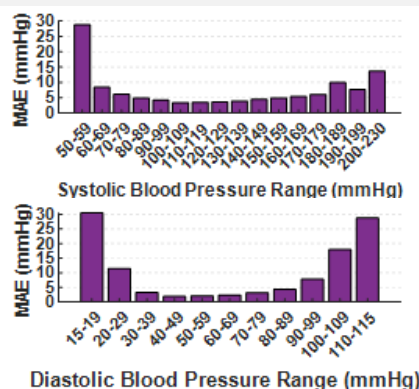
^۱ Pearson Correlation Coefficient

^۲ Mean Absolute Error



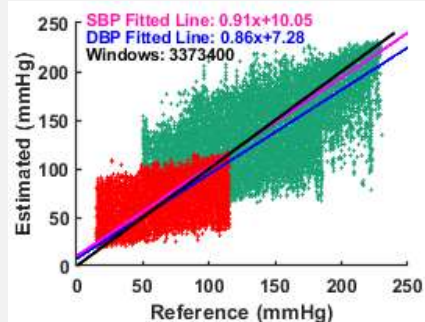
شکل (۷) - نمودار هیستوگرام اختلاف مقادیر تخمین زده شده و مرجع برای فشار خون سیستولیک و دیاستولیک

مقادیر خطای MAE به ازای هر ۱۰ میلی‌متر جیوه در شکل (۸) نشان داده شده است. مدل پیشنهادی برای اندازه‌گیری فشار خون سیستولیک در بازه‌ی ۷۰-۱۸۰ میلی‌متر جیوه و برای فشار خون دیاستولیک در بازه‌ی ۳۰-۹۹ میلی‌متر جیوه، مقدار MAE کم‌تر از ۷ میلی‌متر جیوه [۲۷] دارد. باید توجه داشت که عمل‌کرد الگوریتم‌های یادگیری ماشین به شدت به داده‌های مورد استفاده برای آموزش و ارزیابی آن‌ها بستگی دارد [۱۸]. مقایسه‌ی شکل‌های (۲) و (۸) نشان می‌دهد که هر چه تعداد داده‌های آموزشی کم‌تر باشد دقت الگوریتم کم‌تر است.



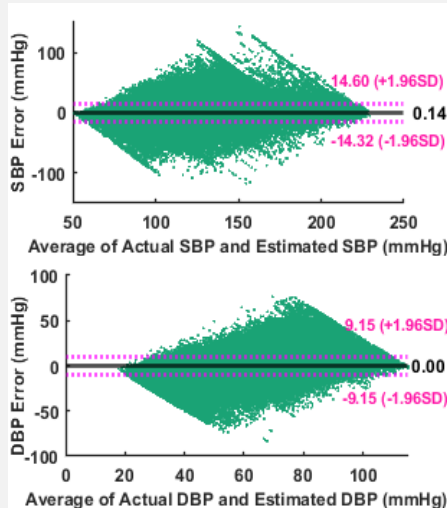
شکل (۸) - نمودار میله‌ای مقادیر MAE به ازای هر ۱۰ میلی‌متر جیوه برای فشار خون سیستولیک و دیاستولیک

در تحقیق [۷] اندازه‌گیری فشار خون بیماران همودیالیزی مورد توجه قرار گرفته است. مقایسه‌ی نتایج مقاله‌ی حاضر و تحقیق [۷] در محدوده‌ی فشار خون یکسان در جدول (۲) ارائه شده است که دقت بالاتر مدل پیشنهادی این مقاله را در بازه‌ی سیستولیک ۷۰-۱۴۰ میلی‌متر جیوه نشان می‌دهد. علاوه بر این در تحقیق حاضر از یک سیگنال PPG استفاده شده است. بنابراین روش پیشنهادی در این پژوهش برای اندازه‌گیری فشار خون بیماران همودیالیزی نیز کاربرد دارد.



شکل (۵) - نمودار همبستگی بین فشار خون سیستولیک (سبز) و دیاستولیک (قرمز) تخمین زده شده و مرجع

نمودار بلند-آلتمن^۱ برای فشار خون سیستولیک و دیاستولیک در شکل (۶) ترسیم شده است. برای این که روش اندازه‌گیری فشار خون شریانی و روش پیشنهادی این مقاله قابل مقایسه باشند، طبق توافقات بلند-آلتمن لازم است ۹۵٪ از نمونه‌ها در بازه‌ی میانگین ± (انحراف معیار × ۱/۹۶) باشند [۲۶]. برای فشار خون سیستولیک ۹۵/۲۲٪ از نمونه‌ها و برای فشار خون دیاستولیک ۹۵/۵۴٪ از نمونه‌ها در بازه‌ی تعیین شده (خط‌چین) در نمودار بلند-آلتمن هستند که در بازه‌ی توافقات بلند-آلتمن قرار دارد. هم‌چنین تحلیل بلند-آلتمن برای هر بیمار به طور جداگانه نیز انجام شده است. به ترتیب ۶۲٪ و ۶۴٪ از بیماران برای SBP و DBP به این توافق دست یافته‌اند.



شکل (۶) - نمودار بلند-آلتمن برای فشار خون سیستولیک و دیاستولیک

هم‌چنین نمودار هیستوگرام اختلاف مقادیر مرجع و مقادیر تخمینی فشار خون سیستولیک و دیاستولیک برای تمام بیماران در شکل (۷) ترسیم شده است. مشاهده می‌شود که بیش‌تر مقادیر خطا حول صفر قرار دارند.

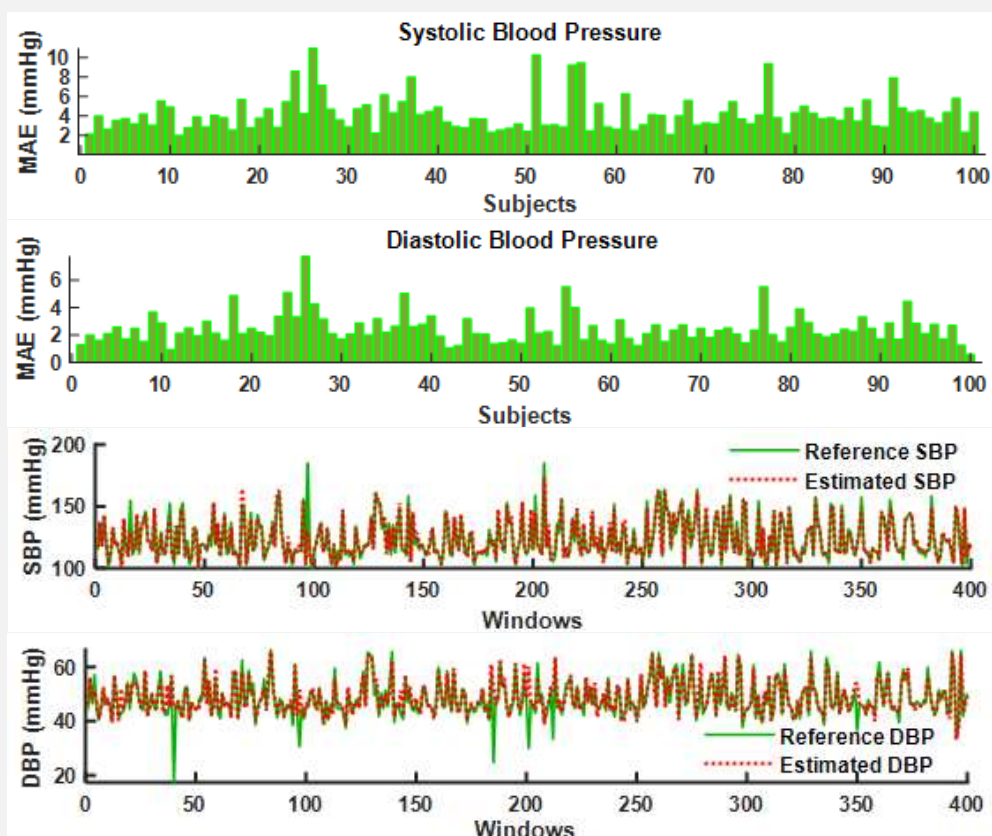
^۱ Bland-Altman

دارند. در شکل (۹) تحلیل گرافیکی مقادیر مرجع و مقادیر تخمینی فشار خون سیستولیک و دیاستولیک مربوط به یک بیمار به ازای ۴۰۰ پنجره‌ی آزمون ترسیم شده است که نشان می‌دهد مقادیر فشار خون تخمین زده شده با مدل پیشنهادی در این پژوهش، مقادیر مرجع را به خوبی دنبال می‌کند.

برای بررسی دقیق‌تر عمل کرد روش مبتنی بر شخصی سازی، مقادیر MAE به تفکیک بیماران محاسبه شده و به صورت نمودار میله‌ای در شکل (۹) نشان داده شده است. برای فشار خون دیاستولیک ۹۹٪ از بیماران و برای فشار خون سیستولیک ۹۱٪ از بیماران MAE کم‌تر از ۷ میلی‌متر جیوه

جدول (۲) - مقایسه‌ی نتایج مقاله‌ی حاضر و تحقیق [۷] در بازه‌ی فشار خون یکسان

| SBP (mmHg) | | بازه‌ی فشار خون | تعداد افراد | نوع سیگنال | تحقیق |
|------------|-------|------------------|-------------|------------|------------|
| SD | ME | | | | |
| ۴/۱۷ | ۱۰/۶۸ | $70 < SBP < 140$ | ۸ | Dual PPG | [۷] |
| ۶/۲۵ | -۰/۵۹ | $70 < SBP < 140$ | ۱۰۰ | Single PPG | تحقیق حاضر |



شکل (۹) - نمودار میله‌ای مقادیر MAE برای فشار خون سیستولیک و دیاستولیک به تفکیک بیماران (دو شکل بالا)، تحلیل گرافیکی فشار خون‌های سیستولیک و دیاستولیک تخمین زده شده و مرجع برای یک بیمار به ازای ۴۰۰ پنجره‌ی آزمون (دو شکل پایین)

جدول (۳) - طبقه‌بندی فشار خون

| فشار دیاستولیک (mmHg) | فشار سیستولیک (mmHg) | طبقه‌بندی |
|-----------------------|----------------------|---------------------|
| <۶۰ | <۹۰ | فشار خون پایین |
| ۶۰-۷۹ | ۹۰-۱۱۹ | نرمال |
| ۸۰-۸۹ | ۱۲۰-۱۳۹ | پیش فشار خون |
| ۹۰-۹۹ | ۱۴۰-۱۵۹ | فشار خون بالا سطح ۱ |
| ۱۰۰-۱۰۹ | ۱۶۰-۱۷۰ | فشار خون بالا سطح ۲ |
| ≥۱۱۰ | ≥۱۸۰ | فشار خون بالا سطح ۳ |

۳-۳- بررسی عمل کرد مدل بر اساس طبقات مختلف فشار خون در این پژوهش فشار خون تمام بیماران بر اساس بازه‌های تعیین شده در جدول (۳) به ۶ کلاس طبقه‌بندی شده است [۲۸]. میانگین و انحراف معیار خطای فشار سیستولیک و دیاستولیک در ۶ کلاس در شکل (۱۰) ارائه شده است. مشاهده می‌شود که مدل CNN-BiLSTM-Transfer برای تخمین فشار خون سیستولیک در گروه‌های نرمال، پیش فشار خون و فشار خون بالای سطح یک و برای فشار خون دیاستولیک در گروه‌های فشار خون پایین، نرمال و پیش فشار خون دقت بالایی دارد.

فشار خون بالای سطح سه است. کم‌ترین خطا برای گروهی بوده که بیش‌ترین تعداد داده را دارد و بیش‌ترین خطا مربوط به گروه دارای کم‌ترین داده است. نمودار مقادیر فشار خون مرجع و تخمینی برای ۶ کلاس در شکل (۱۱) ارائه شده است.

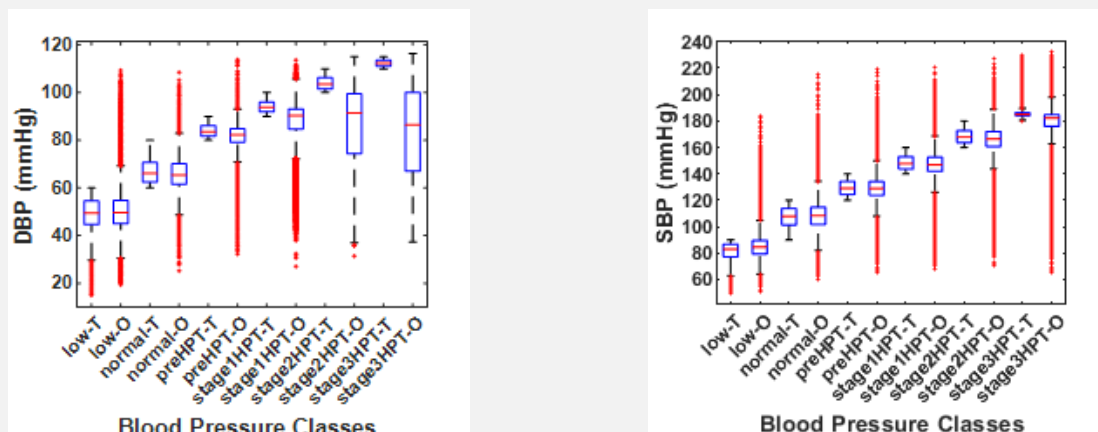
جدول (۴) نشان می‌دهد که بیش‌ترین دقت بر اساس میانگین قدرمطلق خطا در تخمین فشار سیستولیک و دیاستولیک به ترتیب مربوط به گروه نرمال و گروه فشار خون پایین و کم‌ترین دقت برای هر دو فشار سیستولیک و دیاستولیک مربوط به گروه



شکل (۱۰) - عمل کرد شبکه‌ی CNN-BiLSTM بر اساس طبقات مختلف فشار خون، میله‌ها: میانگین خطا، خطوط صورتی: انحراف معیار خطا

جدول (۴) - میانگین قدرمطلق خطا برای طبقات مختلف فشار خون

| فشار خون بالا سطح ۳ | فشار خون بالا سطح ۲ | فشار خون بالا سطح ۱ | پیش فشار خون | نرمال | فشار خون پایین | MAE (mmHg) | SRP |
|---------------------|---------------------|---------------------|--------------|---------|----------------|------------|-----|
| ۱۰/۱۲ | ۵/۶۳ | ۴/۶۸ | ۳/۷۴ | ۳/۶۱ | ۵/۶۷ | | |
| ۷۸۸۴۷ | ۲۱۷۶۷۹ | ۵۳۱۰۰۲ | ۱۰۱۲۰۸۲ | ۱۳۵۲۲۷۹ | ۱۸۱۵۱۱ | #Samples | |
| ۲۸/۷۰ | ۱۷/۸۸ | ۷/۷۸ | ۴/۳۳ | ۲/۵۲ | ۲/۲۴ | MAE (mmHg) | DRP |
| ۱۸۴۳ | ۶۹۰۶ | ۲۸۸۴۲ | ۹۴۲۰۳ | ۹۷۱۳۱۳ | ۲۲۷۰۲۹۳ | #Samples | |



شکل (۱۱) - نمودار جعبه‌ای مقادیر فشار خون سیستولیک و دیاستولیک تخمین زده شده و مرجع در ۶ کلاس

پیچیدگی مدل یادگیری عمیق را به میزان $2/8$ برابر کاهش داده است. هم‌چنین در این پژوهش یک تحلیل زمانی نیز صورت گرفته است که نشان می‌دهد تخمین فشار خون سیستولیک و دیاستولیک به طور هم‌زمان با استفاده از مدل پیشنهادی حدود ۲۰ میلی‌ثانیه طول می‌کشد.

۳-۵- مقایسه با استانداردهای بین‌المللی

۳-۵-۱- استاندارد AAMI

مطابق جدول (۵) شبکه‌ی عصبی عمیق پیشنهادی برای هر دو فشار خون سیستولیک و دیاستولیک الزامات استاندارد AAMI را برآورده کرده است [۲۹].

۳-۴- آنالیز پیچیدگی مدل یادگیری عمیق

الگوریتم‌های یادگیری عمیق به دلیل تعداد زیاد عملیات ضرب و جمع در آن‌ها، به هنگام پیاده‌سازی روی پلتفرم‌های دارای منابع محدود مانند تلفن همراه، مصرف انرژی بالایی داشته و حافظه‌ی زیادی را اشغال می‌کنند. در این راستا به منظور کاهش پیچیدگی مدل CNN-BiLSTM پیشنهادی، کاهش نمونه‌برداری با ضریب ۴ روی داده‌های ورودی صورت گرفته است. پیش از اعمال کاهش نمونه‌برداری، تعداد کل پارامترهای وزن برابر با $7/1$ میلیون بوده که با انجام فرایند کاهش نمونه‌برداری تعداد پارامترهای وزن به $2/4$ میلیون کاهش پیدا کرده است. به این ترتیب کاهش نمونه‌برداری با ضریب ۴



افراد کم و سالم و بازه‌ی فشار خون کوچک باعث حاصل شدن خطای پایین برای روش آن‌ها شده است. در تحقیقات [۹] و [۱۴] علاوه بر این که بازه‌ی فشار خون متفاوتی با تحقیق حاضر در نظر گرفته شده، مدل‌های پیشنهادی آن‌ها نیز متفاوت است و نمی‌توان مقایسه‌ی منصفانه‌ای انجام داد. در دو تحقیق [۱۲] و [۱۴] نیز مرجع فشار خون کاف مورد استفاده قرار گرفته است که نسبت به فشار خون شریانی خطا دارد. در تحقیق [۲۰] مشابه روش پیشنهادی در این پژوهش، با ارائه‌ی یک مدل شخصی‌سازی شده نتایج خوبی به دست آمده است اما بازه‌ی فشار خون کوچک‌تری نسبت به تحقیق حاضر دارد. مدل پیشنهادی این مقاله نسبت به سایر مطالعات بررسی شده در این تحقیق، روی محدوده‌ی فشار خون بزرگ‌تری (خصوصاً برای فشار خون سیستولیک) آموزش داده شده و با این وجود نتایج خوبی را به دست آورده است. بنابراین مقایسه‌ی خطای این مدل با سایر مطالعات منصفانه نیست.

جدول (۵) - تطبیق نتایج پژوهش با الزامات استاندارد AAMI

| افراد | SD (mmHg) | ME (mmHg) | الزامات استاندارد AAMI |
|-------|-----------|-----------|------------------------|
| >۸۵ | <۸ | <۵ | الزامات استاندارد AAMI |
| ۱۰۰ | ۷/۳۸ | ۰/۱۴ | فشار خون سیستولیک |
| ۱۰۰ | ۴/۶۷ | ۰/۰۰ | فشار خون دیاستولیک |

۳-۵-۲- استاندارد BHS

استاندارد BHS عمل کرد مدل را بر حسب درصد تجمعی خطا درجه‌بندی کرده که در جدول (۶) نشان داده شده است [۳۰]. مدل CNN-BiLSTM ارائه شده در این پژوهش درجه‌ی A استاندارد BHS را برای هر دو فشار خون سیستولیک و دیاستولیک به دست آورده است.

جدول (۶) - تطبیق نتایج پژوهش با الزامات استاندارد BHS

| درصد تجمعی خطا | <۵ mmHg | <۱۰ mmHg | <۱۵ mmHg |
|--------------------|---------|----------|----------|
| درجه‌ی A | ٪۶۰ | ٪۸۵ | ٪۹۵ |
| درجه‌ی B | ٪۵۰ | ٪۷۵ | ٪۹۰ |
| درجه‌ی C | ٪۴۰ | ٪۶۵ | ٪۸۵ |
| فشار خون سیستولیک | ٪۷۵/۳۱ | ٪۹۰/۸۰ | ٪۹۵/۵۲ |
| فشار خون دیاستولیک | ٪۸۸/۲۸ | ٪۹۶/۱۷ | ٪۹۸/۱۸ |

۳-۵-۳- استاندارد IEEE 1708a

استاندارد IEEE 1708-2019 عمل کرد دستگاه‌های پوشیدنی و بدون کاف فشار خون را بر اساس میانگین قدرمطلق اختلاف مقادیر تخمین زده شده و مرجع^۱ مطابق جدول (۷) درجه‌بندی می‌کند [۲۷]. روش پیشنهادی در این پژوهش درجه‌ی A استاندارد IEEE 1708a را برای هر دو فشار خون سیستولیک (MAD=۴/۲۱ میلی‌مترجیوه) و دیاستولیک (MAD=۲/۴۷ میلی‌مترجیوه) دریافت کرده است.

۳-۶- مقایسه با سایر مطالعات

در جدول (۸) نتایج روش پیشنهادی با مطالعات پیشین مقایسه شده است. در مطالعات [۷] و [۸] از دو سیگنال PPG برای آموزش شبکه‌ی عصبی استفاده شده که پیچیدگی مدل و بار محاسباتی را افزایش داده است. در مقالات [۸] و [۱۲] تعداد

جدول (۷) - تطبیق نتایج پژوهش با الزامات استاندارد IEEE-1708a

| MAD (mmHg) | ANSI/AAMI SP10 | BHS | سطح پیشنهادی |
|------------|--------------------------|---------------------------------------|------------------|
| ≤۴ | pass | Grade A | A |
| ۴-۵ | mostly pass | بیش‌تر A کم‌تر B | A |
| ۵-۶ | pass or fail | بیش‌تر B کم‌تر A بسیار کم C و D | B |
| ۶-۷ | mostly fail less pass | بیش‌تر C کم‌تر B و D | C |
| ≥۷ | fail | بدتر از C | D (unacceptable) |

۴- نتیجه‌گیری

در این پژوهش یک چارچوب یادگیری عمیق CNN-BiLSTM برای تخمین هم‌زمان فشار خون سیستولیک و دیاستولیک از یک سیگنال PPG پیشنهاد شده است. با توجه به مورفولوژی اختصاصی سیگنال PPG برای هر فرد، در روش پیشنهادی از یادگیری انتقالی برای ایجاد مدل شخصی‌سازی شده برای هر فرد استفاده شده است. از آن‌جا که شکل موج سیگنال PPG تحت تاثیر نویز و آرتیفکت‌های حرکتی و یا در اثر بیماری‌های مختلف تغییر می‌کند، استخراج ویژگی‌های دستی از آن دشوار است. روش پیشنهادی این مقاله بدون نیاز به استخراج ویژگی‌های دستی، دقت بالایی را در تخمین فشار خون به دست

^۱ Mean Absolute Difference (MAD)

عمیق پیشنهادی در بازه‌ی وسیعی از فشار خون آموزش داده شده است به طوری که در بازه‌ی فشار خونی که بیماران در حین دیالیز آن را تجربه می‌کنند دقت بالایی داشته و می‌تواند در واحد دیالیز نیز کاربرد داشته باشد.

آورده و استانداردهای بین‌المللی را برآورده کرده است. همچنین کاهش پیچیدگی مدل یادگیری عمیق با روش کاهش نمونه‌برداری انجام شده است که استقرار روی پلتفرم‌های دارای منابع محدود هم‌چون تلفن همراه را امکان‌پذیر می‌کند. مدل

جدول (۸) - مقایسه‌ی نتایج این پژوهش با سایر مطالعات

| فشار خون دیاستولیک (mmHg) | | | فشار خون سیستولیک (mmHg) | | | بازه‌ی فشار خون | تعداد افراد | کالیبراسیون | سیگنال ورودی (نام دیتاست) | روش |
|---------------------------|------|------|--------------------------|-------|------|----------------------------------|--------------|-------------|--|------------------------------|
| ME | STD | MAE | ME | STD | MAE | | | | | |
| - | - | - | ۸/۳۸ | ۴/۲۳ | - | ۱۰۰ < SBP < ۱۴۰ | ۸ نرمال | | | Regression Equation [۷] |
| - | - | - | ۱۰/۶۸ | ۴/۱۷ | - | ۷۰ < SBP < ۱۴۰ | ۸ همودیالیز | بلی | Dual PPG | |
| ۰/۱۵ | ۲/۳ | - | ۰/۱۱ | ۱/۱۸ | - | ۹۰ < SBP < ۱۴۰ ۵۰ < DBP < ۱۱۰ | ۲۰ سالم | خیر | Dual PPG | GRNN [۸] |
| -۱/۲۵ | ۵/۶۵ | ۲/۳۰ | ۱/۵۵ | ۵/۴۱ | ۳/۹۷ | ۸۰ < SBP < ۱۸۰ ۶۰ < DBP < ۱۳۰ | ۱۵۵۷ بیمار | خیر | Single PPG (MIMIC-II) | CNN-LSTM [۹] |
| ۰/۰۰ | ۳/۶۱ | ۲/۷۳ | -۰/۰۷ | ۴/۴۷ | ۳/۲۳ | ۹۸ < SBP < ۱۸۴ ۶۳ < DBP < ۱۰۷ | ۳۳ سالم | خیر | Single PPG | ANN [۱۲] |
| -۰/۳۱ | ۴/۸۹ | ۳/۳۲ | -۴/۰۲ | ۱۰/۴۰ | ۷/۴۱ | - | ۲۲۵+۳۰ بیمار | خیر | Single PPG (MIMIC-II + UQ Vital Signs) | Feedforward Deep NN-ANN [۱۶] |
| ۰/۶۷ | ۲/۸۴ | - | ۱/۹۱ | ۵/۵۵ | - | ۸۰ < SBP < ۲۰۰ ۵۰ < DBP < ۱۱۰ | ۲۰۰ بیمار | بلی | Single PPG + ECG for segmentation (MIMIC-II) | CNN-LSTM [۱۸] |
| ۰/۱۸ | ۴/۱۷ | ۲/۴۳ | -۰/۰۵ | ۸/۹۰ | ۳/۹۷ | ۷۶ < SBP < ۲۰۰ ۵۰ < DBP < ۱۱۷ | ۴۴۱ بیمار | خیر | Single PPG (MIMIC-II) | Adaboost [۱۷] |
| -۰/۳۸ | ۶/۳۶ | - | ۰/۱۷ | ۴/۷۳ | - | ۸۰ < SBP < ۲۰۰ ۴۰ < DBP < ۱۴۰ | ۴۳۵ بیمار | بلی | Single PPG | Exponential GPR [۱۴] |
| ۰/۰۵ | ۲/۸۲ | ۲/۲۴ | ۰/۱۱ | ۴/۵۶ | ۳/۸۴ | ۸۰ < SBP < ۱۸۰ ۳۰ < DBP < ۱۱۰ | ۱۰۰ بیمار | بلی | Single PPG (MIMIC-III) | CNN-GRU-Transfer [۲۰] |
| ۰/۰۰ | ۴/۶۷ | ۲/۴۷ | ۰/۱۴ | ۷/۳۸ | ۴/۲۱ | ۵۰ < SBP < ۲۳۰ ۱۵ < DBP < ۱۱۵ | ۱۰۰ بیمار | بلی | Single PPG (MIMIC-III) | تحقیق حاضر |

- [4] V. Figini, S. Galici, D. Russo, I. Centoze, M. Visintin and G. Pagana, "Improving Cuff-Less Continuous Blood Pressure Estimation with Linear Regression Analysis", electronics, vol. 11, no. 9, 2022.
- [5] N. Maher, G. A. Elshikh et al. "Non-invasive Calibration-Free Blood Pressure Estimation Based on Artificial Neural Network", International Conference on Advanced Machine Learning Technologies and Applications (AMLTA2019), vol. 921, pp. 701-711, 2020.
- [6] M. Kachuee et al. "Cuff-less High-accuracy Calibration-free Blood Pressure Estimation Using Pulse Transit Time", 2015 IEEE International Symposium on Circuits and Systems (ISCAS), Lisbon, pp. 1006-1009, 2015, doi: 10.1109/ISCAS.2015.7168806.

۵- مراجع

- [1] H. W. Loh, Sh. Xu, O. Faust, Ch. P. Ooi et al. "Application of Photoplethysmography Signals for Healthcare Systems: An In-depth Review", Computer Methods and Programs in Biomedicine, vol. 216, 2022.
- [2] Sh. Yin, G. Li, Y. Luo and L. Lin, "Cuff-less Continuous Blood Pressure Measurement Based on Multiple Types of Information Fusion", Biomedical Signal Processing and Control, vol. 68, 2021.
- [3] M. A. Younessi Heravi, K. Maghooli, S. Joharina, "A New Approach for Blood Pressure Monitoring based on ECG and PPG Signals by using Artificial Neural Networks", International Journal of Computer Applications, vol. 103, pp. 36-40, 2014.

دیاستولیک بر اساس سیگنال‌های ECG و PPG»، پایان‌نامه کارشناسی ارشد، دانشگاه صنعتی امیرکبیر، تهران، ۱۳۹۸.

- [20] J. Leitner, P. H. Chiang et al. "Personalized Blood Pressure Estimation Using Photoplethysmography: A Transfer Learning Approach," *IEEE Journal of Biomedical and Health Informatics*, vol. 26, 2022.
- [21] S. J. Pan and Q. Yang, "A Survey on Transfer Learning", *IEEE Transactions on Knowledge and data*, vol. 22, pp. 1345-1359, 2010.
- [۲۲] م. قنواتی، س. ف. مولایی زاده، م. نویدی، «یک روش شخصی‌سازی شده برای تخمین فشار خون 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] A. E. W. Johnson et al., MIMIC-III, a freely accessible critical care database. *Sci. Data* 3:160035 doi: 10.1038/sdata.2016.35 (2016).
- [24] Y. Liang, M. Elgendi et al. "Analysis: An optimal filter for short photoplethysmogram signals", *Scientific Data*, vol. 5, no. 1, pp. 1-12, 2018.
- [25] M. Panwar, D. Biswas et al. "Rehab-Net: Deep Learning Framework for Arm Movement Classification Using Wearable Sensors for Stroke Rehabilitation", *IEEE Transactions on Biomedical Engineering*, vol. 66, no. 11, pp. 3026-3037.
- [26] D. G. Altman and J. M. Bland, "Measurement in Medicine: The Analysis of Method Comparison Studies", *Royal Statistical Society: Series D (The Statistician)*, vol. 32, pp. 307-317, 1983.
- [27] "IEEE Standard for Wearable, Cuffless Blood Pressure Measuring Devices - Amendment 1", in *IEEE Std 1708a-2019 (Amendment to IEEE Std 1708-2014)*, pp.1-35, 4 Oct. 2019, doi: 10.1109/IEEESTD.2019.8859685.
- [28] Free Printable Medical Forms, "Blood pressure range chart", Blood pressure range chart. [Online]. Available: <https://isipaper.org/post/sbk-rfrns-noisi-ai-tripl-ai-ieeeebyc>.
- [29] E. O'Brien, Th. Pickering et al. "Working Group on BP Monitoring of the ESH International Protocol for Validation of BP Measuring Devices in Adults", *Blood pressure monitoring*, vol. 7, pp. 3-17, 2002.
- [30] E. O'Brien, J. Petrie, W. Littler et al. "The British Hypertension Society Protocol for the Evaluation of Automated and Semi-automated Blood Pressure Measuring Devices with Special Reference to Ambulatory Systems," *Hypertension*, vol. 8, pp. 607-619, 1990.

- [7] M. A. Younessi Heravi, E. Golmakani and Sima Joharinia, "A New Approach for Detecting Sudden Hypotension in Hemodialysis by Using Dual-channel Optical System", *Innovative Optical Health Sciences*, vol. 10, pp. 1-9, 2016.
- [۸] م. شهابی، و. نفیسی، «تخمین بدون کاف فشار خون مبتنی بر ویژگی‌های زمانی سیگنال نبض»، پردازش علائم و داده‌ها، صفحه ۱۱۳-۱۰۳، ۱۳۹۷.
- [9] M. Panwar et al. "PP-Net: A Deep Learning Framework for PPG-Based Blood Pressure and Heart Rate Estimation", *IEEE Sensors*, vol. 20, no. 17, pp. 10000 - 10011, 2020.
- [10] A. Gaurav et al. "Cuff-less PPG based continuous blood pressure monitoring — A smartphone based approach", 38th annual international conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Orlando, pp. 607-610, 2016, doi: 10.1109/EMBC.2016.7590775.
- [11] G. Slapničar, N. Malkar et al. "Blood Pressure Estimation from Photoplethysmogram Using a Spectro-Temporal Deep Neural Network", *Sensors*, vol. 19, no. 15, p. 3420, 2019.
- [12] P. Yao et al. "Multi-Dimensional Feature Combination Method for Continuous Blood Pressure Measurement Based on Wrist PPG Sensor", *Biomedical and Health Informatics*, vol. 26, no. 8, pp. 3708-3719, 2022.
- [13] Y. Kurylyak, "A Neural Network-based Method for Continuous Blood Pressure Estimation from a PPG Signal", in 2013 IEEE International instrumentation and measurement technology conference (I2MTC), Calabria, 2013.
- [14] J. W. Chen et al. "A Data-Driven Model with Feedback Calibration Embedded Blood Pressure Estimator Using Reflective Photoplethysmography", *Sensors*, vol. 22, 2022, doi: <https://doi.org/10.3390/s22051873>.
- [15] C. El-Hajj and P.A Kyriaco, "Cuffless blood pressure estimation from PPG signals and its derivatives using deep learning models", *Biomedical Signal Processing and Control*, vol. 70, 2021.
- [16] H. Samimi and H. R. Dajani, "A PPG-Based Calibration-Free Cuffless Blood Pressure Estimation Method Using Cardiovascular Dynamics", *Sensors*, vol.23,no.8, pp.1-22, 2023.
- [17] S. S. Mousavi et al. "Blood Pressure Estimation from Appropriate and Inappropriate PPG Signals using A Whole-based Method," *Biomedical Signal Processing and Control*, vol. 47, pp. 196-206, 2020.
- [18] J. Esmalpoor et al. "A multistage deep neural network model for blood pressure estimation using photoplethysmogram signals", *Computers in Biology and Medicine*, vol. 120, 2020.
- [۱۹] ج. اسماعیل پور، م. ح. مرادی، «بهبود تخمین ضربان به ضربان فشار خون‌های سیستمیک و