



Optimal adjustment of deep neural network parameters in Estimation of Missing Data of Vital Signs in Wireless Body Area Networks

Aboulfazel Ebrahimi¹✉, Mahboubeh Shamsi² and Morteza Mohajjel³

1. Corresponding author, MSC. Department of computer engineering, Faculty of Electrical and Computer Engineering, Qom University of technology. Email: ebrahimi.a@qut.ac.ir
2. Assistance professor, Department of computer engineering, Faculty of Electrical and Computer Engineering, Qom University of technology. Email: shamsi@qut.ac.ir
3. Assistance professor, Department of computer engineering, Faculty of Electrical and Computer Engineering, Qom University of technology. Email: mohajjel@qut.ac.ir

Article Info	ABSTRACT
<p>Article type: Research Article</p> <p>Article history: Received 2023 April 6 Received in revised form 2023 May 29 Accepted 2023 June 5 Published online 2023 September 16</p> <p>Keywords: Artificial Neural Network, Deep Learning, Estimation, Missing Data WBAN.</p>	<p>In a wireless sensor network (WSN), due to various factors such as limited power, sensor transferability, hardware failure and network problems such as packet collisions, unreliable connection and unexpected damage, the amount sensed to the header or base station is not Arrives. Therefore, data loss is very common in wireless sensor networks. Loss of measured data greatly reduces WBAN accuracy. Because WBAN deals with the vital signs of the human body, network reliability is very important. To solve this problem, missing data must be estimated. In order to predict the missing values, a model for estimating lost data based on LSTM (short-term memory) neural network is presented in this paper. This model combines five vital signs as input to predict the amount lost. The results show that sgd-LSTM is a good way to estimate the amount lost. In addition, experimental results show that the mean square root error of the estimated value is lower than other methods. This value is 4.1495 with the best network parameters.</p>


Cite this article: Ebrahimi, A., Shamsi, M. & Mohajjel, M. (2023). Optimal adjustment of deep neural network parameters in Estimation of Missing Data of Vital Signs in Wireless Body Area Networks. *Engineering Management and Soft Computing*, 9 (1). 162-188. DOI: <https://doi.org/10.22091/JEMSC.2022.7422.1162>



© The Author(s)
DOI: <https://doi.org/10.22091/JEMSC.2022.7422.1162>

Publisher: University of Qom

تنظیم بهینه پارامترهای شبکه عصبی عمیق در برآورد داده‌های ازدست‌رفته علائم حیاتی در شبکه‌های حسگر بی‌سیم بدن

ابوالفضل ابراهیمی^۱✉، محبوبه شمسی^۲، و مرتضی محجل^۳ 

۱. کارشناس ارشد، گروه مهندسی کامپیوتر، دانشکده برق و کامپیوتر، دانشگاه صنعتی قم، قم، ایران. رایانامه: ebrahimi.a@qut.ac.ir
۲. استادیار، گروه مهندسی کامپیوتر، دانشکده برق و کامپیوتر، دانشگاه صنعتی قم، قم، ایران. رایانامه: shamsi@qut.ac.ir
۳. استادیار، گروه مهندسی کامپیوتر، دانشکده برق و کامپیوتر، دانشگاه صنعتی قم، قم، ایران. رایانامه: mohajjel@qut.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	در شبکه‌های حسگر بی‌سیم به دلیل عوامل مختلفی از قبیل انرژی محدود، قابلیت انتقال سنسورها، خرابی سخت‌افزار و مشکلات شبکه‌مانند برخورد بسته‌ها، پیوند غیرقابل اطمینان و آسیب‌های غیرمنتظره، مقدار حس شده به سرخوشه یا ایستگاه پایه نمی‌رسد. بنابراین از بین رفتن داده‌ها در شبکه‌های حسگر بی‌سیم بسیار متداول است. از دست دادن داده‌های سنجیده‌شده، دقت WBAN را بسیار کاهش می‌دهد. برای حل این مشکل، داده‌های گم‌شده باید برآورد شوند. به منظور پیش‌بینی مقادیر گم‌شده، یک مدل برآورد داده ازدست‌رفته براساس شبکه عصبی LSTM (حافظه کوتاه‌مدت) در این مقاله ارائه شده‌است. این مدل پنج علامت حیاتی را به‌عنوان ورودی برای پیش‌بینی مقدار ازدست‌رفته ترکیب می‌کند. نتایج نشان می‌دهد که sgdm-LSTM روش خوبی برای برآورد مقدار ازدست‌رفته است. در ضمن نتایج تجربی نشان می‌دهد که میانگین خطای مربع ریشه مقدار برآورد شده کمتر از سایر روش‌هاست. این مقدار، با بهترین ابرپارامترهای شبکه ۴/۱۴۹۵ است.
تاریخ دریافت: ۱۴۰۲/۰۱/۱۷	
تاریخ بازنگری: ۱۴۰۲/۰۳/۰۸	
تاریخ پذیرش: ۱۴۰۲/۰۳/۱۵	
تاریخ انتشار: ۱۴۰۲/۰۶/۲۵	
کلیدواژه‌ها: برآورد، داده ازدست‌رفته، شبکه حسگر بی‌سیم بدن، شبکه عصبی مصنوعی، یادگیری عمیق.	

استناد: ابراهیمی، ابوالفضل، شمسی، محبوبه و محجل، مرتضی. (۱۴۰۲). «تنظیم بهینه پارامترهای شبکه عصبی عمیق در برآورد داده‌های ازدست‌رفته علائم حیاتی در شبکه‌های حسگر بی‌سیم بدن». *مدیریت مهندسی و رایانش نرم، دوره ۹ (۱)*. صص: ۱۸۸-۱۶۲. <https://doi.org/10.22091/JEMSC.2022.7422.1162>



۱) مقدمه

متأسفانه بیماری‌های مزمن و کشنده مانند سرطان و بیماری‌های قلبی عروقی و آسم اغلب دیر تشخیص داده می‌شوند. در نتیجه، این موضوع میزان مرگ و میر افرادی را که به چنین بیماری‌هایی مبتلا هستند، افزایش می‌دهد. تشخیص زودرس، اثر اینگونه بیماری‌ها را کاهش می‌دهد و امید به زندگی افراد مبتلا را افزایش می‌دهد. عدم تشخیص زودرس و نظارت مؤثر بر بیماری‌ها، هزینه‌های مراقبت‌های بهداشتی را افزایش می‌دهد و بار زیادی به سیستم‌های مراقبت‌های بهداشتی با منابع مالی محدود می‌افزاید. علاوه بر این، سیستم‌های سنتی نظارت، تصویر کاملی از وضعیت یک بیمار ارائه نمی‌دهند زیرا عملکردهای بدن خیلی کم کنترل می‌شود. این امر به دنبال سیستم‌های مقرون به صرفه‌تر و مقیاس پذیرتری است که بتوانند مراقبت‌های بهداشتی فعلی را در راستای تشخیص زودهنگام بیماری و مدیریت سلامتی فعال انجام دهند.

فناوری‌های بی‌سیم، از جمله WSN و شبکه‌های بی‌سیم منطقه شخصی (WPAN)، فناوری نانو و اینترنت، وسیله‌ای را فراهم می‌کند که از طریق آن میتوان راه‌حل‌های اقتصادی برای سیستم‌های مراقبت‌های بهداشتی یافت. چنین فناوری‌هایی، ایده استفاده از ریزسنسورهای هوشمند با توان مصرفی پایین، میکروسنسورها و حسگرها را برای نمونه برداری از داده‌های فیزیولوژیکی و سپس انتقال آن به سرور از راه دور از طریق ارتباط بی‌سیم پیشنهاد می‌کنند. انقلاب شبکه‌های سنسورهای بی‌سیم (WSN) با ساختن فناوری قابل پوشیدن یا حتی کاشت در بدن انسان جهت خود را به سمت فناوری متناسب با تحرک انسانی سوق داد. این فناوری با گره‌های حسگر کم‌هزینه، محدودکننده انرژی، ریز و ناهمگن شناخته می‌شود که نوع خاصی از WSN، یعنی شبکه بی‌سیم بدن (WBAN) را تشکیل می‌دهد. WBAN با تشخیص به موقع موقعیت‌های غیرطبیعی از طریق دستگاه‌های مانیتور پوشیدنی و کاشته شده، زندگی افراد را نجات می‌دهد. این امر اجازه می‌دهد تا نظارت مداوم و در زمان واقعی و بدون مداخله انسانی انجام شود که باعث بهبود کیفیت نتایج به دست آمده می‌شود. علاوه بر این، WBAN به بیماران امکان می‌دهد فعالیت‌های عادی خود را بدون وقفه انجام دهند درحالی‌که سیگنال‌های حیاتی آنها مورد بررسی قرار می‌گیرد زیرا دیگر نیازی به ماندن در بیمارستان یا مراجعه به خدمات پزشکی نیست. تصویب WBAN باید هزینه‌های مراقبت‌های بهداشتی را با به حداقل رساندن نیاز به مراقبت‌های گران‌قیمت در مراقبت‌های بیمارستانی کاهش دهد. مهمتر از همه، داده‌های ارائه شده توسط WBAN به پزشکان دید بهتری از وضعیت یک بیمار می‌دهد زیرا این داده‌ها در طی فعالیت‌های عادی یک بیمار در محیط طبیعی خود جمع‌آوری می‌شود.

WBAN باید قابل اعتماد باشد زیرا هر عیب و نقصی می‌تواند تهدیدکننده زندگی برای شخص وابسته به این فناوری باشد. یکی از الزامات یک سیستم قابل اعتماد این است که باید تحمل پذیر در برابر خطا باشد. یعنی اگر یک خطا بدون در نظر گرفتن نوع یا ماهیت خطا رخ دهد، باید توانایی بهبودی خود را داشته باشد. با توجه به حساسیت و اهمیت داده‌های حمل شده و مورد استفاده WBAN، تحمل خطا یک مسئله مهم است. با وجود مطالعات تحقیقاتی مداوم که در WBAN با موضوعات فنی مقابله می‌کند، مانند انرژی، تحرک، امنیت، مسیریابی و طراحی سنسور، با این حال؛ تشخیص خطا و بازگشت در WBAN‌ها هنوز در مراحل ابتدایی خود است.

۲) پیشینه پژوهش

روش‌های بسیاری برای بازسازی داده‌های سنسور ازدست‌رفته براساس همبستگی زمانی، همبستگی مکانی، روش درون‌یابی یا نظریه پراکنده استفاده می‌شود. با توجه به ویژگی‌های داده‌های علائم حیاتی، می‌توان آنها را به‌عنوان یک سری اطلاعات متوالی در نظر گرفت. تاکنون روش‌های مختلفی برای برآورد داده‌های ازدست‌رفته در داده‌های سری زمانی زمینه‌های مختلف، توسعه یافته‌است. این روش‌ها را می‌توان به دو دسته تقسیم کرد: روش‌های آماری و روش‌های مبتنی بر یادگیری ماشین.

نویسندگان [۲] یک الگوریتم برآورد داده ازدست‌رفته در شبکه WSN با استفاده از الگوریتم k نزدیکترین همسایه، براساس همبستگی فضایی-زمانی داده‌های سنسور پیشنهاد دادند. آنها از مدل رگرسیون خطی، برای توصیف همبستگی فضایی داده‌های سنسور در گره‌های حسگر مختلف و از اطلاعات داده گره‌های مختلف همسایه برای برآورد داده‌های ازدست‌رفته به‌طور مشترک به‌جای مستقل استفاده می‌کنند. از آنجا که روش پیشنهادی مبتنی بر همبستگی مکانی داده‌های حسگر برای تخمین داده‌های ازدست‌رفته و مدل خطی توسط الگوریتم اتخاذ شده‌است، هنگامی که داده‌های حسگر گره‌های مختلف کاملاً خطی باشد، بهترین عملکرد را خواهد داشت.

یکی از محاسن الگوریتم پیشنهادشده در این مقاله، عملکرد خوب برای داده‌ها در داخل و خارج از منزل می‌باشد و مشکل الگوریتم یادشده وابستگی به تعداد نود همسایه و تعداد مقادیر ازدست‌رفته است. همچنین همبستگی داده‌های حسگر ممکن است گاهی اوقات خطی نباشد. مدل خطی می‌تواند در یک بازه زمانی کوتاه همبستگی داده واقعی را به‌خوبی تخمین بزند و از این رو وقتی اندازه نمونه زیاد نباشد، عملکرد خوبی خواهد داشت حتی اگر داده‌های سنسور به‌طور صحیح به‌صورت خطی نباشد.

نویسندگان [۱] الگوریتم برآورد داده‌های ازدست‌رفته حسگرها براساس همبستگی فضایی و زمانی ارائه کردند. این الگوریتم اطلاعات مربوطه را به‌عنوان نمونه تجزیه و تحلیل انتخاب می‌کند و تضمین می‌کند که هیچ نمونه‌ای از داده‌های بیش از حد وجود نداشته باشد و نمونه قوی‌ترین ارتباط را با داده‌های گم‌شده داشته باشد. در مرحله اول، تمام داده‌های سنجش شده همزمان با یک سری زمانی را ذخیره می‌کند و مرتبط‌ترین سری‌ها به‌عنوان نمونه تجزیه و تحلیل انتخاب می‌شوند که به‌طور قابل توجهی کارایی و دقت الگوریتم را بهبود می‌بخشد. ثانیاً مقادیر ازدست‌رفته را از ابعاد زمانی و مکانی تخمین می‌زند. وزن‌های مختلفی به این دو بعد اختصاص داده شده‌است. الگوریتم یادشده رابطه بین صفات را در نظر نگرفته‌است. نویسندگان [۳] از فرآیندهای گاوسی یادگیری ماشین برای پیش‌بینی داده‌های ازدست‌رفته در شبکه حسگرهای بی‌سیم بدن، استفاده کردند. الگوریتم انتخاب‌شده برای مدل‌سازی و پیش‌بینی، الگوریتم N4SID مبتنی بر فضای حالت است. این الگوریتم در صورت تنظیم دقیق پارامترهای یادگیری ماشین دقت بالایی ارائه می‌دهد.

نویسندگان [۴] روشی با تحلیل پویای فاکتور فراموشی متغیر برای شبکه‌های حسگر بی‌سیم با داده‌های گم‌شده به‌صورت بازگشتی ارائه دادند. با تجزیه اندازه‌گیری‌های WSN به بارهای فاکتور متعامد و فاکتورهای همبستگی از ساختار همبستگی افزونگی در بین اندازه‌گیری‌های WSN استفاده می‌کنند. یک فاکتور فراموشی متغیر مبتنی بر مدل چندجمله‌ای محلی (LPM) برای الگوریتم RDFA ارائه شده‌است و ما را قادر می‌سازد تا با محیط متغیر با زمان سازگاری بهتری داشته

باشیم. روش آنها نسبت به روش k نزدیکترین همسایه به حذف نمونه‌ها مقاومتر است. اما مشکل آن پیچیدگی بالای زمانی در محاسبه مقدار داده ازدست‌رفته می‌باشد.

نویسندگان [۶] با توجه به اینکه داده‌های جمع‌آوری شده توسط گره‌های حسگر به دلیل استفاده از توپولوژی استقرار شبکه حسگر بی‌سیم، از لحاظ مکانی و زمانی باهم ارتباط دارند، پیش‌بینی ارزش‌های گم‌شده در شبکه حسگر بی‌سیم با استفاده از همبستگی فضایی و زمانی را ارائه دادند که نسبت به متد خطی و knn دقت بالاتری دارد. اما دقت وابسته به تعداد نودهای همسایه است. پس از استقرار گره‌های حسگر، تشکیل خوشه صورت می‌گیرد که منجر به ایجاد خوشه‌هایی از آن گره‌های حسگر می‌شود که از لحاظ زمانی و مکانی باهم ارتباط دارند. بعد از تشکیل خوشه، گره‌های حسگر داده‌ها را حس می‌کنند و آنها را به سرخوشه می‌فرستند. سرخوشه داده‌های سنجش شده را جمع‌آوری کرده، پردازش کرده و برای گره سینک می‌فرستد. اگر سرخوشه، از دست دادن داده‌های هر یک از اعضای خود را شناسایی کند سپس سرخوشه از PSTC برای پیش‌بینی مقدار ازدست‌رفته استفاده می‌کند.

نویسندگان [۵] از روش هموارسازی نمایی مرتبه دوم و آنالیز رگرسیون خطی برای پیش‌بینی داده‌های ازدست‌رفته در شبکه حسگرهای بی‌سیم استفاده کردند. به این صورت که الگوریتم از روش هموارسازی نمایی مرتبه دوم برای تخمین داده‌های گم‌شده در ابعاد زمانی و از آنالیز رگرسیون خطی چندگانه برای تخمین ارزش‌های گم‌شده در فضا استفاده می‌کند. پیچیدگی زمانی الگوریتم کم و دقت پیش‌بینی بالاست. اما نیازمند داده‌های نسبتاً دقیق به عنوان پایه می‌باشد. در مقایسه با الگوریتم‌های تخمین داده‌های ازدست‌رفته سنتی، این الگوریتم نه تنها ویژگی‌های شبکه‌های حسگر بی‌سیم را در نظر می‌گیرد، بلکه می‌تواند داده‌های ازدست‌رفته را در زمان واقعی پردازش کند. به منظور برآورد داده‌های ازدست‌رفته، دو الگوریتم با وزن‌های مختلف ادغام می‌شوند. بردار وزنی با کمترین جمع مربعات خطاها به دست می‌آید و سپس نتیجه برآورد نهایی به دست می‌آید. انتخاب ضریب وزن به‌طور مستقیم دقت نتایج را تعیین می‌کند. بنابراین باید وزن بالاتری به برآورد دقیق‌تر اختصاص داده شود. در این مقاله، از ضریب همبستگی پیرسون برای یافتن ارتباط بین گره‌ها استفاده می‌کنیم. پس از به دست آوردن ضریب همبستگی، ضریب رگرسیون با استفاده از روش حداقل مربعات به دست می‌آید. این الگوریتم خصوصیات مختلف داده‌های ادراکی را نه تنها برای همبستگی فضایی بلکه در سری زمانی برای تخمین داده‌های ازدست‌رفته در نظر می‌گیرد تا بتواند برآوردی را پیدا کند که مجموع مربعات خطاها را به حداقل برساند. نویسندگان [۷] روش یادگیری فرهنگ لغت انطباقی به روز را برای بازسازی اطلاعات گم‌شده در شبکه حسگرهای بی‌سیم را ارائه کردند که نیاز به حداقل داده آموزش دارد اما پیچیدگی محاسباتی زیادی دارد.

الگوریتم K-SVD برای آموزش فریم داده‌های تاریخی است که در زمان‌های مختلف برای تولید اتم‌های فرهنگ لغت اصلی جمع‌آوری می‌شود. علاوه بر این، به منظور دستیابی به ویژگی‌های مداوم داده‌های حسگر در زمان واقعی، یک الگوریتم به‌روزرسانی فرهنگ لغت تطبیقی مورد مطالعه قرار گرفته است. این همبستگی بین قاب داده‌های بازسازی شده فعلی و بزرگترین چهارچوب وزن در فرهنگ لغت آموزش برای به‌روزرسانی فرهنگ لغت را محاسبه می‌کند. با ترکیب همبستگی زمانی و تولید فرهنگ لغت پراکنده، از الگوریتم یادگیری فرهنگ لغت مبتنی بر KSVD برای آموزش فریم‌های تاریخی در یک بازه زمانی خاص برای به دست آوردن فرهنگ لغت تابع پایه استفاده می‌شود. سپس برای بازسازی قاب

حسگر فعلی با توجه به اتم‌های فرهنگ لغت و ضرایب پراکنده مربوطه با کدگذاری پراکنده استفاده می‌شود. وقتی از فرهنگ لغت ثابت برای بازسازی فریم‌های داده استفاده می‌شود، خطای بازسازی با افزایش فاصله نمونه‌برداری بزرگتر خواهد شد. بنابراین یک روش به‌روزرسانی فرهنگ لغت تطبیقی برای کاهش خطای بازسازی ارائه شده است که امکان به‌روزرسانی انتخابی اتم‌های فرهنگ لغت وجود دارد. نویسندگان [۸] از کدگذاری شبکه همکاری به‌منظور بازیابی داده‌ها در شبکه حسگرهای بی‌سیم بدن استفاده کردند. آنها با روش پیشنهادی‌اشان با کاهش زمان انتقال مجدد اطلاعات، از تک نقاط شکست جلوگیری می‌کنند. ارتباطات مشترک در WBAN یک راه‌حل منحصر به فرد برای نیازهای عملکردی ارائه می‌دهد. این از حالت پخش کانال‌های ارتباطی بی‌سیم استفاده می‌کند تا گره‌های همسایه (که به آنها رله گفته می‌شود) بتوانند سیگنال منبع در نظر گرفته شده برای یک مقصد خاص را بشنوند، سیگنال را پردازش کرده و به مقصد مورد نظر منتقل کنند. سیگنال‌هایی که از رله‌ها و منبع دریافت می‌شوند در مقصد مورد نظر ترکیب می‌شوند که منجر به کاهش تلفات بسته به دلیل خرابی پیوند یا یک نقطه خرابی می‌شود. ایده اصلی این روش استفاده از ترمینال‌های موجود کاربر به‌عنوان رله‌هایی است که می‌توانند برای افزایش کارایی سیستم همکاری کنند.

ارتباط همکاری با کدگذاری شبکه بر روی به‌حداقل رساندن تعداد انتقال سیگنال‌های یک رله منفرد است. سیگنال‌هایی که در یک رله منفرد دریافت می‌شوند به‌صورت خطی ترکیب شده و در نتیجه فقط یک سیگنال تولید می‌شود و سپس به مقصد منتقل می‌شود. بنابراین هر رله برای ارسال سیگنال خود فقط به یک اسلات زمان نیاز دارد. فرض بر این است که رله‌ها در حالت نیمه‌دوبلکس ارتباط برقرار می‌کنند و بنابراین هیچ گره‌ای قادر به ارسال و دریافت همزمان نیست. در ابتدا گره منبع بسته‌ای را به گره مقصد پخش می‌کند. اگر رله بتواند آن را رمزگشایی کند، یک کپی از بسته نیز در شکاف بعدی ارسال می‌شود. بنابراین سینک یا مقصد، اطلاعات را از دو نسخه بسته دریافت‌شده رمزگشایی می‌کند. در انواع رمزگشایی و طرح‌های ارتباطی مبتنی بر جلو، گره‌های رله باید ابتدا پیام منبع را رمزگشایی کرده و سپس آن را رمزگذاری مجدد کرده و به مقصد منتقل کنند. اما همه این طرح‌ها فقط با تعداد محدودی از گره‌های منبع مفید هستند. با افزایش تعداد گره‌های منبع، گره‌های رله نیاز به پردازش زیادی دارند که انرژی انتقال زیادی را مصرف می‌کند. نویسندگان [۹] با استفاده از شبکه‌های عصبی مصنوعی، داده‌های گم‌شده را تخمین می‌زنند. اما بهره‌وری یادگیری ANN بستگی به مقادیر اولیه پارامترها دارد. داده‌های عادی اصلی با استفاده از پنجره‌های داده تبدیل می‌شوند تا خصوصیات سری زمانی داده‌های ویتترین با ANN را بیاموزند. روند داده‌های سری زمانی با مرور زمان در نوسان است. از این رو، یادگیری ویژگی‌های سری زمانی داده موثرتر از یادگیری تنها یک داده در یک زمان است. شبکه ANN می‌تواند با استفاده از ماتریس ترکیبی تبدیل شده به‌عنوان داده ورودی و داده هدف، مشخصات داده‌ها را با توجه به ویژگی‌های سری زمانی بیاموزد. یک تابع سیگموئید برای سلول‌های عصبی در توابع فعال‌سازی لایه پنهان استفاده می‌شود. خطای میانگین مربع به‌عنوان تابع ازدست‌دادن استفاده می‌شود. ANN پارامترهای مناسب برای تخمین داده‌های ازدست‌رفته ویتترین را با استفاده از داده‌های اندازه پنجره گذشته به‌عنوان ورودی و داده‌های پنجره بعدی به‌عنوان داده‌های هدف یاد می‌گیرد. وقتی تکرار یادگیری به تعداد تکرار از پیش تعیین شده می‌رسد، یادگیری متوقف می‌شود. اگر هنگام اندازه‌گیری داده‌های ویتترین آنلاین، اطلاعات ازدست‌رفته وجود داشته باشد، داده‌های ازدست‌رفته با استفاده از ANN آموخته‌شده تخمین زده می‌شود.

داده‌های ازدست‌رفته با ورود داده‌های آنلاین پنجره‌های گذشته و پنجره فعلی به شبکه عصبی آموخته شده تخمین زده می‌شود. این مقاله اندازه پنجره و تعداد سلول‌های عصبی موجود در یک لایه مخفی را با ۱۰ افزایش، تغییر می‌دهد. نویسندگان [۱۰] با استفاده از تکرار درخواست، بخش شامل داده خراب را مجددا دریافت می‌کنند که سربار اضافی به سیستم تحمیل می‌کند اما در مقایسه با سایر روش‌هایی که کل قاب داده را درخواست می‌کنند انرژی مصرفی کمتر و دقت بالاتری دارند. طرح پیشنهادی هنگامی که وضعیت کانال خراب است، میزان بار داده را به بخش‌هایی تقسیم می‌کند و فقط بخش (های) خراب را دوباره انتقال می‌دهد. این اندازه فریم‌های انتقال یافته را کاهش می‌دهد که باعث بهبود سرعت دریافت قاب و کاهش میزان ترافیک منتقل شده و در نتیجه، مصرف انرژی می‌شود. آزمایش‌های ما با استفاده از یک بستر آزمایش WBAN مبتنی بر IEEE 802.15.4 واقعی نشان می‌دهد که روش پیشنهادی قابلیت اطمینان انتقال بالاتر و مصرف برق کمتری را نسبت به مکانیسم پیش فرض IEEE 802.15.4 ARQ فراهم می‌کند. نویسندگان [۱۱] با استفاده از بهینه‌سازی ذرات ازدحام مبتنی بر شبکه عصبی مصنوعی، ویژگی‌های سری زمانی داده‌ها را فرا می‌گیرند و داده‌ها را تخمین می‌زنند که دقت تخمین داده‌های ازدست‌رفته از روش مبتنی بر DEEPSO پیشنهادی نسبت به روش‌های متداول BP و PSO برتر است اما راندمان محاسبه بالا است. DEEPSO یک روش ترکیبی با PSO تکاملی (EPSO) است که یک روش بهبودی PSO و تکامل دیفرانسیل (DE) است. این روش می‌تواند راه‌حل‌های با کیفیت بالاتر از PSO های معمولی تولید کند. DEEPSO از معادلات به‌روزرسانی مختلف مانند تصویر زیر استفاده می‌کند:

تکثیر: هر ذره R بار تکرار (شبیه‌سازی) می‌شود.

جهش: تمام ذرات شبیه‌سازی شده R دارای وزنی هستند که با معادلات مربوطه جهش می‌یابند.

تولید مثل: فرزندان $R + 1$ (اصلی و کلون‌ها) با معادلات مربوطه به‌روز می‌شوند. ارزیابی: مقدار تابع هدف به همه فرزندان محاسبه می‌شود.

انتخاب: فرزندان تشکیل دهنده نسل بعدی با استفاده از مسابقات تصادفی یا سایر روش‌های انتخاب، انتخاب می‌شوند. در این مقاله؛ یک روش انتخاب که در آن عامل با بهترین سازگاری از بین عوامل اصلی و کلون برای نسل بعدی انتخاب می‌شود، استفاده می‌شود. پارامترهای ANN مناسب برای تخمین داده‌های ازدست‌رفته توسط DEEPSO آموزش داده می‌شود. داده‌های اندازه‌گیری شده در گذشته داده‌های یادگیری استفاده شده است و ANN مقادیر اندازه‌گیری شده، اندازه پنجره را به‌عنوان داده ورودی و مقدار اندازه‌گیری شده بعدی را به‌عنوان داده هدف می‌آموزد. علاوه بر این، مقدار تابع هدف با استفاده از پارامترهای به‌روز شده توسط DEEPSO محاسبه می‌شود و پارامترها براساس فرآیندهای مربوطه به‌روز می‌شوند. یک تابع خطای مربع میانگین به‌عنوان یک تابع هدف استفاده می‌شود. وقتی داده از دست می‌رود، مقادیر ازدست‌رفته را می‌توان با استفاده از مقادیر اندازه‌گیری شده اندازه پنجره به‌عنوان داده ورودی تخمین زد. یک تابع سیگموئید به‌عنوان تابع فعال‌سازی ANN استفاده می‌شود. علاوه بر این، برای هر سنسور ویتترین یک مدل ANN سه لایه آماده شده است.

نویسندگان [۱۲] با استفاده از یادگیری عمیق، یک مدل خطی برای پیش‌بینی مشاهدات مفقود شده جریان ترافیک از طریق ترکیب اطلاعات زمانی مقیاس‌های مختلف ارائه می‌کنند که دقت بالاتری نسبت به روش‌های مشابه دارد. الگوهای

مختلف داده‌های ازدست‌رفته را تجزیه و تحلیل می‌کنند و یک روش پیش‌بینی جدید که ویژگی‌های هر الگو را ترکیبی می‌کند، طراحی می‌کنند. علاوه بر این، با ترکیب صریح الگوی ازدست‌رفته براساس مدل LSTM اصلاح شده، رویکرد جدیدی برای استنباط باقیمانده پیش‌بینی ارائه می‌دهند.

معماری اصلی از ۶ لایه LSTM و ۱ لایه کاملاً متصل (FC) تشکیل شده است. پارامترها با توجه به تجربه مهندسی انتخاب می‌شوند. متغیر مشاهده (ورودی) دارای بعد ۱ است و اندازه واحد پنهان در LSTM در کل این مقاله، ۳۲ است. به علاوه، تابع فعال‌سازی برای لایه LSTM، تابع \tanh است. از الگوریتم Adam برای بهینه‌سازی استفاده می‌کنند زیرا داده‌های جریان ترافیک پرسروصدا هستند و Adam برای مشکلات گرادیان‌های پرسروصدا و یا پراکنده مناسب است. میزان یادگیری $r = 0.001$ است. آموزش وقتی خاتمه یابد که به حداکثر تعداد دوره (در این مورد ۱۰ دوره) برسد. در پژوهش قبلی [۷۰] به مدل مناسب شبکه عصبی عمیق، برای برآورد داده‌های ازدست‌رفته ضربان قلب دست پیدا کردیم. در این پژوهش با بهم‌ریختن ترتیب ورود داده‌ها در هنگام آموزش شبکه و همچنین مقایسه با روش مشابه در تخمین داده‌های ازدست‌رفته با استفاده از شبکه عصبی عمیق [۶۹]، به پارامترهای بهینه شبکه عصبی عمیق در مورد مجموعه داده خواهیم رسید.

۳) روش‌شناسی پژوهش

۳-۱) مراحل انجام پژوهش

با توجه به این که داده‌های ما از نوع سری زمانی است و برتری LSTM در تجزیه و تحلیل توالی نسبت به سایر روش‌ها، از LSTM برای یادگیری سری زمانی داده‌های علائم حیاتی بدن استفاده می‌کنیم.

۳-۲) جامعه پژوهش

پایگاه داده MIMIC-III Waveform، با نظارت بر بیماران بستری در بخش مراقبت‌های ویژه بزرگسالان و نوزادان، هزاران سیگنال فیزیولوژیکی چندگانه ضبط شده و سری زمانی علائم حیاتی جمع‌آوری نموده است که ما برای تست الگوریتم و تعیین پارامترهای الگوریتم از آن استفاده می‌کنیم.

۳-۳) نمونه پژوهش

به علت حجم زیاد داده‌ها و دشواری بودن تست الگوریتم روی تمامی داده‌ها، به تست ۵۰۰ بیمار از این دیتاست که علائم حیاتی آنها شامل ضربان قلب، تنفس، اکسیژن خون و غیره بود، اکتفا می‌کنیم. ۷۰ درصد ابتدای سری زمانی هر بیمار را برای آموزش و ۳۰ درصد انتهای آن را برای اعتبارسنجی استفاده می‌کنیم و از ۱۰۰ بیمار دیگر برای تست الگوریتم و محاسبه میزان خطای الگوریتم استفاده می‌کنیم.

۳-۴) پیش‌پردازش داده‌ها

به علت اینکه فرمت دیتاست با ورودی الگوریتم ما یکسان نیست ابتدا ورودی موردنظر را استخراج می‌کنیم. سپس به پر کردن مقادیر ازدست‌رفته در دیتاست می‌پردازیم. بدین صورت که ابتدا خانه‌های خالی را با میانگین ۱۰ خانه اخیر پر

می‌کنیم. اگر به این ۱۰ خانه دسترسی نداشتیم، با نزدیکترین مقدار جایگزین می‌کنیم. همچنین اگر باز هم داده‌ای نداشتیم مقدار هر یک از علائم حیاتی را با مقادیر ثابت زیر جایگزین می‌کنیم که میانگین کل مقادیر مشاهده شده در دیتاست است:

$$\begin{aligned} \text{Hr} &= 91, \text{ Resp} = 20, \text{ Spo2} = 100 \\ \text{Abps} &= 121, \text{ Abpd} = 62, \text{ Abpm} = 81 \end{aligned}$$

سپس به نرمال‌سازی داده‌ها می‌پردازیم بدین صورت که، ابتدا مینیمم و ماکزیمم را از داده‌ها حذف می‌کنیم سپس از تمامی داده‌ها، میانگین را کم و بر انحراف معیار تقسیم می‌کنیم.

۳-۵) ابزارهای مورد استفاده در پژوهش

با بررسی مقالات پیرامون موضوع این پژوهش، نرم‌افزار متلب به‌عنوان نرم‌افزار شبیه‌سازی و مشاهده نتایج انتخاب شد. این نرم‌افزار روش‌های مختلفی برای تعامل و انتقال داده‌ها دارد. همچنین از وارد و صادر کردن مدل‌ها بین چهارچوب‌های دیگر یادگیری عمیق پشتیبانی می‌کند.

۳-۶) پارامترهای ارزیابی

سه معیار برای ارزیابی کارایی استفاده می‌شود: خطای میانگین مربعات ریشه (RMSE)، میانگین خطای مطلق (MAE)، میانگین درصد خطای مطلق (MAPE) که معیارهای مشهور برای اعتبارسنجی نتایج عملکرد پیش‌بینی هستند.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2}$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i|$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i - \hat{x}_i}{x_i} \right| \times 100$$

MAE اندازه متوسط خطاها را در مجموعه‌ای از پیش‌بینی‌ها، بدون در نظر گرفتن جهت آنها، اندازه‌گیری می‌کند. این برای متغیرهای پیوسته دقت را اندازه‌گیری می‌کند. MAE نمره خطی است به این معنی که تمام تفاوت‌های فردی به‌طور مساوی در میانگین وزنی است.

RMSE یک قانون امتیازدهی درجه دوم است که مقدار متوسط خطا را اندازه‌گیری می‌کند. از آنجایی که خطاها قبل از میانگین کردن آنها مربع هستند، RMSE وزن نسبتاً بالایی به خطاهای بزرگ می‌دهد. این بدان معنی است که RMSE هنگامی که خطاهای بزرگ به‌خصوص نامطلوب هستند، مفید است. RMSE همیشه بزرگتر یا مساوی با MAE خواهد بود. تفاوت بیشتر بین آنها، بیشتر واریانس در خطاهای فردی در نمونه است. اگر $RMSE = MAE$ باشد، همه خطاها از یک اندازه است هر دو MAE و RMSE می‌توانند از ۰ تا بی‌نهایت متغیر باشند. آنها نمرات منفی گرا هستند: یعنی مقادیر پایین بهتر هستند.

۳-۷) مدل استفاده شده

مدل استفاده شده برای شروع الگوریتم، مطابق مقاله پایه [۶۶] و به‌صورت زیر خواهد بود:

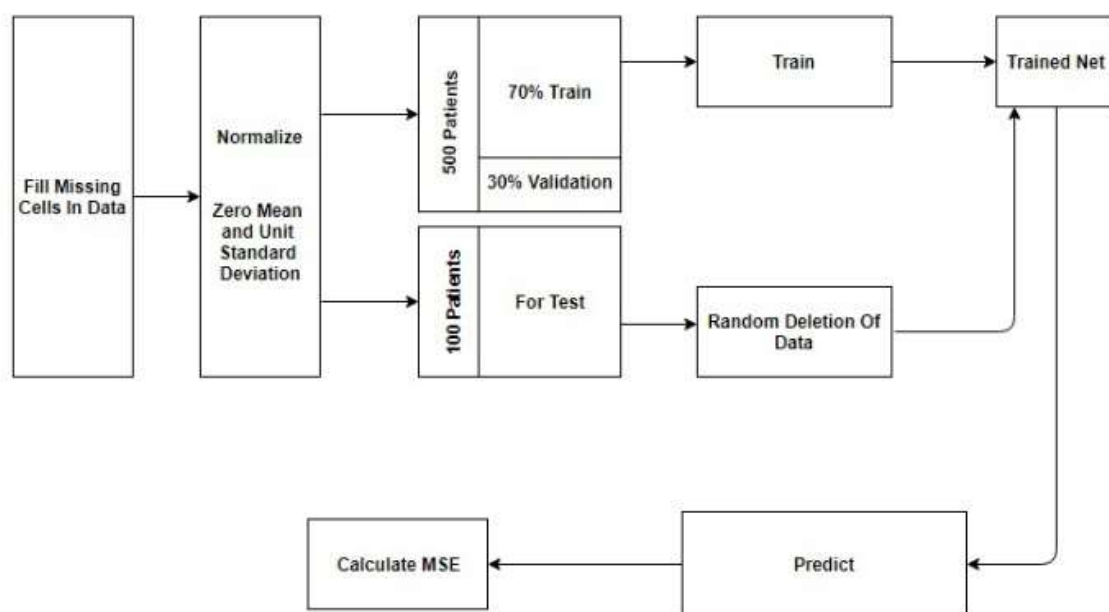
جدول ۱. پارامترهای اولیه مدل استفاده شده

مرحله	توضیحات	تعداد واحدها
۱	Input Layer	6
۲	Lstm Layer	150
۳	Fully Connected Layer 1	50
۴	DroupOut Layer	۰/۵
۵	Fully Connected Layer 2	1
۶	Regression Layer	1

۴) جزئیات روش پیشنهادی

روند کلی کار بدین صورت است که ابتدا داده‌های مربوط به ۵۰۰ بیمار را برای آموزش و ۱۰۰ بیمار دیگر را برای تست در نظر می‌گیریم. سپس از ۷۰ درصد سری زمانی داده‌های آموزش، برای آموزش مدل و ۳۰ درصد پایانی سری زمانی برای ارزیابی و جلوگیری از Overfitting استفاده می‌کنیم.

به دلیل اینکه بعضی از مقادیر ثبت نشده‌است و برای به‌دست آوردن خطای مدل نیاز به مقایسه مقادیر پیش‌بینی شده با مقادیر واقعی داریم، مقادیر ثبت نشده را با بهترین مقدار جایگزین می‌کنیم. در مرحله بعد به نرمال‌سازی داده‌ها می‌پردازیم تا داده‌ها یکنواخت شوند. سپس الگوریتم آموزش شبکه را بر روی داده‌های آموزش اجرا می‌کنیم و همچنین به‌طور تصادفی برخی خروجی موردانتظار داده‌های تست را حذف می‌کنیم. در نهایت با استفاده از شبکه آموزش دیده مقادیر از دست‌رفته را پیش‌بینی می‌کنیم و با مقادیر موردانتظار مقایسه می‌کنیم تا خطای مدل به‌دست آید.



شکل ۱. روند کار

۴-۱) فاز اول) ورود داده‌ها و پرکردن مقادیر خالی

در این مرحله ابتدا خروجی‌های تهیه شده از دیتاست را وارد می‌کنیم. سپس خانه‌های خالی را ابتدا با میانه، در غیر این صورت با نزدیکترین همسایه و در صورت موجود نبودن هیچ کدام با مقدار ثابت که میانگین کل داده‌ها در دیتاست می‌باشد، پر می‌کنیم.

```

1. function Import-Data ()
2.     Import patient from csv
3.     Replace missing cell with median
4.     Replace missing cell with nearest
5.     Replace missing hr column with average hr value in dataset (91)
6.     Replace missing resp column with average resp value in dataset (20)
7.     Replace missing spo2 column with average spo2 value in dataset (100)
8.     Replace missing abps column with average abps value in dataset (121)
9.     Replace missing abpd column with average abpd value in dataset (62)
10.    Replace missing abpm column with average abpm value in dataset (81)
11.    Return Train & Test & Validation Data

```

شکل ۲. فاز اول

۴-۲) فاز دوم) نرمال‌سازی داده‌های آموزش و تست

در این فاز کمترین و بیشترین مقدار را پیدا می‌کنیم و از داده‌ها حذف می‌کنیم. سپس میانگین و انحراف معیار داده‌ها را حساب کرده و از تمامی داده‌ها میانگین را کم و تقسیم بر انحراف معیار می‌کنیم. به این صورت همه داده‌ها نرمال خواهند شد و دامنه تغییراتشان کوچکتر می‌شود.

```

1. function Normalize ()
2.     find min & max
3.     remove min & max
4.     calculate mean & sig
5.     for i from 1 to n
6.          $x\{i\} = x\{i\} - \text{mean} / \text{sig}$ 
7.     Return Train & Test & Validation Data

```

شکل ۳. فاز دوم

۳-۴) فاز سوم) آموزش شبکه

در این فاز پس از تنظیم ابرپارامترهای شبکه، شبکه را با داده‌های آموزش تعلیم می‌دهیم. در نهایت خروجی شبکه، یک ماتریس وزنی خواهد بود که برای پیش‌بینی مقادیر ازدست‌رفته می‌توان از آن استفاده کرد.

```

1. function Train ()
2.     configure network parameters & hyper-parameters
3.     train Network
4.     Return Network Weight Matrix

```

شکل ۴. فاز سوم

۴-۴) فاز چهارم) پیش‌بینی مقادیر ازدست‌رفته

در این مرحله با استفاده از ماتریس وزنی به‌دست‌آمده در مرحله قبل، به پیش‌بینی مقادیر ازدست‌رفته داده‌های تست خواهیم پرداخت.

```

1. function Predict ()
2.     predict
3.     Return predicted value

```

شکل ۵. فاز چهارم

۵-۴) فاز پنجم) محاسبه مقادیر خطا

در این فاز، تک‌تک مقادیر پیش‌بینی شده را با مقادیر موردانتظار مقایسه می‌کنیم و خطای مدل را به‌دست می‌آوریم و برای محاسبه خطای کل از میانگین خطاها استفاده می‌کنیم.

```

1. function Calculate-Error ()
2.     for i from 1 to n
3.         rmse(i) = sqrt(mean((y{i}-p{i})^2))
4.         mae(i) = mean(abs(y{i}-p{i}))
5.         mape(i) = mean(abs(y{i}-p{i})/y{i})*100
6.     RMSE = mean(rmse)
7.     MAE = mean(mae)
8.     MAPE = mean(mape)
9.     Return RMSE & MAE & MAPE

```

شکل ۶. فاز پنجم

۵) تنظیم ابرپارامترها

شبکه‌های عصبی مصنوعی دارای دو فراپارامتر اصلی هستند که معماری یا توپولوژی شبکه را کنترل می‌کنند: تعداد لایه‌ها و تعداد گره‌ها در هر لایه پنهان. هنگام تنظیم شبکه باید مقادیر این پارامترها را مشخص کرد. مطمئن‌ترین روش برای پیکربندی این ابرپارامترها برای مدل‌سازی یک مسئله پیش‌بینی خاص، از طریق آزمایش سیستماتیک با یک تست قوی است.


۶) یافته‌های پژوهش

با توجه به این که الگوریتم یادگیری عمیق نیاز به یک سری فراپارامترها برای دقت بیشتر نیاز دارد، ابتدا یک پارامتر را متغیر و مابقی پارامترها را ثابت در نظر می‌گیریم و برای بررسی تاثیر متغیر از خطای مربعات استفاده می‌کنیم و کمترین خطا را به عنوان هدف در نظر می‌گیریم تا مقدار بهینه پارامتر به دست آید. تاثیر پارامترها را مطابق سناریوهای زیر بررسی خواهیم کرد:

در این بخش چند سناریو برای بررسی و ارزیابی روش پیشنهادی استفاده می‌شود که هر کدام به‌طور کامل شرح داده می‌شوند و نتایج آنها نشان داده می‌شود.

۶-۱) سناریوی اول: تاثیر افزایش BatchSize

تمامی پارامترهای شبکه بجز BatchSize، ثابت در نظر گرفته شده‌اند.



شکل ۷. تاثیر batchsize

همانطور که در شکل ۷ مشخص است، کمترین خطا مربوط به batchsize با مقدار ۱۰ است. همچنین نمودار شیب صعودی دارد ولی در مقدار ۲۰ به دلیل عدم بسته‌بندی مناسب داده‌ها مقدار ناگهان افزایش داشته‌است. همچنین در مقدار ۹۰ به دلیل عدم بسته‌بندی مناسب داده‌ها این اتفاق دوباره تکرار شده‌است.

اگر اندازه دسته برابر با کل مجموعه داده باشد، همگرایی با بهینه سراسری تابع هدف را تضمین می‌کند اما این به بهای کندتر شدن فرآیند یادگیری است. از طرف دیگر به صورت تجربی، استفاده از اندازه دسته کوچکتر، همگرایی سریع‌تری به راه‌حل‌های خوب دارد. به صورت شهودی اندازه دسته کوچکتر به مدل اجازه می‌دهد قبل از دیدن همه داده‌ها، شروع به یادگیری کند. نکته منفی استفاده از اندازه دسته کوچکتر این است که همگراشدن مدل با بهینه سراسری تضمین نمی‌شود.

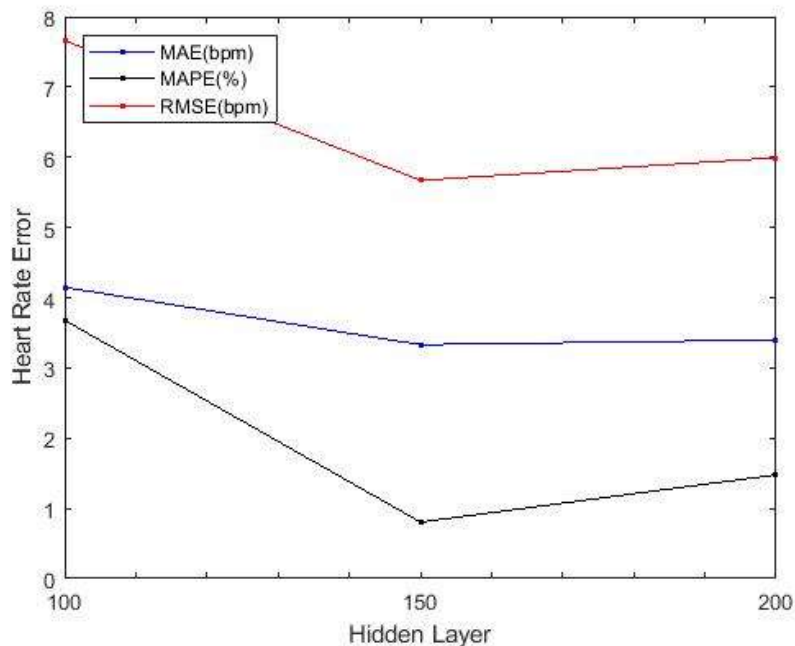
جدول ۲. تاثیر batchsize

lstm hidden unit=150; dropout=0.5; Fully Connected Input=150				
Batch	Time	RMSE	MAE	MAPE
10	---	5.8414	3.7765	2.0546
20	---	6.4476	3.9983	3.1355
30	---	6.0950	3.6885	2.1005
40	1353	6.0883	3.8904	2.6858
50	1182	6.6260	4.1024	3.0073
60	1100	7.1845	4.1846	2.5557
70	1042	7.1839	4.6266	4.1542
80	1289	7.5516	4.8430	4.0672
90	880	8.8961	6.1485	5.6945
100	949	6.3461	3.8753	1.4623

به دلیل اینکه کمترین میزان خطای شبکه در BatchSize=10 روی داده است، این مقدار را برای مراحل بعدی ۱۰ در نظر می‌گیریم.

۶-۲) سناریوی دوم: تاثیر افزایش لایه‌های پنهان لایه LSTM

در این آزمایش بجز تعداد لایه‌های پنهان بقیه موارد ثابت در نظر گرفته شده‌اند.



شکل ۸. تاثیر لایه پنهان

این نمودار شیب نزولی دارد ولی به صورت کلی افزایش مقدار لایه‌ها منجر به خطای بیشتر می‌شود. افزایش لایه‌های پنهان بیش از تعداد کافی باعث کاهش دقت در مجموعه تست می‌شود چون باعث می‌شود شبکه با مجموعه آموزش مطابقت داشته باشد اما نمی‌تواند به داده‌های جدید تعمیم یابد.


جدول ۳: تاثیر لایه پنهان

lstm batch=10; dropout=0.5;				
Hidden	Time	RMSE	MAE	MAPE
100	---	7.6604	4.1481	3.6793
150	---	5.6705	3.3309	0.8053
200	---	5.9937	3.3997	1.4784

با توجه به نتایج به دست آمده تعداد لایه‌های پنهان برای بقیه مراحل ۱۵۰ در نظر گرفته می‌شود.

۳-۶ سناریوی سوم: تاثیر افزایش dropout

در این مرحله فقط dropout را تغییر می‌دهیم و به سایر پارامترها کاری نداریم.



شکل ۹. تاثیر dropout

همانطور که در شکل ۹ پیداست با افزایش dropout تا ۰/۵ خطا کاهش داشته اما به دلیل overfitting بعد از مقدار ۰/۵ مجدداً افزایش خطا را خواهیم داشت. این بدان معنی است که در مقدار ۰/۵ بالاترین واریانس را برای این توزیع داشته‌ایم.

Dropout با حذف احتمالی یا رهاکردن ورودی‌های یک لایه کار می‌کند که ممکن است متغیرهای ورودی در نمونه داده یا فعال‌سازی‌های یک لایه قبلی باشد. این اثر شبیه‌سازی تعداد زیادی از شبکه‌ها با ساختار شبکه بسیار متفاوت است و به نوبه خود باعث می‌شود که گره‌های شبکه به‌طور کلی ورودی‌های بیشتری داشته باشند. به صورت تجربی مقدار خوب برای dropout در یک لایه مخفی بین ۰/۵ تا ۰/۸ است.

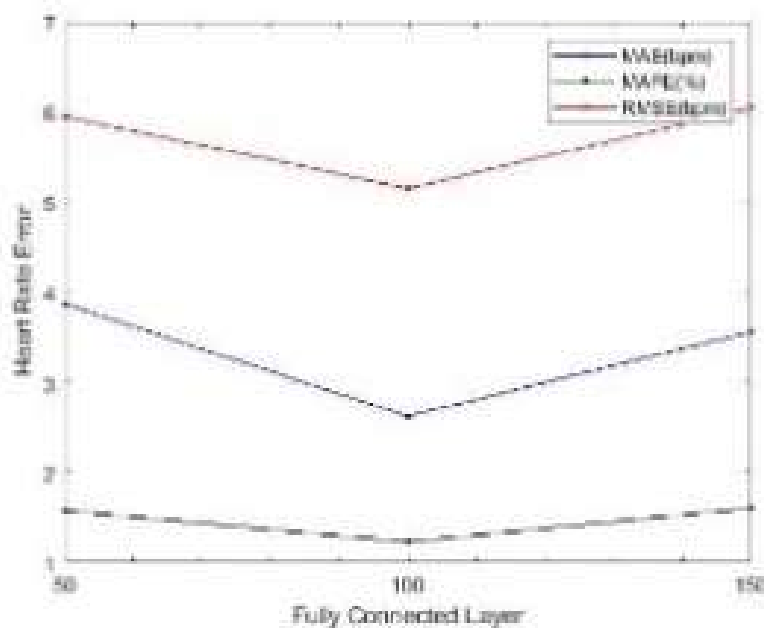
جدول ۴. تاثیر dropout

lstm batch=10; lstm hidden unit=150; Fully Connected Input=150				
Dropout	Time	RMSE	MAE	MAPE
۰/۲	---	6.1048	3.9898	1.4867
۰/۳	---	5.5148	3.4520	1.1101
۰/۴	---	5.6118	3.6856	2.6985
۰/۵	---	5.4459	3.1728	1.4051
۰/۶	---	5.9611	3.8165	2.0784
۰/۷	---	5.6573	3.2605	1.1050
۰/۸	---	5.7242	3.5815	2.1259

با توجه به نتایج، مقدار ۰/۵ را برای dropout در نظر می‌گیریم.

۴-۶ سناریوی چهارم: تاثیر افزایش تعداد لایه خروجی لایه FullyConnected

در این سناریو، تاثیر افزایش تعداد لایه‌های خروجی لایه FullyConnected را بررسی می‌کنیم.



شکل ۱۰. تاثیر لایه‌های fullyconnected

با توجه به شکل ۱۰؛ نمودار تا مقدار ۱۰۰ شیب نزولی داشته‌است ولی به دلیل overfitting بعد از این مقدار شاهد افزایش خطا می‌باشیم. افزودن یک لایه کاملاً متصل (Fully-Connected layer) معمولاً راهی ارزان برای یادگیری ترکیب‌های غیرخطی سطح بالای ویژگی‌هاست. این اتصال کامل باعث اتلاف بوده و تعداد بسیار زیاد پارامترها به سرعت باعث overfitting خواهد شد.

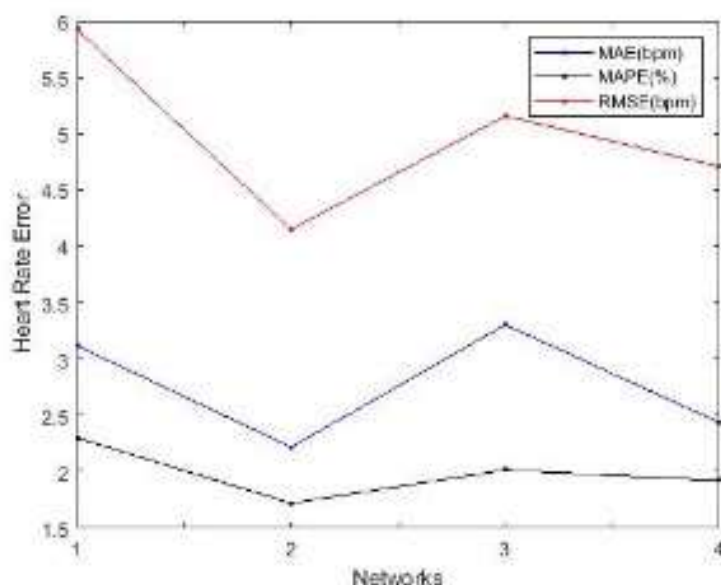
جدول ۵. تاثیر لایه‌های fullyconnected

lstm batch=10; dropout=0.5; lstm hidden unit=150;				
Fully	Time	RMSE	MAE	MAPE
50	---	5.9462	3.8681	1.5722
100	---	5.1508	2.6217	1.2283
150	---	6.0394	3.5595	1.5980

همانطور که از نتایج مشخص می‌باشد، تعداد لایه خروجی لایه FullyConnected مناسب برای پژوهش ما ۱۰۰ می‌باشد.

۵-۶ سناریوی پنجم: تاثیر افزایش لایه‌های متوالی LSTM

در این سناریو تعداد لایه‌های LSTM را تغییر می‌دهیم.



شکل ۱۱. تاثیر لایه LSTM

با توجه به شکل ۱۱؛ با افزایش تعداد لایه LSTM خطا کاهش می‌یابد ولی با بیش از ۳ لایه به دلیل overfitting عملاً بهبودی در پیش‌بینی و کاهش خطا نداریم.

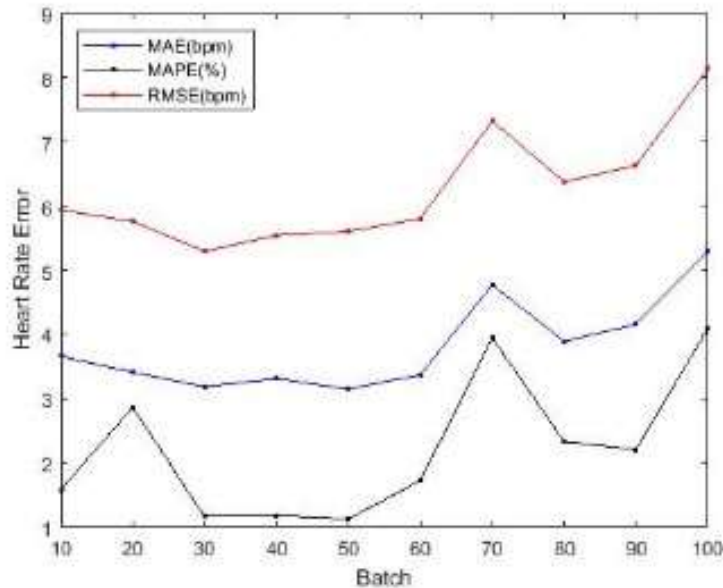
جدول ۶. تاثیر لایه LSTM

lstm batch=10; dropout=0.5;				
lstm	Time	RMSE	MAE	MAPE
1) 150	---	5.9215	3.1185	2.2992
2) 150-120	---	4.1495	2.2157	1.7192
3) 250-200-150	---	5.1566	3.3030	2.0147
4) 200-175-150	---	4.7058	2.4341	1.9199

نتایج نشان‌دهنده این می‌باشند که با افزایش تعداد لایه متوالی LSTM، بهبودی در خطای شبکه اتفاق نمی‌افتد و بهترین ساختار، استفاده از دو لایه LSTM با ۱۵۰ و ۱۲۰ لایه پنهان می‌باشد. با توجه به اینکه نمودارها روند مشخصی را طی نمی‌کنند بار دیگر سناریوها را با بهم‌ریختن ترتیب ورود داده انجام می‌دهیم.

۶-۶ سناریوی ششم: تاثیر افزایش BatchSize

در این مرحله، پارامترهای شبکه بجز BatchSize ثابت در نظر گرفته شده‌اند. همانطور که در شکل ۱۲ مشخص است، کمترین خطا مربوط به batchsize با مقدار ۳۰ است. همچنین نمودار شیب صعودی دارد و علت اوج ناگهانی در مقدار ۷۰، بسته‌بندی نامناسب داده‌ها با این مقدار می‌باشد.



شکل ۱۲. تاثیر batchsize

جدول ۷. تاثیر batchsize

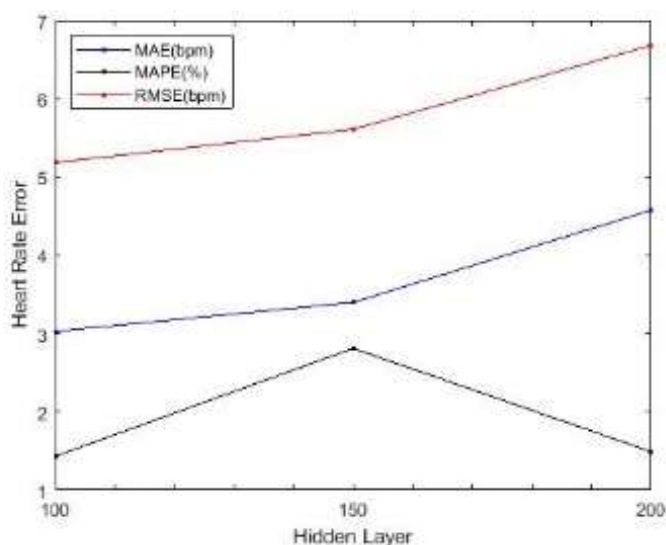
lstm hidden unit=150; dropout=0.5; Fully Connected Input=50				
Batch	Time	RMSE	MAE	MAPE
10	---	5.9372	3.6618	1.5824
20	---	5.7616	3.4093	2.8656
30	1934	5.2930	3.1856	1.1638
40	1671	5.5453	3.3123	1.1809
50	1451	5.6032	3.1495	1.1269
60	1348	5.8036	3.3718	1.7232
70	1293	7.3246	4.7747	3.9467
80	1175	6.3753	3.8918	2.3320
90	1059	6.6335	4.1588	2.2066
100	1114	8.1389	5.3022	4.0988

به دلیل اینکه کمترین میزان خطای شبکه در BatchSize=30 اتفاق افتاد، این مقدار را برای مراحل بعدی ۳۰ در نظر

می‌گیریم.

۶-۷ سناریوی هفتم: تاثیر افزایش لایه‌های پنهان لایه Lstm

بجز تعداد لایه‌های پنهان، سایر موارد ثابت در نظر گرفته شده‌اند.



شکل ۱۳. تاثیر لایه پنهان

این نمودار شیب صعودی دارد و افزایش مقدار لایه‌ها منجر به خطای بیشتر می‌شود.


جدول ۸. تاثیر لایه پنهان

lstm batch=30; dropout=0.5;				
Hidden	Time	RMSE	MAE	MAPE
100	1396	5.1848	3.0281	1.4296
150	1948	5.6089	3.3971	2.8101
200	---	6.6809	4.5752	1.4890

با توجه به نتایج به‌دست‌آمده تعداد لایه‌های پنهان برای بقیه مراحل، ۱۰۰ در نظر گرفته می‌شود.

۶-۸ سناریوی هشتم: تاثیر افزایش dropout

در این مرحله به سایر پارامترها کاری نداریم و فقط dropout را تغییر می‌دهیم.



شکل ۱۴. تاثیر dropout

همانطور که در شکل ۱۴ پیداست، با افزایش dropout روند مشخصی نداریم ولی کمترین مقدار خطا، در مقدار ۰/۶

است.

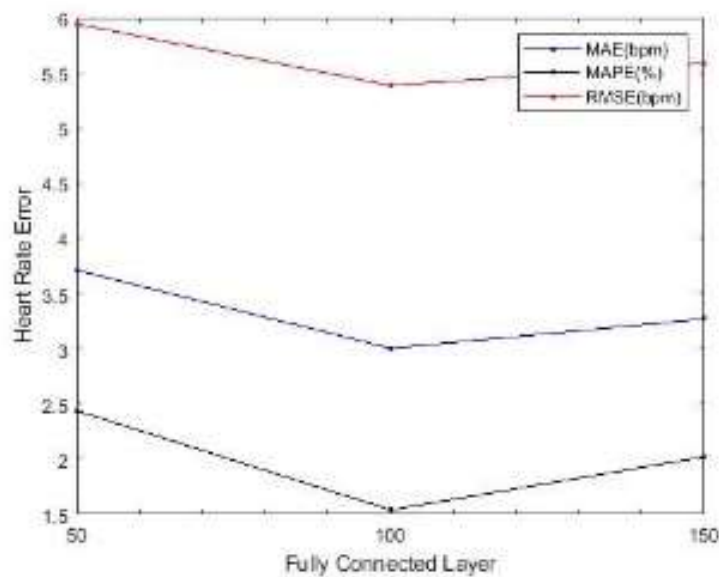
جدول ۹. تاثیر dropout

lstm batch=30; lstm hidden unit=100; Fully Connected Input=50				
Dropout	Time	RMSE	MAE	MAPE
0/2	---	5.7898	3.3733	2.8124
0/3	1368	5.5382	3.1184	1.0171
0/4	---	6.3425	3.9096	3.2456
0/5	---	5.2702	2.9983	0.7125
0/6	---	4.7635	2.5864	0.7192
0/7	---	5.1929	2.9965	1.4851
0/8	---	6.8902	5.1470	5.0295

با توجه به نتایج، مقدار ۰/۶ را برای dropout در نظر می‌گیریم.

۹-۶ سناریوی نهم: تاثیر افزایش تعداد لایه خروجی لایه FullyConnected

در این سناریو، با ثابت در نظر گرفتن سایر پارامترها و تغییر تعداد لایه‌های FullyConnected تاثیر افزایش تعداد لایه‌های خروجی لایه FullyConnected را بررسی می‌کنیم.



شکل ۱۵. تاثیر لایه‌های fullyconnected

با توجه به شکل ۱۵؛ نمودار تا مقدار ۱۰۰ شیب نزولی داشته‌است ولی به دلیل overfitting بعد از این مقدار شاهد افزایش خطا می‌باشیم.


جدول ۱۰. تاثیر لایه‌های fullyconnected

lstm batch=30; dropout=0.6; lstm hidden unit=100;				
Fully	Time	RMSE	MAE	MAPE
50	1369	5.9450	3.7130	2.4400
100	---	5.3873	3.0050	1.5403
150	1443	5.5891	3.2714	2.0206

با توجه به نتایج، تعداد لایه خروجی لایه FullyConnected، ۱۰۰ می‌باشد.

۶-۱۰) سناریوی دهم: تاثیر افزایش لایه‌های متوالی Lstm

در این مرحله فقط تعداد لایه‌های Lstm را تغییر می‌دهیم.



شکل ۱۶. تاثیر لایه Lstm

با توجه به شکل ۱۶؛ با افزایش تعداد لایه Lstm خطا کاهش می‌یابد.

جدول ۱۱. تاثیر لایه Lstm

Lstm batch=30; dropout=0.6;				
lstm	Time	RMSE	MAE	MAPE
1) 120	1603	5.4033	3.2146	1.5851
2) 150-120	---	4.7258	2.5790	0.8549
3) 250-200-150	---	4.3896	2.3288	0.9783
4) 200-175-150	---	4.3323	2.6005	1.7238

نتایج نشان‌دهنده این می‌باشد که با افزایش تعداد لایه متوالی Lstm، خطای شبکه کاهش می‌یابد و بهترین ساختار، استفاده از سه لایه Lstm با ۲۰۰ و ۱۷۵ و ۱۵۰ لایه پنهان می‌باشد. با توجه به نتایج، بعد از تغییر در ورود داده‌ها، بهبودی در خطا صورت نگرفت ولی روند نمودارها ساختارمند شد.

۷) نتیجه‌گیری و پیشنهادها

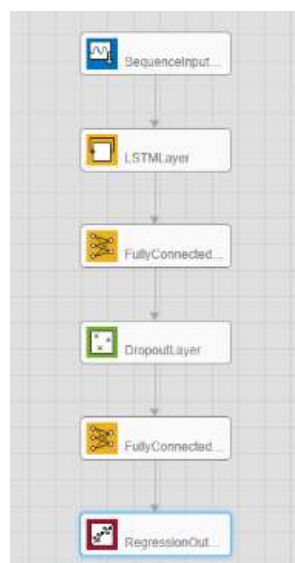
۷-۱) مقایسه روش پیشنهادی با شبکه عصبی و Narx (Nonlinear autoregressive)

برای مقایسه مدل پیشنهادی با شبکه عصبی، از یک شبکه عصبی ساده با ۲ لایه پنهان با ۵ نورون در هر لایه استفاده می‌کنیم. مدل پیشنهادی را با مدل شبکه عصبی غیرخطی خود کاهشی نیز مقایسه می‌کنیم که ۱۰ لایه پنهان دارد.



شکل ۱۷. معماری نهایی

معماری نهایی مدل ما شکل ۱۷ خواهد بود که پس از سناریوهای مختلف و بررسی کمینه خطا به آن دست پیدا کردیم. مدل نهایی را با یکی از مقالات مشابه [۶۹] در زمینه پیش‌بینی مقادیر که معماری آن مطابق شکل ۱۸ می‌باشد، مقایسه می‌کنیم. این شبکه از یک لایه LSTM با تابع فعال‌ساز tanh، یک لایه Fullyconnected با تابع فعال‌ساز خطی، یک لایه Dropout با مقدار ۰/۲ و یک در نهایت یک لایه Fullyconnected با تابع فعال‌ساز ReLU، تشکیل شده‌است. همچنین مقدار BatchSize در این مدل ۱۲۸ و مقدار epoch100 در نظر گرفته شده‌است. از آنجاکه الگوریتم SGD سرعت همگرایی کندتری دارد و در همان زمان پیش‌بینی نتیجه مستعد نوسان است، بنابراین adam به‌عنوان بهینه‌ساز در این مقاله انتخاب شده‌است.



شکل ۱۸. معماری شبکه پیش‌بینی ضربان قلب

در نهایت مدل خود را از لحاظ خطای پیش‌بینی و سرعت یادگیری و پیش‌بینی با سایر روش‌ها مقایسه می‌کنیم، نتایج مطابق جدول ۴-۱۱ می‌باشد.

جدول ۱۲. مقایسه مدل پیشنهادی با سایر روش‌ها

	Methods				
	Narx	NN	Deep Sgdm	Deep Adam	Deep Adam ^[69]
RMSE	27.3647	22.3362	4.3295	6.4139	7.0064
TrainTime(Secs)		50	4738	8383	616
PredictTime(Secs)	9752	8	32	34	5

با توجه به نتایج، روش پیشنهادی ما دقت بیشتری نسبت به سایر روش‌ها دارد اما شبکه عصبی مصنوعی نیاز به زمان بسیار کمتری برای آموزش شبکه دارد.

شبکه‌های حسگر بی سیم بدن در نظارت بر سلامت و تشخیص بسیاری از بیماری‌ها کاربرد دارند. این شبکه‌ها با مشکلاتی روبه‌رو هستند. یکی از این مشکلات، از دست رفتن مقادیر می‌باشد و به دلیل اینکه این داده‌ها با سلامتی و جان انسان‌ها در ارتباط هستند، پیش‌بینی این مقادیر یک نیاز اساسی می‌باشد. تمرکز اصلی ما این بود که با استفاده از lstm کمترین خطا برای این کار را ارائه دهیم. روش پیشنهادی به‌طور نسبی خطای کمتری نسبت به سایر روش‌های مشابه در این حوزه دارد. با توجه به نتایج سناریوهای طراحی شده مناسب‌ترین مقدار برای batchSize، ۱۰ و تعداد لایه‌های پنهان lstm اول، ۱۵۰ و تعداد لایه پنهان لایه دوم lstm، ۱۰۰ می‌باشد. همچنین میزان dropout شبکه ۰/۵ می‌باشد. روش مناسب برای پیش‌بینی مقادیر از دست رفته استفاده از sgd-LSTM می‌باشد که با افزایش تعداد لایه‌ها، دقت پیش‌بینی بهبود می‌یابد. افزایش تعداد لایه‌های پنهان، تاثیری بر سرعت پاسخگویی الگوریتم نخواهد داشت ولی باعث کاهش سرعت یادگیری و افزایش خطا خواهد شد که در نهایت دقت پیش‌بینی را کاهش خواهد داد. با افزایش تعداد لایه‌های مدل، خطا کاهش می‌یابد و دقت پیش‌بینی بهبود خواهد یافت. همچنین تاثیری بر سرعت پاسخگویی الگوریتم نخواهد داشت ولی این افزایش باعث کاهش سرعت فرآیند یادگیری می‌شود. در مقایسه با سایر روش‌های مشابه در حوزه پیش‌بینی مقادیر، روش ما سرعت یادگیری پایینی دارد ولی در صورت تنظیم مناسب ابر پارامترهای شبکه، دقت بالاتری نسبت به سایر روش‌ها در تخمین مقادیر دارد.

منابع

- A. B. C. ChavanPatil و S. S. Sonawane، "To Predict Heart Disease Risk and Medications Using Data Mining Techniques With an IoT Based Monitoring System For Post Operative Heart Disease Patients"، Sixth Post Graduate Conference for Computer Engineering (cPGCON 2017) Procedia, 2017. <https://doi.org/10.1016/j.trb.2017.04.003>
- A. B. Islam، D. Costinett و S. K. Islam، "Wireless Power Transfer, Recovery, and Data Telemetry for Biomedical Applications"، Handbook of Biochips, 2017 <https://doi.org/1097/j.trb.2014.6.40>
- B. Kim، B. Lee و J. Cho، "ASRQ: Automatic Segment Repeat reQuest for IEEE 802.15.4-based WBAN"، IEEE SENSORS JOURNAL, 2016. <https://doi.org/1071/j.trb.2004.34.125>

- B.-K. Kim ,H.-K. Song ,S.-I. Seo و Y.-H. You ،"Frame and carrier frequency synchronization algorithm for wireless body area network," INTERNATIONAL JOURNAL OF COMMUNICATION SYSTEMS ,2015. <https://doi.org/1016/j.trb.2020.23.29>
- B. LIU ,Z. YAN و C. W. CHEN ،"MAC PROTOCOL IN WIRELESS BODY AREA NETWORKS FOR E-HEALTH: CHALLENGES AND A CONTEXT-AWARE DESIGN," IEEE Wireless Communications ٢٠١٣ ، <https://doi.org/1027/j.trb.2019.10.94>
- C. Lee ,Z. Luo ,K. Y. Ngiam ,M. Zhang ,K. Zheng ,G. Chen ,B. C. Ooi و W. L. J. Yip ،"Big Healthcare Data Analytics: Challenges and Applications " تألیف Handbook of Large-Scale Distributed Computing in Smart Healthcare ,2017. <https://doi.org/1014/j.trb.2007.33.102>
- D. Sakurai ,A. Santana و Y. Kawamura ،"Estimation of Missing Data of Showcase Using Artificial Neural Networks " تألیف ، IEEE 10th International Workshop on Computational Intelligence and Applications ٢٠١٧ ، <https://doi.org/1046/j.trb.2023.36.63>
- D. Sow ,D. S. Turaga و M. Schmidt ،"MINING OF SENSOR DATA IN HEALTHCARE: A SURVEY " تألیف Managing and Mining Sensor Data ,2012. <https://doi.org/1076/j.trb.2021.32.13>
- D. Yuan ,G. Zheng ,H. Ma ,J. Shang و J. Li ،"An Adaptive MAC Protocol Based on IEEE802.15.6 for Wireless Body Area Networks," Wireless Communications and Mobile Computing, 2019. <https://doi.org/1056/j.trb.2017.7.23>
- D. Yu , L. Deng ،Deep Learning: Methods and Applications ٢٠١٤ ، <https://doi.org/1064/j.trb.2022.34.47>
- E. Cadenas ,W. Rivera ,R. Campos-Amezcuca و C. Heard ،"Wind Speed Prediction Using a Univariate ARIMA Model and a Multivariate NARX Model," energies ,2016. <https://doi.org/1029/j.trb.2008.15.81>
- E. S. Kaur و P. B. Singh ،"A survey on Body Area Network applications and its routing issues," International Research Journal of Engineering and Technology (IRJET), 2017. <https://doi.org/1094/j.trb.2023.37.44>
- F. Hu ,X. Liu ,M. Shao ,D. Sui و L. Wang ،"Wireless Energy and Information Transfer in WBAN: An Overview," IEEE Network ٢٠١٧ ، <https://doi.org/1035/j.trb.2009.6.59>
- F. Lia ,G. Renb و J. Lee ،"Multi-step wind speed prediction based on turbulence intensity and hybrid deep neural networks," Energy Conversion and Management ,2019. <https://doi.org/1034/j.trb.2021.14.45>
- F. Rundo ،"Deep LSTM with Reinforcement Learning Layer for Financial Trend Prediction in FX High Frequency Trading Systems," Applied Sciences, 2019. <https://doi.org/1032/j.trb.2021.15.125>
- F. V. Nelwamondo ،Computational Intelligence Techniques for Missing Data Imputation, 2008. <https://doi.org/1022/j.trb.2014.19.66>
- G. Huang ,Y. Zhang ,J. Cao ,M. Steyn و K. Taraporewalla ،"Online mining abnormal period patterns from multiple medical sensor data streams," World Wide Web ٢٠١٣ ، <https://doi.org/1066/j.trb.2018.13.87>
- G. Mohammad ,B. Janko ,R. S. Sherratt ,W. Harwin ,R. Piechockic و C. Soltanpur ،"A Survey on Wireless Body Area Networks for eHealthcare Systems in Residential Environments," sensors ٢٠١٦ ، <https://doi.org/1086/j.trb.2012.13.69>
- H. Arora ,R. S. Sherratt ,B. Janko و W. Harwin ،"Experimental validation of the recovery effect in batteries for wearable sensors and healthcare devices discovering the existence of hidden time constants," Institution of Engineering and Technology ، ٢٠١٧. <https://doi.org/1098/j.trb.2005.8.16>
- H. Cheng ,Z. Xie ,L. Wu ,Z. Yu و R. Li ،"Data prediction model in wireless sensor networks based on bidirectional LSTM," Wireless Communications and Networking ٢٠١٩ ، <https://doi.org/1064/j.trb.2020.26.134>

- H. M. Rai و K. Chatterjee, "A unique Feature Extraction using MRDWT for Automatic Classification of Abnormal Heartbeat from ECG Big Data with Multilayered Probabilistic Neural Network Classifier," *Applied Soft Computing*, 2018. <https://doi.org/1036/j.trb.2021.21.91>
- I. Ha, "Technologies and Research Trends in Wireless Body Area Networks for Healthcare: A Systematic Literature Review," *International Journal of Distributed Sensor Networks* ۲۰۱۵, <https://doi.org/1017/j.trb.2008.22.8>
- J. Camilo J. Felipe و Natalia, "Energy consumption and quality of service in WBAN: A performance evaluation between cross-layer and IEEE802.15.4," *Revista DYNA* ۲۰۱۷, <https://doi.org/1068/j.trb.2005.5.104>
- J. I. Bangash, A. H. Abdullah, M. H. Anisi و A. W. Khan, "A Survey of Routing Protocols in Wireless Body Sensor Networks," *Sensors* ۲۰۱۴, <https://doi.org/1034/j.trb.2006.24.77>
- J. Chen, G.-Q. Zeng, W. Zhou, W. Du و K.-D. Lu, "Wind speed forecasting using nonlinear-learning ensemble of deep learning time series prediction and extremal optimization," *Energy Conversion and Management* ۲۰۱۸, <https://doi.org/1030/j.trb.2011.21.80>
- J. Q. Lin, H. C. Wu و S. C. Chan, "A New Regularized Recursive Dynamic Factor Analysis with Variable Forgetting Factor for Wireless Sensor Networks with Missing Data," *IEEE International Symposium on Circuits and Systems (ISCAS)* ۲۰۱۷, <https://doi.org/1024/j.trb.2012.24.95>
- J. Pagán, "Robust and Accurate Modeling Approaches for Migraine Per-Patient Prediction from Ambulatory Data," 2015. <https://doi.org/1054/j.trb.2012.12.120>
- K. C. Shekar, K. R. Kanth و K. S. Kanth, "Improved Algorithm for Prediction of Heart Disease Using Case based Reasoning Technique on Non-Binary Datasets," *International Journal of Research in Computer and Communication technology*, ۲۰۱۲, <https://doi.org/1027/j.trb.2002.25.9>
- K. W. Minmin Luo, "Heart rate prediction model based on neural network," *IOP Conference Series: Materials Science and Engineering* ۲۰۲۰, <https://doi.org/1032/j.trb.2007.26.67>
- K. Yan, X. Wang, Y. Du, N. Jin, H. Huang و H. Zhou, "Multi-Step Short-Term Power Consumption Forecasting with a Hybrid Deep Learning Strategy," *energies* ۲۰۱۸, <https://doi.org/1060/j.trb.2015.35.73>
- L. Pan, J. Li, "K-Nearest Neighbor Based Missing Data Estimation Algorithm," pp. 115-122, ۲۰۱۰, <https://doi.org/1023/j.trb.2006.22.76>
- L. Zhao, F. Zheng, "Missing Data Reconstruction Using Adaptively Updated Dictionary in Wireless Sensor Networks," *Proceeding of science* ۲۰۱۷, <https://doi.org/1061/j.trb.2012.35.138>
- M. K. M. Rabby, M. S. Alam, S. A. Shawkat و M. A. Hoque, "A Scheduling Scheme for Efficient Wireless Charging of Sensor Nodes in WBAN," *IEEE/ACM International Conference on Connected Health: Applications, Systems and Engineering Technologies (CHASE)* ۲۰۱۷, <https://doi.org/1091/j.trb.2011.13.36>
- M. Salayma, A. Al-Dubai, J. Romdhani و Y. Nasser, "Wireless Body Area Network (WBAN): A Survey on Reliability, Fault Tolerance, and Technologies Coexistence," *ACM Computing Surveys* ۲۰۱۷, <https://doi.org/1045/j.trb.2005.8.42>
- M. S. Saha و D. D. K. Anvekar, "Mitigation of Single Point Failure and Successful Data Recovery in Wireless Body Area Network," *International Journal of Network Infrastructure Security* ۲۰۱۷, <https://doi.org/1027/j.trb.2002.25.9>
- O. Salem, A. Serhrouchni, A. Mehaoua و R. Boutaba, "Event Detection in Wireless Body Area Networks using Kalman Filter and Power Divergence," *IEEE Transactions on Network and Service Management* ۲۰۱۸, <https://doi.org/1027/j.trb.2002.25.9>

- Q. Zhen و T. Zhang ،"A Missing Data Estimation Algorithm in Wireless Sensor Networks," *Boletín Técnico* ٢٠١٧ ، <https://doi.org/1026/j.trb.2002.21.67>
- R. Kumar ،D. Chaurasia ،N. Chuahan و N. Chand ،"Predicting Missing Values in Wireless Sensor Network using Spatial-Temporal Correlation," *International Journal of Computer Networks and Wireless Communications (IJCNWC)* ٢٠١٧ ، <https://doi.org/1074/j.trb.2021.8.25>
- R. Zhang ،Z. Chen ،S. Chen ،J. Zheng ،O. Büyüköztürk و H. Sun ،"Deep long short-term memory networks for nonlinear structural seismic response prediction," *Computers and Structures* ٢٠١٩ ، <https://doi.org/1055/j.trb.2003.27.101>
- S. Ghazal ،M. Sauthier ،D. Brossier ،W. Bouachir ،P. Jouvét و R. Noumeir ،"Using machine learning models to predict oxygen saturation following ventilator support adjustment in critically ill children: a single center pilot study," *PLoS ONE* ، ٢٠١٩. <https://doi.org/1059/j.trb.2005.35.100>
- S. M. Demir ،F. Al-Turjman و A. Muhtaroglu ،"Energy Scavenging Methods for WBAN," *IEEE Sensors Journal* ٢٠١٨ ، <https://doi.org/1032/j.trb.2012.10.123>
- S. Mujeeb ،N. Javaid ،M. Ilahi ،Z. Wadud ،F. Ishmanov و M. K. Afzal ،"Deep Long Short-Term Memory: A New Price and Load Forecasting Scheme for Big Data in Smart Cities," *sustainability* ٢٠١٩ ، <https://doi.org/1057/j.trb.2002.20.96>
- S. u. Islam ،G. Ahmed ،M. Shahid ،N. Hassan ،M. Riaz ،H. Jan و A. Shakeel ،"Implanted Wireless Body Area Networks: Energy Management, Specific Absorption Rate and Safety Aspects," *Ambient Assisted Living and Enhanced Living Environments* ٢٠١٧ ، <https://doi.org/1098/j.trb.2007.17.75>
- S. Zhang ،Y. Yang ،J. Xiao ،X. Liu ،Y. Yang ،D. Xie و Y. Zhuang ،"Fusing Geometric Features for Skeleton-Based Action Recognition using Multilayer LSTM Networks," *IEEE TRANSACTIONS ON MULTIMEDIA* ٢٠١٥ ، <https://doi.org/1035/j.trb.2008.28.77>
- S. Zhao ،Y. Zhang ،S. Wang ،B. Zhou و C. Cheng ،"A recurrent neural network approach for remaining useful life prediction utilizing a novel trend features construction method," *Measurement* ٢٠١٩ ، <https://doi.org/1077/j.trb.2010.12.25>
- T. Shu ،J. Chen ،V. K. Bhargava و C. W. d. Silva ،"An Energy-Efficient Dual Prediction Scheme Using LMS filter and LSTM in Wireless Sensor Networks for Environment Monitoring," *IEEE Internet of Things Journal* ٢٠١٩ ، <https://doi.org/1065/j.trb.2004.34.135>
- T. Zhang ،S. Song ،S. Li ،L. Ma ،S. Pan و L. Han ،"Research on Gas Concentration Prediction Models Based on LSTM Multidimensional Time Series," *Energies* ٢٠١٩ ، <https://doi.org/1039/j.trb.2021.5.53>
- V. Bhanumathi و C. P. Sangeetha ،"A guide for the selection of routing protocols in WBAN for healthcare applications," *Human-centric Computing and Information Sciences* ٢٠١٧ ، <https://doi.org/1018/j.trb.2014.16.94>
- T. Kuremoto ،S. Kimura ،K. Kobayashi و M. Obayashi ،"Time series forecasting using a deep belief network with restricted Boltzmann machines," *Neurocomputing* ٢٠١٣ ، <https://doi.org/1065/j.trb.2013.29.138>
- V. Abdolzadeh و N. Petra ،"Efficient Implementation of Recurrent Neural Network," *author Applications in Electronics Pervading Industry, Environment and Society* ٢٠١٨ ، <https://doi.org/1083/j.trb.2019.9.32>
- W. Bao ،J. Yue2 و Y. Rao ،"A deep learning framework for financial time series using stacked autoencoders and long-short term memory," *PLoS ONE* ٢٠١٧ ، <https://doi.org/1012/j.trb.2020.23.79>
- X. Yang ،S. Mao ،H. Gao ،Y. Duan و Q. Zou ،"Novel Financial Capital Flow Forecast Framework Using Time Series Theory and Deep Learning: A Case Study Analysis of Yu'e Bao Transaction Data," *IEEE Access* ٢٠١٩ ، <https://doi.org/1028/j.trb.2006.13.7>

- Y. Cheng ,Y. Ye ,M. Hou ,W. He ,Y. Li و X. Deng , "A Fast and Robust Non-Sparse Signal Recovery Algorithm for Wearable ECG Telemonitoring Using ADMM-Based Block Sparse Bayesian Learning," *sensors* ۲۰۱۸ ، <https://doi.org/1087/j.trb.2006.17.22>
- Y. Kawamura ,K. Murakami ,A. Santana ,T. Iizaka و T. Matsui , "Differential Evolutionary Particle Swarm Optimization based ANN Training for Estimation of Missing Data of Refrigerated Showcase," author 57th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE) ۲۰۱۸ ، <https://doi.org/1073/j.trb.2002.20.120>
- Y. Li ,H. Wu و H. Liu , "Multi-step wind speed forecasting using EWT decomposition, LSTM principal computing, RELM subordinate computing and IEWT reconstruction," *Energy Conversion and Management* ۲۰۱۸ ، <https://doi.org/1023/j.trb.2004.24.18>
- Y. Lv ,Y. Duan ,W. Kang ,Z. Li و F.-Y. Wang , "Traffic Flow Prediction With Big Data: A Deep Learning Approach," *IEEE TRANSACTIONS ON INTELLIGENT TRANSPORTATION SYSTEMS* ۲۰۱۴ ، <https://doi.org/1048/j.trb.2023.7.51>
- Y. Qu ,G. Zheng ,H. Ma ,X. Wang ,B. Ji و H. Wu , "A Survey of Routing Protocols in WBAN for Healthcare Applications," *sensors* ۲۰۱۹ ، <https://doi.org/1092/j.trb.2008.36.112>
- Y. Tian ,K. Zhang ,J. Li ,X. Lin و B. Yang , "LSTM-based Traffic Flow Prediction with Missing Data," *Neurocomputing* ، ۲۰۱۸. <https://doi.org/1081/j.trb.2016.27.58>
- Z. Gao ,W. Cheng ,X. Qiu و L. Meng , "A Missing Sensor Data Estimation Algorithm Based on," 2015. <https://doi.org/1097/j.trb.2009.27.12>
Available: <https://www.mathworks.com/content/dam/mathworks/tag-team/Objects/p/preprocessing-time-series-data-tips-and-tricks.pdf>. <https://doi.org/1085/j.trb.2015.23.107>
Available: <https://www.mathworks.com/campaigns/offers/deep-learning-with-matlab.html?elqCampaignId=10588>. <https://doi.org/1034/j.trb.2005.26.137>
Available: <https://www.mathworks.com/campaigns/offers/deep-learning-examples-with-matlab.html?elqCampaignId=10588>. <https://doi.org/1045/j.trb.2015.17.26>
Available: http://lab.fs.uni-lj.si/lasin/wp/IMIT_files/neural/NN-examples.pdf. <https://doi.org/1047/j.trb.2022.12.89>
Available: <http://www.heatonresearch.com/node/707>. <https://doi.org/1012/j.trb.2020.34.33>
۱. ابراهیمی، م. شمس‌ی و م. محجل، برآورد داده‌های ازدست‌رفته علائم حیاتی در شبکه‌های حسگر بی‌سیم بدن، ششمین کنفرانس ملی پژوهش‌های کاربردی در مهندسی برق، مکانیک و مکاترونیک، تهران، ۱۳۹۹.
- ف. کیم، یادگیری عمیق در MATLAB، نیاز دانش، ۱۳۹۶.
- ف. کیم، یادگیری عمیق با MATLAB همراه با یادگیری ماشین و شبکه‌های عصبی، انتشارات دانشگاهی کیان، ۱۳۹۶.
- غ. لطیف‌شگاهی، س. زعفرانچی و ک. اصلان‌صفت، "شبکه‌های حسگر بی‌سیم و کاربرد آنها در صنایع دریایی: توپولوژی‌ها، چالش‌ها و پیشنهادات"، در شانزدهمین همایش صنایع دریایی، ۱۳۹۳.
- م. فرنقی و ه. رحیمی، "پیش‌بینی مکانی-زمانی بارش ماهانه با استفاده از شبکه‌ی باور عمیق (مورد مطالعاتی: منطقه شمال غرب ایران)"، فصلنامه علوم و فنون نقشه برداری، ۱۳۹۶.
- م. مشیری، م. قادری زفرهایی و ف. قانع گل محمدی، "مقایسه دقت الگوریتم‌های یادگیری ماشین در تخمین داده‌های گمشده حاصل از آزمایش‌های ریزآرایه DNA، مجله پژوهش‌های سلولی و مولکولی (مجله زیست‌شناسی ایران)، ۱۳۹۴.