

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

بی‌سیم بدن

ابوالفضل ابراهیمی^۱

محبوبه شمسی^۲

مرتضی محجل^۳

چکیده

در شبکه‌های حسگری سیم به دلیل عوامل مختلفی از قبیل انژرژی محدود، قابلیت انتقال سنسورها، خرابی ساخت افزار و مشکلات شبکه‌مانند برخورد بسته‌ها، پیوند غیرقابل اطمینان و آسیب‌های غیرمنتظره، مقدار حسنه شده به سرخوشی یا ایستگاه پایه نمی‌رسد. بنابراین از بین رفتن داده‌ها در شبکه‌های حسگری سیم بسیار متداول است. از دست دادن داده‌های سنجیده شده، دقت WBAN را بسیار کاهش می‌دهد. برای حل این مشکل، داده‌های گم شده باید برآورد شوند. به منظور پیش‌بینی مقادیر گم شده، یک مدل برآورد داده از دست‌رفته براساس شبکه عصبی LSTM (حافظه کوتاه‌مدت) در این مقاله ارائه شده است. این مدل پنج علامت حیاتی را به عنوان ورودی برای پیش‌بینی مقدار از دست‌رفته ترکیب می‌کند. نتایج نشان می‌دهد که *sgdm-LSTM* روش خوبی برای برآورد مقدار از دست‌رفته 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 ۱۴۹۵/۴ است.

واژه‌های کلیدی: برآورد، داده از دست‌رفته، شبکه حسگری سیم بدن، شبکه عصبی مصنوعی، یادگیری عمیق

^۱ ebrahimi.a@qut.ac.ir

^۲ shamsi@qut.ac.ir

^۳ mohajjel@qut.ac.ir

^۲ (نویسنده مسئول)

^۳

مقدمه

متأسفانه بیماری‌های مزمن و کشنده مانند سرطان و بیماری‌های قلبی عروقی و آسم اغلب دیر تشخیص داده می‌شوند. درنتیجه، این موضوع میزان مرگ‌ومیر 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. علاوه‌براین، سیستم‌های سنتی نظارت، تصویر کاملی از وضعیت یک بیمار ارائه نمی‌دهند زیرا عملکردهای بدن خیلی کم کنترل می‌شود. این امر به دنبال سیستم‌های مقرر به صرفه‌تر و مقیاس‌پذیرتری 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 راه حل‌های اقتصادی برای سیستم‌های مراقبت‌های بهداشتی یافت. چنین فناوری‌هایی، ایده استفاده از ریزسنسورهای هوشمند با توان مصرفی پایین، میکروسنسورها و حسگرها را برای نمونه‌برداری 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، محدود کننده 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. علاوه‌براین، WBAN به بیماران امکان می‌دهد فعالیت‌های

عادی خود را بدون وقفه انجام دهندهای 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 بهداشت‌رساندن 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 تهدید کننده 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.

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 به عنوان یک سری اطلاعات متوالی در نظر گرفت. تاکنون روش‌های مختلفی برای برآورد داده‌های ازدست‌رفته در داده‌های سری زمانی زمینه‌های مختلف، توسعه یافته است. این روش‌ها را می‌توان به دو دسته تقسیم کرد: روش‌های آماری و روش‌های مبتنی بر یادگیری ماشین.

نویسنده‌گان [۲] یک الگوریتم برآورد داده ازدست‌رفته در شبکه wsn با استفاده از الگوریتم کانزدیکتورین 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 به طور مشترک به جای مستقل استفاده می‌کنند. از آنجاکه روش پیشنهادی مبتنی بر همبستگی مکانی داده‌های حسگر برای تخمین داده‌های ازدست‌رفته و مدل خطی توسط الگوریتم اتخاذ شده است، هنگامی که داده‌های حسگر گره‌های مختلف کاملاً خطی باشد، بهترین عملکرد را خواهد داشت.

یکی از محسن 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 به خوبی تخمین بزند و از این رو وقتی اندازه نمونه زیاد نباشد، عملکرد خوبی خواهد داشت حتی اگر داده‌های سنسور به طور صحیح به صورت خطی نباشد.

نویسنده‌گان [۱] الگوریتم برآورد داده‌های ازدست‌رفته حسگرها براساس همبستگی فضایی و زمانی ارائه کردند. این الگوریتم اطلاعات مربوطه را به عنوان نمونه تجزیه و تحلیل انتخاب می‌کند و تضمین می‌کند که هیچ نمونه‌ای از داده‌های بیش از حد وجود نداشته باشد و نمونه قوی ترین ارتباط را با داده‌های گم شده داشته باشد. در مرحله اول، تمام داده‌های سنجش شده همزمان با یک سری زمانی را ذخیره می‌کند و مرتبط‌ترین سری‌ها به عنوان نمونه تجزیه و تحلیل انتخاب می‌شوند که به طور قابل توجهی کارآیی و دقت الگوریتم را بهبود می‌بخشد. ثانیاً مقادیر ازدست‌رفته را از ابعاد زمانی و مکانی تخمین می‌زنند. وزن‌های مختلفی به این دو بعد اختصاص داده شده است. الگوریتم یادشده رابطه بین صفات را در نظر نگرفته است.

نویسنده‌گان [۳] از فرآیندهای گاووسی یادگیری ماشین برای پیش‌بینی داده‌های ازدست‌رفته در شبکه حسگرها بی‌سیم بدن، استفاده کردند. الگوریتم انتخاب شده برای مدل‌سازی و پیش‌بینی، الگوریتم N4SID مبتنی بر فضای حالت است. این الگوریتم در صورت تنظیم دقیق پارامترهای یادگیری ماشین دقت بالایی ارائه می‌دهد.

نویسنده‌گان [۴] روشی با تحلیل پویای فاکتور فراموشی متغیر برای شبکه‌های حسگر به سیم با داده‌های گم شده به صورت 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 شده است 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.

نویسنده‌گان [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 گم شده در شبکه حسگر بی‌سیم با استفاده از همبستگی فضایی و زمانی را ارائه دادند که نسبت به متدهای خطا knn دقت بالاتری دارد. اما دقت وابسته به تعداد نودهای همسایه است. پس از استقرار گره‌های حسگر، تشکیل خوشۀ صورت می‌گیرد که منجر به ایجاد خوشۀایی از آن گره‌های حسگر می‌شود که از لحاظ زمانی و مکانی باهم ارتباط دارند. بعد از تشکیل خوشۀ، گره‌های حسگر داده‌ها را حس می‌کنند و آنها را به سرخوشۀ می‌فرستند. سرخوشۀ داده‌های سنجش شده را جمع‌آوری کرده، پردازش کرده و برای گره سینک می‌فرستد. اگر سرخوشۀ، از دست داده‌های هر یک از اعضای خود را شناسایی کند سپس سرخوشۀ از PSTC برای پیش‌بینی مقدار از دست‌رفته استفاده می‌کند.

نویسنده‌گان [۵] از روش هموارسازی نمایی مرتبه دوم و آنالیز رگرسیون خطی برای پیش‌بینی داده‌های ازدست‌رفته در شبکه حسگرها بی‌سیم استفاده کردند. به این صورت که الگوریتم از روش هموارسازی نمایی مرتبه دوم برای تخمین داده‌های گم شده در ابعاد زمانی و از آنالیز رگرسیون خطی چند گانه برای تخمین ارزش‌های گم شده در فضا استفاده می‌کند. پیچیدگی زمانی الگوریتم کم و دقیق 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. به‌منظور برآورد داده‌های ازدست‌رفته، دو الگوریتم با وزن‌های مختلف ادغام می‌شوند. بردار وزنی با کمترین جمع مربعات خطاهای به‌دست می‌آید و سپس نتیجه برآورد نهایی به‌دست 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 پرسون برای یافتن ارتباط بین گره‌ها استفاده می‌کنیم. پس از به‌دست آوردن ضریب همبستگی، ضریب رگرسیون با استفاده از روش حداقل مربعات به‌دست 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 برآورده را پیدا کند که مجموع مربعات خطاهای را به حداقل برساند. نویسنده‌گان [۷] روش یادگیری فرهنگ لغت انطباقی به روز را برای بازسازی اطلاعات گم شده در شبکه حسگرها 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 جمع آوری می‌شود. علاوه‌بر این، به‌منظور دستیابی به ویژگی‌های مدام داده‌های حسگر در زمان واقعی، یک الگوریتم به روزرسانی 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 به روزرسانی 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 به‌دست 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. نویسنده‌گان [۸] از کدگذاری شبکه همکاری به منظور بازیابی داده‌ها در شبکه حسگرهای بی‌سیم بدن استفاده کردند. آنها با روش پیشنهادی اشان با کاهش زمان انتقال مجدد اطلاعات، از تک نقاط شکست جلوگیری می‌کنند. ارتباطات مشترک در WBAN یک راه حل 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 درنظر گرفته شده برای یک مقصد خاص را بشنوند، سیگنال را پردازش کرده و به مقصد موردنظر موردنظر منتقل کنند. سیگنال‌هایی که از رله‌ها و منبع دریافت می‌شوند در مقصد موردنظر 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 به عنوان رله‌هایی است که می‌توانند برای افزایش کارآیی سیستم همکاری کنند.

ارتباط همکاری با کدگذاری شبکه بر روی به حداقل رساندن تعداد انتقال سیگنال‌های یک رله منفرد است. سیگنال‌هایی که در یک رله منفرد دریافت می‌شوند به صورت خطی ترکیب شده و درنتیجه فقط یک سیگنال تولید می‌شود و سپس به مقصد منتقل می‌شود. بنابراین هر رله برای ارسال سیگنال خود فقط به یک اسلاط 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 دریافت شده رمزگشایی می‌کند. در انواع رمزگشایی و طرح‌های ارتباطی مبتنی بر جلو، گره‌های رله باید ابتدا پیام منع 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 منع مفید هستند. با افزایش تعداد گره‌های منع،

گره‌های رله نیاز به پردازش زیادی دارند که انرژی انتقال زیادی را مصرف می‌کند. نویسنده‌گان [۹] با استفاده از شبکه‌های عصبی مصنوعی، داده‌های گم شده 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 ویترین 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 به عنوان داده ورودی و داده هدف، مشخصات داده‌ها را با توجه به ویژگی‌های سری زمانی بیاموزد. یکتابع سیگموئید برای سلول‌های عصبی در توابع فعال‌سازی لایه پنهان استفاده می‌شود. خطای میانگین مربع به عنوان تابع از دست دادن استفاده می‌شود. ANN پارامترهای مناسب برای تخمین داده‌های از دست رفته ویترین را با استفاده از داده‌های اندازه پنجره گذشته به عنوان ورودی و داده‌های پنجره بعدی به عنوان داده‌های هدف یاد می‌گیرد. وقتی تکرار یادگیری به تعداد تکرار از پیش تعیین شده می‌رسد، یادگیری متوقف می‌شود. اگر هنگام اندازه گیری داده‌های ویترین آنلاین، اطلاعات از دست رفته وجود داشته باشد، داده‌های از دست رفته با استفاده از ANN آموخته شده تخمین زده می‌شود. داده‌های از دست رفته 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. نویسنده‌گان [۱۰] با استفاده از تکرار درخواست، بخش شامل داده خراب را مجدداً 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 دقیق‌تر بالاتری دارند. طرح پیشنهادی هنگامی که وضعیت کanal 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 درنتیجه، 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 پیش‌فرض IEEE 802.15.4 ARQ فراهم می‌کند. نویسنده‌گان [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 راه حل‌های با کیفیت بالاتر از PSO های معمولی تولید کند. DEEPSO از معادلات به روزرسانی مختلف مانند تصویر زیر استفاده می‌کند:

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

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

تولیدمثل: فرزندان $1 + R$ (اصلی و کلون‌ها) با معادلات مربوطه به روز می‌شوند.

ارزیابی: مقدار تابع هدف به همه فرزندان محاسبه می‌شود.

انتخاب: فرزندان تشکیل‌دهنده 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 شده‌است و ANN مقادیر اندازه‌گیری شده، اندازه‌پنجره را به عنوان داده ورودی و مقدار اندازه‌گیری شده بعدی را به عنوان داده هدف می‌آموزد. علاوه بر این، مقدار تابع هدف با استفاده از پارامترهای به روز شده توسط DEEPSO محاسبه می‌شود و پارامترها براساس فرآیندهای مربوطه به روز می‌شوند. یک تابع

خطای مربع میانگین به عنوان یکتابع هدف استفاده می‌شود. وقتی داده از دست می‌رود، مقادیر از دست رفته را می‌توان با استفاده از مقادیر اندازه‌گیری شده اندازه پنجره به عنوان داده ورودی تخمین زد. یکتابع سیگموئید به عنوان تابع فعال‌سازی ANN استفاده می‌شود. علاوه بر این، برای هر سنسور ویترین یکمدل ANN سه لایه آماده شده است.

نویسنده‌گان [۱۲] با استفاده از یادگیری عمیق، یکمدل خطی برای پیش‌بینی مشاهدات مفقودشده جریان ترافیک از طریق ترکیب اطلاعات زمانی مقیاس‌های مختلف ارائه می‌کنند که دقیق‌تری نسبت به روش‌های مشابه دارد. الگوهای مختلف داده‌های از دست رفته را تجزیه و تحلیل می‌کنند و یکروش پیش‌بینی جدید که ویژگی‌های هر الگو را ترکیبی می‌کند، طراحی می‌کنند. علاوه بر این، با ترکیب صریح الگوی از دست رفته 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 وقی خاتمه یابد که به حداقل تعداد دوره (در این مورد ۱۰ دوره) برسد. در پژوهش قبلی [۷۰] به مدل مناسب شبکه عصبی عمیق، برای برآورد داده‌های از دست رفته ضربان قلب دست پیدا کردیم. در این پژوهش با بهم ریختن ترتیب ورود داده‌ها در هنگام آموزش شبکه و همچنین مقایسه با روش مشابه در تخمین داده‌های از دست رفته با استفاده از شبکه عصبی عمیق [۶۹]، به پارامترهای بهینه شبکه عصبی عمیق در مورد مجموعه داده خواهیم رسید.

روش‌شناسی پژوهش 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.

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.

نمونه پژوهش

به علت حجم زیاد داده‌ها و دشواربودن 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.

پیش پردازش 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 نداشیم، با نزدیکترین مقدار جایگزین می‌کنیم. همچنین اگر باز هم داده‌ای نداشیم مقدار هریک از علائم حیاتی را با مقادیر ثابت زیر جایگزین می‌کنیم که میانگین کل مقادیر مشاهده شده در دیتاست است:

Hr=91, Resp=20, Spo2=100
Abps=121, Abpd=62, Abpm=81

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.

ابزارهای مورد استفاده در پژوهش

با بررسی مقالات پیرامون موضوع این پژوهش، نرم‌افزار متلب به عنوان 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.

پارامترهای ارزیابی

سه معیار برای ارزیابی کارآیی 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.

$$\begin{aligned} RMSE &= \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \\ MAE &= \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i| \\ MAPE &= \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i - \hat{x}_i}{x_i} \right| \times 100 \end{aligned}$$

MAE اندازه متوسط خطاهای از پیش‌بینی‌ها، بدون درنظر گرفتن جهت آنها، اندازه گیری می‌کند. این برای متغیرهای پیوسته دقیق‌تر است. MAE نمره خطی است به این معنی که تمام تفاوت‌های فردی به طور مساوی در میانگین وزنی است.

RMSE یک قانون امتیازدهی درجه دوم است که مقدار متوسط خطای اندازه گیری می‌کند. از آنجایی که خطاهای 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 به خصوص 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 خطاهای 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.

مدل استفاده شده

مدل استفاده شده برای شروع الگوریتم، مطابق مقاله پایه [۶۶] و به صورت زیر خواهد

پوڈ:

جدول ۱. پارامترهای اولیه مدل استفاده شده

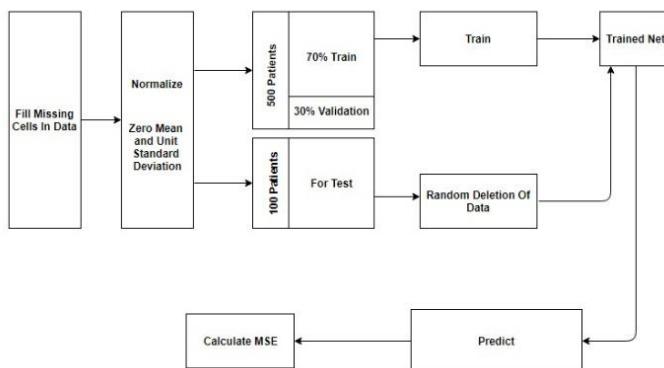
مرحله	توضیحات	تعداد واحداها
۱	Input Layer	6
۲	Lstm Layer	150
۳	Fully Connected Layer 1	50
۴	DropOut Layer	٠/٥
۵	Fully Connected Layer 2	1
٦	Regression Layer	1

جزئیات روش پیشنهادی

روند کلی کار بدنی 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 نشده است و برای به دست 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

به طور تصادفی برخی خروجی موردنظر داده‌های تست را حذف می‌کنیم. درنهایت با استفاده از شبکه آموزش دیده مقادیر ازدست رفته را پیش‌بینی می‌کنیم و با مقادیر موردنظر مقایسه می‌کنیم تا خطای مدل به دست آید.



شکل ۱. روند کار

فاز اول) ورود داده‌ها و پر کردن 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

فاز دوم) نرمال سازی 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]-mean)/sig
7.   Return Train & Test & Validation Data

```

شکل ۳. فاز دوم

فاز سوم) آموزش شبکه

در این فاز پس از تنظیم ابرپارامترهای شبکه، شبکه را با داده‌های آموزش تعلیم می‌دهیم. درنهایت 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

فاز چهارم) پیش‌بینی مقادیر ازدست‌رفته

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

```

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

```

شکل ۵. فاز چهارم

فاز پنجم) محاسبه مقادیر خطأ

در این فاز، تک تک مقادیر پیش‌بینی شده را با مقادیر موردنظر مقایسه می‌کنیم و خطای مدل را به دست می‌آوریم و برای محاسبه خطای کل از میانگین خطاهای 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

تنظیم ابرپارامترها

شبکه‌های عصبی مصنوعی دارای دو فرآپارامتر 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.

یافته‌های پژوهش

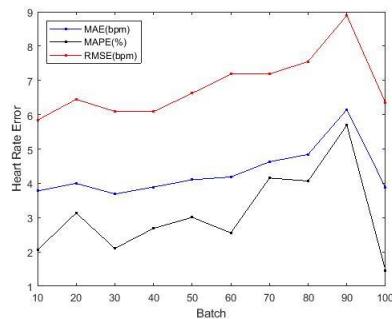
با توجه به این که الگوریتم یادگیری عمیق نیاز به یک سری فرآپارامترها برای دقت بیشتر نیاز دارد، ابتدا یک پارامتر را متغیر و مابقی پارامترها را ثابت درنظر می‌گیریم و برای بررسی تاثیر متغیر از خطای مربعات استفاده می‌کنیم و کمترین خطای را به عنوان هدف درنظر می‌گیریم تا مقدار بهینه پارامتر به دست آید. تاثیر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

در این بخش چند سناریو برای بررسی و ارزیابی روش پیشنهادی استفاده می‌شود که

هر کدام به طور کامل شرح داده می‌شوند و نتایج آنها نشان داده می‌شود.

سناریوی اول: تاثیر افزایش BatchSize

تمامی پارامترهای شبکه بجز BatchSize، ثابت درنظر گرفته شده‌اند.



شکل ۲. تاثیر

همانطور که در شکل ۷ مشخص است، کمترین خطأ مربوط به batchsize با مقدار ۱۰ است. همچنین نمودار شبیه صعودی دارد ولی در مقدار ۲۰ بهدلیل عدم سسته‌بندی مناسب داده‌ها مقدار ناگهان افزایش داشته است. همچنین در مقدار ۹۰ بهدلیل عدم سسته‌بندی مناسب داده‌ها این اتفاق دوباره تکرار شده است.

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 راه حل‌های 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.

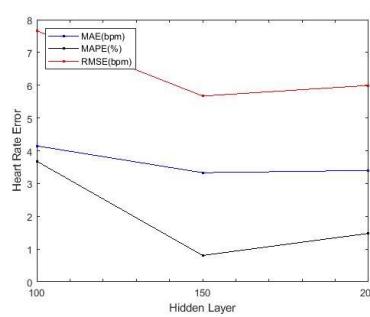
جدول ۲. تاثیر

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 درنظر می‌گیریم.

سناریوی دوم: تأثیر افزایش لایه‌های پنهان لایه Lstm
در این آزمایش بجز تعداد لایه‌های پنهان بقیه موارد ثابت درنظر گرفته شده‌اند.



شکل ۸. تأثیر لایه پنهان

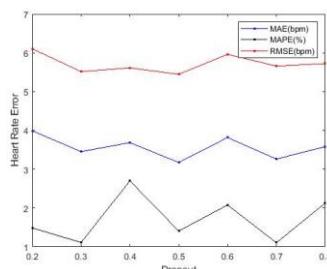
این نمودار شبیه نزولی دارد ولی به صورت کلی افزایش مقدار لایه‌ها منجر به خطای بیشتر می‌شود. افزایش لایه‌های پنهان بیش از تعداد کافی باعث کاهش دقت در مجموعه تست می‌شود چون باعث می‌شود شبکه با مجموعه آموزش مطابقت داشته باشد اما نمی‌تواند به داده‌های جدید تعمیم یابد.

جدول ۳: تأثیر 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 بدست آمده تعداد لایه‌های پنهان برای بقیه مراحل ۱۵۰ درنظر گرفته می‌شود.

سناریوی سوم: تأثیر افزایش dropout
در این مرحله فقط dropout را تغییر می‌دهیم و به سایر پارامترها کاری نداریم.



شکل ۹. تأثیر dropout

همانطور که در شکل ۹ پیداست با افزایش dropout تا 0.5% خطای کاهش داشته اما بعد از مقدار 0.5% مجدداً افزایش خطای خواهیم داشت. این بدان معنی است که در مقدار 0.5% بالاترین واریانس را برای این توزیع داشته‌ایم.

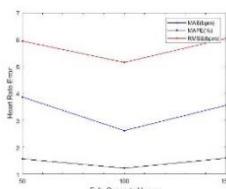
Dropout با حذف احتمالی یا رها کردن ورودی‌های یک لایه کار می‌کند که ممکن است متغیرهای ورودی در نمونه داده یا فعال‌سازی‌های یک لایه قبلی باشد. این اثر شبیه‌سازی تعداد زیادی از شبکه‌ها با ساختار شبکه بسیار متفاوت است و به نوبه خود باعث می‌شود که گره‌های شبکه به طور کلی ورودی‌های بیشتری داشته باشند. به صورت تجربی مقدار خوب برای dropout در یک لایه مخفی بین 0.5% تا 0.8% است.

جدول ۴. تأثیر dropout

lstm batch=10; lstm hidden unit=150; Fully Connected Input=150				
Dropout	Time	RMSE	MAE	MAPE
$0/2$	---	6.1048	3.9898	1.4867
$0/3$	---	5.5148	3.4520	1.1101
$0/4$	---	5.6118	3.6856	2.6985
$0/5$	---	5.4459	3.1728	1.4051
$0/6$	---	5.9611	3.8165	2.0784
$0/7$	---	5.6573	3.2605	1.1050
$0/8$	---	5.7242	3.5815	2.1259

با توجه به نتایج، مقدار 0.5% را برای dropout در نظر می‌گیریم.

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 داشته است ولی به دلیل overfitting بعد از این مقدار شاهد افزایش خطای باشیم. افزودن یک لایه کاملاً متصل (معمولًا 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.

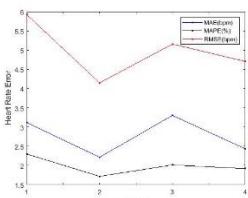
جدول ۵. تاثیر لایه‌های fullyconnected

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.

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 خطای کاهش می‌یابد ولی با بیش از ۳ لایه به دلیل overfitting علاوه‌بهبودی در پیش‌بینی و کاهش خطای نداریم.

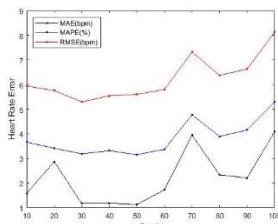
جدول ۶. تاثیر لایه lstm

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 متواتی 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 بهمنریختن ترتیب ورود داده انجام می‌دهیم.

سناریوی ششم: تاثیر افزایش BatchSize

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



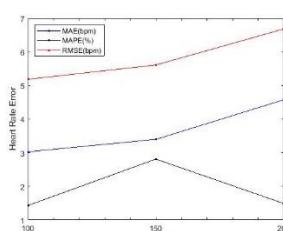
شکل ۱۲ . تأثیر batchsize

جدول ۷ . تأثیر 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.

سناریوی هفتم: تأثیر افزایش لایه‌های پنهان لایه Lstm
بجز تعداد لایه‌های پنهان، سایر موارد ثابت در نظر گرفته شده‌اند.



شکل ۱۳ . تأثیر لایه پنهان

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

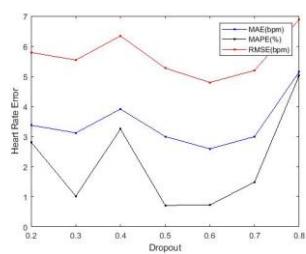
جدول ۸. تأثیر لایه پنهان

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 به دست آمده تعداد لایه‌های پنهان برای بقیه مراحل، ۱۰۰ در نظر گرفته می‌شود.

سناریوی هشتم: تأثیر افزایش dropout

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



شكل ۱۴. تأثیر dropout

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

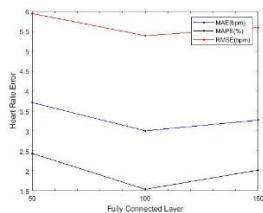
جدول ۹. تأثیر dropout

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.

سناریوی نهم: تاثیر افزایش تعداد لایه خروجی لایه FullyConnected

در این سناریو، با ثابت درنظر 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 داشته است ولی به دلیل بعد از این مقدار شاهد افزایش خطأ overfitting می‌باشیم.

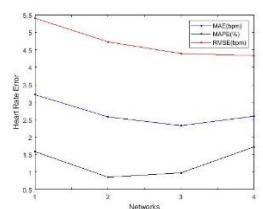
جدول ۱۰. تاثیر لایه‌های fullyconnected

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.

سناریوی دهم: تاثیر افزایش لایه‌های متواالی 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 خطأ کاهش می‌یابد.

جدول ۱۱. تأثیر 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، بُهْبُودی در خطا صورت نگرفت ولی روند نمودارها ساختارمند شد.

نتیجه‌گیری و پیشنهادها

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

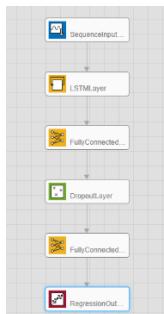
برای مقایسه مدل پیشنهای با شبکه عصبی، از یک شبکه عصبی ساده با ۲ لایه پنهان با ۵ نورون در هر لایه استفاده می‌کنیم. مدل پیشنهادی را با مدل شبکه عصبی غیرخطی خودکاهشی نیز مقایسه می‌کنیم که ۱۰ لایه پنهان دارد.



شکل ۱۷. معماری نهایی

معماری نهایی مدل ما شکل ۱۷ خواهد بود که پس از سناریوهای مختلف و بررسی کمینه خطابه 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

فعال ساز ReLU، تشکیل شده است. همچنین مقدار BatchSize در این مدل ۱۲۸ و مقدار epoch 100 در نظر گرفته شده است. از آنجاکه الگوریتم SGD سرعت همگرایی کندتری دارد و در همان زمان پیش‌بینی نتیجه مستعد نوسان است، بنابراین adam به عنوان بهینه‌ساز در این مقاله انتخاب شده است.



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 ۱۱-۴ 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)	9752	50	4738	8383	616
PredictTime(Secs)		8	32	34	5

با توجه به نتایج، روش پیشنهادی ما دقیق‌تری نسبت به سایر روش‌ها دارد اما شبکه عصبی مصنوعی نیاز به زمان بسیار کمتری برای آموزش شبکه دارد. شبکه‌های حسگر بی‌سیم بدن در نظارت بر سلامت و تشخیص بسیاری از بیماری‌ها کاربرد دارند. این شبکه‌ها با مشکلاتی روبرو هستند. یکی از این مشکلات، از دست رفتن مقادیر می‌باشد و بدلیل 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 خطای برای این کار را ارائه دهیم. روش پیشنهادی به طور 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 $dstm$ ۱۰۰ می‌باشد. همچنین میزان $dropout$ شبکه $0/5$ می‌باشد. روش مناسب برای پیش‌بینی مقادیر ازدست‌رفته استفاده از sgdm-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 ابرپارامترهای شبکه، دقت بالاتری نسبت به سایر روش‌ها در تخمین مقادیر دارد.

منابع

- [1] 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." تألیف Sixth Post Graduate Conference for Computer Engineering (cPGCON 2017) Procedia ,۲۰۱۷.
- [2] A. B. Islam .D. Costinett و S. K. Islam ."Wireless Power Transfer, Recovery, and Data Telemetry for Biomedical Applications." تألیف Handbook of Biochips, ۲۰۱۷ .
- [3] B. Kim .B. Lee و J. Cho ."ASRQ: Automatic Segment Repeat reQuest for IEEE 802.15.4-based WBAN." IEEE SENSORS JOURNAL , ۲۰۱۶.
- [4] 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 , ۲۰۱۵.
- [5] 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 ۲۰۱۳ .
- [6] 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 , ۲۰۱۷.
- [7] 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 ۲۰۱۷ .
- [8] D. Sow .D. S. Turaga و M. Schmidt ."MINING OF SENSOR DATA IN HEALTHCARE: A SURVEY." تألیف Managing and Mining Sensor Data , ۲۰۱۲.
- [9] 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, ۲۰۱۹ .
- [10] D. Yu , L. Deng .Deep Learning: Methods and Applications ۲۰۱۴ .
- [11] E. Cadenas .W. Rivera .R. Campos-Amezcua و C. Heard ."Wind Speed Prediction Using a Univariate ARIMA Model and a Multivariate NARX Model." energies , ۲۰۱۶.
- [12] 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), ۲۰۱۷ .

- [13] F. Hu , X. Liu ,M. Shao ,D. Sui و L. Wang , "Wireless Energy and Information Transfer in WBAN: An Overview," IEEE Network ۲۰۱۷ .
- [14] 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 , ۲۰۱۹ .
- [15] F. Rundo , "Deep LSTM with Reinforcement Learning Layer for Financial Trend Prediction in FX High Frequency Trading Systems," Applied Sciences, ۲۰۱۹ .
- [16] F. V. Nelwamondo ,Computational Intelligence Techniques for Missing Data Imputation, ۲۰۰۸ .
- [17] 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 ۲۰۱۲ .
- [18] 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 , ۲۰۱۶.
- [19] 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 ۲۰۱۷ .
- [20] 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 ۲۰۱۹ .
- [21] 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 , ۲۰۱۸ .
- [22] I. Ha , "Technologies and Research Trends in Wireless Body Area Networks for Healthcare: A Systematic Literature Review," International Journal of Distributed Sensor Networks ۲۰۱۵ .
- [23] 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 . 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 .
- [24] 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 .

- [25] 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," ۲۰۱۷ IEEE International Symposium on Circuits and Systems (ISCAS) ۲۰۱۷ .
- [26] J. Pagán , "Robust and Accurate Modeling Approaches for Migraine Per-Patient Prediction from Ambulatory Data," 2015.
- [27] K. C. Shekar و 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 .
- [28] K. W. Minmin Luo , "Heart rate prediction model based on neural network," تألیف IOP Conference Series: Materials Science and Engineering ۲۰۲۰ .
- [29] 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 .
- [30] L. Pan , J. Li , "K-Nearest Neighbor Based Missing Data Estimation Algorithm," pp. 115-122 ۲۰۱۰ .
- [31] L. Zhao , F. Zheng , "Missing Data Reconstruction Using Adaptively Updated Dictionary in Wireless Sensor Networks," تألیف Proceeding of science ۲۰۱۷ .
- [32] 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," ۲۰۱۷ IEEE/ACM International Conference on Connected Health: Applications, Systems and Engineering Technologies (CHASE) ۲۰۱۷ .
- [33] 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 .
- [34] 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 .
- [35] 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 .
- [36] Q. Zhen و T. Zhang , "A Missing Data Estimation Algorithm in Wireless Sensor Networks," Boletín Técnico ۲۰۱۷ .

- [37] 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) ۲۰۱۷ .
- [38] 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 ۲۰۱۹ .
- [39] S. Ghazal ,M. Sauthier ,D. Brossier ,W. Bouachir ,P. Jouvet 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 ۲۰۱۹ .
- [40] S. M. Demir ,F. Al-Turjman و A. Muhtaroğlu , "Energy Scavenging Methods for WBAN," IEEE Sensors Journal ۲۰۱۸ .
- [41] 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 ۲۰۱۹ .
- [42] 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 ۲۰۱۷ .
- [43] 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 ۲۰۱۵ .
- [44] 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 ۲۰۱۹ .
- [45] 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 ۲۰۱۹ .
- [46] 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 ۲۰۱۹ .
- [47] 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 ۲۰۱۷ .
- [48] T. Kuremoto ,S. Kimura ,K. Kobayashi و M. Obayashi , "Time series forecasting using a deep belief network with restricted Boltzmann machines," Neurocomputing ۲۰۱۳ .

- [49] V. Abdolzadeh و N. Petra ."Efficient Implementation of Recurrent Neural Network." author Applications in Electronics Pervading Industry, Environment and Society ۲۰۱۸ ..
- [50] 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 ۲۰۱۷ ..
- [51] 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 ۲۰۱۹ ..
- [52] 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 ..
- [53] 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 ۵۷ th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE) ۲۰۱۸ ..
- [54] 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 ..
- [55] 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 ..
- [56] 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 ..
- [57] Y. Tian ,K. Zhang ,J. Li ,X. Lin و B. Yang ."LSTM-based Traffic Flow Prediction with Missing Data." Neurocomputing ۲۰۱۸ ..
- [58] Z. Gao ,W. Cheng ,X. Qiu و L. Meng ."A Missing Sensor Data Estimation Algorithm Based on." 2015.
- [59] [متصل]. Available: <https://www.mathworks.com/content/dam/mathworks/tag-team/Objects/p/preprocessing-time-series-data-tips-and-tricks.pdf>.
- [60] [متصل]. Available: <https://www.mathworks.com/campaigns/offers/deep-learning-with-matlab.html?elqCampaignId=10588>.
- [61] [متصل]. Available: <https://www.mathworks.com/campaigns/offers/deep-learning-examples-with-matlab.html?elqCampaignId=10588>.
- [62] [متصل]. Available: http://lab.fs.uni-lj.si/lasin/wp/IMIT_files/neural/NN-examples.pdf.

[63]. Available: <http://www.heatonresearch.com/node/707>. [متصل]

[۶۴] ا. ابراهیمی، م. شمسی و م. محجل، برآورد داده‌های ازدست‌رفته علامت حیاتی در شبکه‌های حسگر بی‌سیم بدن، ششمین کنفرانس ملی پژوهش‌های کاربردی در مهندسی برق، مکانیک و مکاترونیک، تهران، ۱۳۹۹.

[۶۵] ف. کیم، یادگیری عمیق در MATLAB، نیاز داشت، ۱۳۹۶.

[۶۶] ف. کیم، یادگیری عمیق با MATLAB همراه با یادگیری ماشین و شبکه‌های عصبی، انتشارات دانشگاهی کیان، ۱۳۹۶.

[۶۷] غ. لطیف شبگاهی، س. زعفرانچی و ک. اصلاح صفت، "شبکه‌های حسگر بی‌سیم و کاربرد آنها در صنایع دریابی: توپولوژی‌ها، چالش‌ها و پیشنهادات"، در شانزدهمین همایش صنایع دریابی، ۱۳۹۳.

[۶۸] 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.

[۶۹] م. مشیری، م. قادری زفرهایی و ف. قانع گل محمدی، "مقایسه دقیق الگوریتم‌های یادگیری ماشین در تخمین داده‌های گمشده حاصل از آزمایش‌های ریزآرایه DNA؛ مجله پژوهش‌های سلولی و مولکولی (مجله زیست‌شناسی ایران)، ۱۳۹۴.

استناد به این مقاله:

رضایی مقدم، سعید؛ دوستی، اسلام. (۱۴۰۰). «تنظیم بهینه پارامترهای شبکه عصبی عمیق در برآورد داده‌های ازدست‌رفته علامت حیاتی در شبکه‌های حسگر بی‌سیم بدن». مدیریت مهندسی و ریانش نرم، ۹(۱)، ۲۵۳-۲۸۷.

Investigating the impact of implementation ISO 9000 on Inventory of Supply Chain

Reza Baradaran Kazemzadeh¹

Abstract

ISO 9000 is an international quality management standard that introduced as key criteria for assessing suppliers, a possibility for international trade, and a requirement for government bids in many countries. Moreover, implementing this standard positively affected processes and internal communication in supply chain organizations. Inventory also plays an important role in cost management in supply chains. It seems that the implementation of this standard could improve inventory indexes in the supply chains. In this paper, 39 companies in the stock market of Iran were used to assess by two indexes of inventory return and inventory to working capital to recognize the effects of ISO 9000 on the supply chain. Results indicated that ISO 9000 had no positive effect on inventory turnover and just caused some minor improvement on inventory to capital turnover in the investigated companies.

Keywords: Automotive Supply chain, Financial Indexes, Inventory turnover, ISO 9000

¹ Professor of Technology Management Faculty of Industrial and Systems Engineering Tarbiat Modares University
(Corresponding Author) rkazem@gmail.com