



بهبود الگوریتم بر آورد داده‌های ازدست‌رفته علائم حیاتی در شبکه‌های حس گر بی سیم بدن مبتنی بر شبکه عصبی عمیق

ابوالفضل ابراهیمی^۱، محبوبه شمسی^{۲*}، مرتضی محجل^۳

کارشناس ارشد مهندسی برق و کامپیوتر، دانشگاه صنعتی قم، قم، ایران^۱

دانشیار دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی قم، قم، ایران^{۲*}

استادیار دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی قم، قم، ایران^۳

چکیده

در شبکه‌های حس گر بی سیم به دلیل عوامل مختلفی از قبیل محدود بودن انرژی، قابلیت انتقال حس گرها، خرابی سخت افزار و مشکلات شبکه مانند برخورد بسته‌ها، پیوند غیر قابل اطمینان و آسیب‌های غیرمنتظره، مقدار حس شده به سرخوشه یا ایستگاه پایه نمی‌رسد؛ بنابراین از بین رفتن داده‌ها در شبکه‌های حس گر بی سیم بسیار متداول است. از دست دادن داده‌های سنجیده شده، دقت WBAN را بسیار کاهش می‌دهد. از آنجا که WBAN با علائم حیاتی بدن انسان سروکار دارد، قابلیت اطمینان شبکه از اهمیت زیادی برخوردار است. برای حل این مشکل، داده‌های گم شده باید برآورد شوند. به منظور پیش‌بینی مقادیر گم شده، یک مدل برآورد داده ازدست‌رفته بر اساس شبکه عصبی بازگشتی LSTM که وزن‌های شبکه به وسیله الگوریتم ازدحام ذرات (PSO) بهینه شده‌اند، در این مقاله ارائه شده است. نتایج نشان می‌دهد sgd-m-LSTM با ترکیب PSO 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 ابر پارامترهای شبکه LSTM و بهترین مقادیر برای الگوریتم PSO، ۱.۵۸۹۸ است.

واژگان کلیدی: برآورد، داده ازدست‌رفته، شبکه حس گر بی سیم بدن، شبکه عصبی مصنوعی، یادگیری عمیق.

Improvement of missing vital signs data estimation algorithm in wireless body sensor networks based on deep neural networks

Aboulfazl Ebrahimi¹, Mahboubeh Shamsi^{2*}, Morteza Mohajjel³

Master student of computer engineering Qom University of Technology, Qom, Iran^{*1}

Associate professor of Qom university of technology, Qom, Iran²

Assistance professor of Qom university of technology, Qom, Iran³

Abstract

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. Many methods are used to reconstruct lost sensor data based on temporal correlation, spatial correlation, interpolation method, or sparse theory. Due to the characteristics of vital signs data, they can be considered as a series of sequential information. So far, various methods have been developed to estimate missing data in time series data in different fields. These methods can be divided into two categories: statistical methods and machine learning-based methods. In order to predict missing values, a missing data estimation model based on LSTM recurrent neural network whose network weights are optimized by particle swarm algorithm (PSO) is presented in

* Corresponding author

* نویسنده عهده‌دار مکاتبات

this paper. In this paper, we use the MIMIC-III Waveform database to test the algorithm and determine the algorithm parameters. However, due to the large volume of data and the difficulty of testing the algorithm on all data, we suffice to test 500 patients with this data, whose vital signs included heart rate, respiration, blood oxygen, and so on. After data preprocessing, network training, predicting lost values and calculating error values, it is observed that the proposed technique of sgdm-LSTM By combining the PSO algorithm is a suitable method for estimating lost values. In addition, experimental results show that the mean square root error of the estimated value is lower than other methods. This value is 1.5898 with the best LSTM network hyperparameters.

Keywords: WBAN, Deep Learning, Artificial Neural Network, Missing Data, Estimation.

۱- مقدمه

متأسفانه، اغلب بیماری‌های مزمن و گشوده مانند سرطان و بیماری‌های قلبی عروقی و آسم دیر تشخیص داده می‌شوند؛ در نتیجه، این موضوع میزان مرگ‌ومیر افرادی را که به چنین بیماری‌هایی مبتلا هستند، افزایش می‌دهد. تشخیص زودرس، اثر این‌گونه بیماری‌ها را کاهش و امید به زندگی افراد مبتلا را افزایش می‌دهد.

تشخیص‌ن دادن زودرس و نظارت مؤثر بر بیماری‌ها، هزینه مراقبت‌های بهداشتی را افزایش می‌دهد و بار زیادی به سامانه‌های مراقبت‌های بهداشتی با منابع مالی محدود می‌افزاید؛ علاوه بر این، سامانه‌های سنتی نظارت، تصویر کاملی از وضعیت یک بیمار ارائه نمی‌دهند؛ زیرا عملکردهای بدن خیلی کم کنترل می‌شود. این امر به دنبال سامانه‌های مقرون به صرفه‌تر و مقیاس‌پذیرتری است که بتوانند مراقبت‌های بهداشتی فعلی را در راستای تشخیص زود هنگام 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 سامانه‌های مراقبت‌های بهداشتی یافت. چنین فناوری‌هایی، ایده استفاده از ریزحس‌گرهای هوشمند با توان مصرفی پایین، میکرو حس‌گرها 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 حس‌گرهای 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 در حالی که 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 کمینه‌رساندن نیاز به مراقبت‌های گران‌قیمت در مراقبت‌های بیمارستانی کاهش دهد. مهم‌تر از همه، داده‌های ارائه شده به وسیله 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. از الزامات یک سامانه قابل اعتماد این است که باید تحمل‌پذیر در برابر خطا باشد، یعنی اگر یک خطا بدون در نظر گرفتن نوع یا ماهیت خطا رخ دهد، باید توانایی بهبود خود را داشته باشد.

باتوجه به حساسیت و اهمیت داده‌های حمل‌شده و مورد استفاده WBAN، تحمل خطا یک مسئله مهم است. با وجود مطالعات تحقیقاتی مداوم مانند انرژی، تحرک، امنیت، مسیریابی و طراحی حس‌گر که در WBAN با موضوعات فنی مقابله می‌کند؛ با این حال، تشخیص خطا و بازگشت در WBAN‌ها هنوز در مراحل ابتدایی خود است.

۲- پیشینه پژوهش

روش‌های بسیاری برای بازسازی داده‌های حس‌گر از دست‌رفته بر اساس 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 [۳۳].

آقای پان و لی [۱]، یک الگوریتم برآورد داده ازدست‌رفته در شبکه WSN با استفاده از الگوریتم k نزدیک‌ترین همسایه، بر اساس همبستگی فضایی-زمانی داده‌های حس گر پیشنهاد دادند. از آنجا که روش پیشنهادی مبتنی بر همبستگی مکانی داده‌های حس گر برای تخمین داده‌های ازدست‌رفته و مدل خطی به‌وسیله الگوریتم اتخاذ شده است، هنگامی که داده‌های حس گر گره‌های مختلف به‌طور کامل خطی باشد، بهترین عملکرد را خواهد داشت.

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

نویسندگان [۲] الگوریتم برآورد داده‌های ازدست‌رفته حس گر براساس همبستگی فضایی و زمانی ارائه کردند. در مرحله نخست، تمام داده‌های سنجش‌شده 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؛ همچنین مقادیر ازدست‌رفته را از ابعاد زمانی و مکانی تخمین می‌زند. وزن‌های مختلفی به این دو بعد اختصاص داده شده است. الگوریتم یادشده رابطه بین صفات را در نظر نگرفته است.

نویسندگان [۳] با توجه با اینکه داده‌های جمع‌آوری شده به‌وسیله گره‌های حس گر به‌دلیل استفاده از توپولوژی استقرار شبکه حس گر بی‌سیم، از لحاظ مکانی و زمانی با هم ارتباط دارند، پیش‌بینی مقدارهای گم‌شده در شبکه حس گر بی‌سیم با استفاده از همبستگی فضایی و زمانی را ارائه دادند که نسبت به مدل خطی و knn دقت بالاتری دارد، اما دقت وابسته به تعداد نودهای همسایه است.

پگان و همکاران [۴] از فرایندهای گاوسی یادگیری ماشین برای پیش‌بینی داده‌های ازدست‌رفته در شبکه حس گرهای بی‌سیم بدن استفاده کردند. این الگوریتم در صورت تنظیم دقیق پارامترهای یادگیری ماشین دقت بالایی ارائه می‌دهد.

آقای لین و همکاران [۵] روشی با تحلیل پویای فاکتور فراموشی متغیر برای شبکه‌های حس گر بی‌سیم با داده‌های گم‌شده 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 چند جمله‌ای محلی (LPM) برای الگوریتم RDFA ارائه شده است تا با محیط متغیر با زمان سازگاری بهتری داشته باشد. روش آن‌ها نسبت به روش k نزدیک‌ترین همسایه به حذف نمونه‌ها مقاوم‌تر است، اما مشکل آن پیچیدگی بالای زمانی در محاسبه مقدار داده ازدست‌رفته است.

نویسندگان [۶] از روش هموارسازی نمایی مرتبه دوم و آنالیز رگرسیون خطی برای پیش‌بینی داده‌های ازدست‌رفته در شبکه حس گرهای 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؛ همچنین از ضریب همبستگی پیرسون برای یافتن ارتباط بین گره‌ها استفاده می‌کنند. پیچیدگی زمانی الگوریتم کم و دقت پیش‌بینی بالاست، اما نیازمند داده‌های کمابیش دقیق پایه است.

ژائو و همکارش ژنگ [۷] روش یادگیری فرهنگ لغت انطباقی به‌روز را برای بازسازی اطلاعات گم‌شده در شبکه حس گرهای بی‌سیم ارائه کردند که نیاز به حداقل داده آموزش دارد، اما پیچیدگی محاسباتی زیادی دارد.

نویسندگان [۸] از کدگذاری شبکه همکاری برای بازایی داده‌ها در شبکه حس گرهای بی‌سیم بدن استفاده کردند. آن‌ها با روش پیشنهادی خود با کاهش زمان انتقال مجدد اطلاعات، از تک نقاط شکست جلوگیری می‌کنند. ایده اصلی این روش استفاده از ترمینال‌های موجود کاربر به‌عنوان رله‌هایی است که می‌توانند برای افزایش کارایی سامانه همکاری کنند. با افزایش تعداد گره‌های منبع، گره‌های رله نیاز به پردازش زیادی دارند که انرژی انتقال زیادی را مصرف می‌کند.

دایجی ساکورائی و همکاران [۹] با استفاده از شبکه‌های عصبی مصنوعی، داده‌های گمشده را تخمین می‌زنند؛ اما بهره‌وری یادگیری ANN بستگی به مقادیر اولیه پارامترها دارد.

بیونگ‌سون کیم و همکاران [۱۰] با استفاده از تکرار درخواست، بخش شامل داده خراب را دوباره دریافت می‌کنند که سر بار اضافی به سامانه تحمیل می‌کند، اما در مقایسه با سایر روش‌هایی که کل قاب داده را درخواست می‌کنند انرژی مصرفی کمتر و دقت بالاتری دارند.

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 کارایی محاسبه بالاست. 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 معمولی تولید کند.


آقای یانگ و همکاران [۱۲] با استفاده از یادگیری عمیق، برای پیش‌بینی مشاهدات مفقود شده جریان ترافیک یک مدل خطی 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 بر اساس مدل LSTM اصلاح شده، رویکرد جدیدی برای استنباط باقی‌مانده پیش‌بینی ارائه می‌دهند. در پژوهش پیشین [۳۱ و ۳۰]، با استفاده از روش آزمون و خطا به مدل مناسب شبکه عصبی عمیق، برای برآورد داده‌های ازدست‌رفته ضربان قلب دست پیدا کردیم، در این پژوهش با استفاده از بهینه‌سازی بیزی، به ساختار شبکه مطمئن‌تر خواهیم رسید؛ همچنین با استفاده از الگوریتم فراابتکاری PSO مرحله آموزش شبکه را بهبود می‌بخشیم.

۳- روش پیشنهادی

در سال‌های اخیر از مدل‌های «یادگیری عمیق» (Deep Learning) در حوزه‌های بسیاری نظیر ترجمه ماشین (Machine Translate)، تشخیص تصاویر، پیش‌بینی بازار

[۲۰ و ۱۷] و سایر حوزه‌ها [۲۶ و ۱۹، ۱۸] استفاده شده است [۱۳]. معماری مدل‌های یادگیری عمیق از ساختاری با عنوان «شبکه عصبی» (Neural Network) تشکیل شده است که با نام «شبکه عصبی مصنوعی» (Artificial Neural Network) نیز شناخته می‌شوند. برای کارهایی مانند پیش‌بینی توالی، مدل‌سازی زبان و تشخیص گفتار از شبکه‌های عصبی تکرار شونده (Recurrent Neural Networks) استفاده می‌کنند [۲۳ و ۱۴، ۱۶].

با توجه به برتری LSTM در تجزیه و تحلیل توالی نسبت به سایر روش‌ها (LSTM نوع خاصی از شبکه RNN است که مشکل حافظه بلندمدت شبکه RNN را حل می‌کند). و این که داده‌های ما از نوع سری زمانی هستند، از LSTM برای یادگیری سری زمانی داده‌های علائم حیاتی بدن استفاده می‌کنیم [۲۷]. ساختار شبکه LSTM را در شکل (۱) می‌بینیم:



(شکل-۱): ساختار شبکه LSTM

(Figure-1): LSTM Network

شبکه LSTM از چندین دروازه تشکیل شده است، دروازه فراموشی، دو لایه به‌طور کامل متصل (Fully Connected) با وزن‌های w_{hf} و w_{if} به ترتیب برای ورودی h_{t-1} و x_t است که از معادلات زیر به دست می‌آیند:

$$f_t = \sigma(w_{hf}h_{t-1} + w_{if}x_t + b_{hf} + b_{if}) \quad (1)$$

$$c_t = c_{t-1} \odot f_t \quad (2)$$

عمل به‌خاطر سپردن در شبکه عصبی LSTM با معادله (۳) نشان داده می‌شود:

$$g_t = \sigma(w_{hg}h_{t-1} + w_{ig}x_t + b_{hg} + b_{ig}) \quad (3)$$

دروازه ورودی، دو ورودی h_{t-1} و x_t را وارد دو لایه به‌طور کامل متصل، سپس این‌ها را با هم جمع می‌کند و در نهایت از تابع سیگموید عبور می‌دهد.

می‌کنیم و متریک میانگین خطای مطلق را برای بهینه‌سازی انتخاب می‌کنیم، الگوریتم، ترکیبی از فراپارامترها را جستجو می‌کند که متریک انتخابی ما را کمینه کند.

بهینه‌سازی بیزی با استفاده از روش بهینه‌سازی جایگزین (Surrogate optimization)، برای مسائلی که ارزیابی تابع برای بهینه‌سازی هزینه‌بر است و یا مشتق ناشناخته است و یا مسائلی که باید کمینه سراسری را پیدا کنیم راه حل مناسبی ارائه می‌دهد و باعث می‌شود در کمینه گام‌های ممکن به کمینه سراسری برسیم.

الگوریتم‌های فراابتکاری قادرند بدون دانستن مسئله، با ارائه یک راه حل عمومی مسئله را با سرعت و دقت معقولی حل کنند. این روش‌ها در اصطلاح Problem Independent (مستقل از مسئله) هستند. از آنجاکه الگوریتم فراابتکاری بهینه‌سازی ازدحام ذرات (PSO) یک الگوریتم مبتنی بر جمعیت است و این خاصیت باعث می‌شود که کمتر در کمینه محلی گرفتار شود و یک الگوریتم بهینه‌سازی تصادفی است که می‌تواند نواحی نامشخص و پیچیده را جستجو کند، بعد از به دست آمدن ابرپارامترهای مناسب به وسیله بهینه‌سازی بیزی، با استفاده از این الگوریتم، وزن‌های شبکه آموزش دیده را بهبود می‌بخشیم تا خطای کمتری داشته باشیم.

نقش بایاس در شبکه عصبی این است که خروجی نهایی تابع فعال‌سازی را تغییر دهد. بایاس مشابه مقدار ثابت در تابع خطی است و مقدار نهایی تابع فعال‌سازی را در فضای برداری به چپ و راست منتقل می‌کند تا تابع نهایی بر روی داده‌ها بهتر منطبق شود و مدل در نهایت پیش‌بینی دقیق‌تری داشته باشد.

با توجه به این امر، برای بهبود پیش‌بینی می‌توانیم از الگوریتم PSO برای تنظیم دقیق مقادیر بایاس که در معادلات LSTM به آن‌ها اشاره کردیم، استفاده کنیم.

$$v_i(t+1) = wv_i(t) + c_1r_1(x^{i, personal\ best} - x^i(t)) + c_2r_2(x^{i, global\ best} - x^i(t)) \quad (9)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (10)$$

در فرمول‌های سرعت و مکان هر ذره در الگوریتم PSO، اگر قسمت نخست را در معادله سرعت در نظر بگیریم $wv_i(t)$ ، آن‌گاه سرعت ذرات تنها با توجه به

$$i_t = \sigma(w_{hi}h_{t-1} + w_{ii}x_t + b_{hi} + b_{ii}) \quad (4)$$

$$g'_t = g_t \odot i_t \quad (5)$$

$$c_t = c_t + g'_t \quad (6)$$

دروازه خروجی، دو ورودی x_t و h_{t-1} را وارد دو لایه به‌طور کامل متصل می‌کند و این‌ها را با هم جمع می‌کند و در نهایت از تابع سیگموید عبور می‌دهد.

$$o_t = \sigma(w_{ho}h_{t-1} + w_{io}x_t + b_{ho} + b_{io}) \quad (7)$$

$$h_t = o_t \odot \tanh(c_t) \quad (8)$$


هنگامی که یک شبکه یادگیری عمیق را آموزش می‌دهیم، نحوه پیش‌پردازش داده‌ها، تعداد لایه‌ها و واحدهای پنهان و نرخ یادگیری اولیه در شبکه می‌تواند بر رفتار آموزشی و عملکرد شبکه تأثیر بگذارد [۲۱]. انتخاب عمق شبکه LSTM مستلزم متعادل کردن سرعت و دقت است؛ برای مثال، شبکه‌های عمیق‌تر می‌توانند دقیق‌تر باشند، اما آموزش و هم‌گرایی بیشتر طول می‌کشد. از آنجا که شبکه‌های عصبی مصنوعی دارای دو ابر پارامتر اصلی‌اند 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. روش‌های مبتنی بر آزمون و خطا برای تخمین این عوامل، ممکن است بهینه‌ترین شبکه را تضمین نکنند. مطمئن‌ترین روش برای پیکربندی این ابرپارامترها برای مدل‌سازی یک مسئله پیش‌بینی خاص، از طریق آزمایش منسجم با یک تست قوی است.

این مقاله راه حلی را برای حل مسئله یادشده با استفاده از سازوکار ترکیبی شبکه RNN-LSTM با یک روش بهینه‌سازی فراابتکاری تعریف می‌کند. این مدل یک روش قاعده‌مند را پیشنهاد می‌کند که به ما در تولید خودکار شبکه بهینه‌شده کمک می‌کند [۳۴]. شبکه به‌دست آمده با مقادیر فراپارامتریک تنظیم‌شده، منجر به فرایند یادگیری دقیق‌تر با حداقل میزان خطا و افزایش دقت می‌شود.

با استفاده از بهینه‌سازی بیزی (Bayesian optimization) ابر پارامترها و شبکه بهینه را به‌دست می‌آوریم [۲۸ و ۳۲]. بهینه‌سازی بیزی یک استراتژی جایگزین برای فراپارامترها در یک آزمایش ارائه می‌کند. محدوده‌ای از مقادیر را برای هر ابر پارامتر مشخص

w ضریب لختی (inertia) نامیده می‌شود؛ چون ضربی است که جهت حرکت کنونی $v_i(t)$ را به جهت حرکت بعدی $v_i(t+1)$ مرتبط می‌گرداند؛ به عبارت دیگر نشان‌دهنده میزان تمایل ذره برای حفظ حالت حرکت کنونی خود است. این عدد بایستی کمتر از یک باشد و مقدار مناسب آن بین $0/4$ الی $0/9$ است. اینرسی هرچقدر کمتر باشد، الگوریتم سریع‌تر هم‌گرا و بیش‌تر شدن آن باعث بالا رفتن تعداد حرکت‌های ناگهانی ذرات خواهد شد.

موقعیت فعلی و بهترین تجربه ذره و بهترین تجربه جمع تعیین و درعمل تأثیر سرعت کنونی و لختی آن حذف می‌شود؛ به این ترتیب، بهترین ذره گروه، در جای خود ثابت می‌ماند و سایرین به سمت آن ذره حرکت می‌کنند؛ درواقع حرکت دسته‌جمعی ذرات بدون قسمت نخست معادله، چرخه‌ای خواهد بود که طی آن فضای جست‌وجو به تدریج کوچک می‌شود و جست‌وجویی محلی حول بهترین ذره شکل می‌گیرد. در مقابل اگر تنها قسمت اول معادله را درنظر بگیریم، ذرات راه عادی خود را می‌روند تا به دیواره محدودده برسند و به نوعی جست‌وجویی سراسری را انجام می‌دهند. پارامترهای c_1 و c_2 میزان اهمیت و وزن یادگیری جمعی و یادگیری شخصی را مشخص می‌کنند.



(شکل-۲): ساختار الگوریتم پیشنهادی
(Figure-2): Structure of the proposed method

c_1 و c_2 ضرایب یادگیری نام دارند. c_1 ضریب یادگیری شخصی و c_2 ضریب یادگیری جمعی است. مرسوم است که c_1 و c_2 اعدادی نامنفی و حداکثر برابر دو باشند؛ لذا بیشتر اوقات داریم:

$$\begin{aligned} w &\in [0.4, 0.9] \\ c_1 &\in [0, 2] \\ c_2 &\in [0, 2] \end{aligned} \quad (12)$$

r_1 و r_2 هرکدام بردارهایی به طول بردار موقعیت‌اند. هر یک از اعضای این دو بردار عددی تصادفی بین صفر و یک با توزیع یکنواخت است.

$$r_{ij} \sim u(0,1) \quad i \in \{1,2\}$$

(۱۱)

مقصود از r_{ij} عضو λ ام بردار r_1 یا r_2 است.

یک از علائم حیاتی را با مقادیر ثابت زیر جایگزین می‌کنیم که میانگین کل مقادیر مشاهده‌شده در مجموعه داده است:

$$hr = 91, Resp = 20, spo2 = 100, \\ abps = 121, abpd = 62, abpm = 81 \quad (13)$$

برای مقایسه پذیرتر شدن داده‌ها، به نرمال‌سازی آن‌ها می‌پردازیم. بدین‌صورت که ابتدا کمینه و بیشینه را از داده‌ها حذف، سپس از تمامی داده‌ها، میانگین را کم و بر انحراف معیار تقسیم می‌کنیم.

$$x_{normalized} = \frac{x - mean(x)}{\sigma(x)} \quad (14)$$

۴-۴- ابزارهای مورد استفاده در پژوهش

با بررسی مقالات مرتبط با موضوع این پژوهش، نرم‌افزار متلب به‌عنوان نرم‌افزار شبیه‌سازی و مشاهده نتایج انتخاب شد. متلب کتابخانه‌های اختصاصی و توابع داخلی توسعه‌یافته‌ای دارد که اجازه می‌دهد عملیات خاص، سریع‌تر از پایتون اجرا شوند؛ درضمن متلب برای تجزیه و تحلیل داده‌های تعاملی و کارهای گرافیکی فشرده، به‌دلیل توسعه ابزارهای ترسیم داخلی و رابط کاربری گرافیکی تعاملی، مناسب‌تر از پایتون است.

۴-۵- پارامترهای ارزیابی

به‌طور معمول 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 [۲۹ و ۲۵].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (15)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i| \quad (16)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i - \hat{x}_i}{x_i} \right| \times 100 \quad (17)$$

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

با توجه به معادلات یادشده، پس از آنکه شبکه مناسب برای پیش‌بینی مقادیر ازدست‌رفته به‌دست آمد، به بهبود مقادیر بایاس با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات می‌پردازیم. ساختار کلی الگوریتم ما در شکل (۲) آمده است:

همان‌گونه که در بخش **Error! Reference source not found.** مراحل اجرای کار شامل دو مرحله اصلی است. گفتنی است که مرحله نخست یک مرتبه و مرحله دوم در هر مرحله از اجرای روش پیشنهادی تکرار می‌شود، با احتساب پیکره متنی در دسترس ده‌بار الگوریتم پیشنهادی اجرا خواهد شد.

۴- ارزیابی و نتایج

در این بخش ابتدا مجموعه داده‌های استفاده‌شده، سپس معیارهای ارزیابی و در نهایت سناریوهای مختلف ارزیابی رویکرد پیشنهادی، مورد بررسی قرار گرفته است.

۴-۱- جامعه پژوهش

پایگاه داده MIMIC-III Waveform، با نظارت بر بیماران بستری در بخش مراقبت‌های ویژه بزرگسالان و نوزادان، هزاران سیگنال فیزیولوژیکی چندگانه ضبط‌شده و سری زمانی علائم حیاتی جمع‌آوری کرده است، برای تست الگوریتم و تعیین پارامترهای الگوریتم از آن استفاده خواهیم کرد.

۴-۲- نمونه پژوهش


به‌دلیل حجم زیاد داده‌ها و دشواری بودن آزمایش الگوریتم روی تمامی داده‌ها، به آزمایش پانصد بیمار از این مجموعه داده که در مجموع حدود ۲۳۰,۰۰۰ داده زمانی هستند و علائم حیاتی آن‌ها شامل ضربان قلب، تنفس، اکسیژن خونو ... بود بسنده و هفتاد درصد ابتدای سری زمانی هر بیمار را برای آموزش و سی درصد انتهایی آن را برای اعتبارسنجی استفاده می‌کنیم. و از صد بیمار دیگر که شامل حدود شصت‌هزار داده زمانی است برای آزمایش الگوریتم و محاسبه میزان خطای الگوریتم استفاده می‌کنیم.

۴-۳- پیش‌پردازش داده‌ها

به‌دلیل این‌که فرمت مجموعه داده با ورودی الگوریتم ما یکسان نیست، ابتدا ورودی مورد نظر را استخراج می‌کنیم، سپس به پرکردن مقادیر ازدست‌رفته در مجموعه داده می‌پردازیم. بدین‌صورت که ابتدا خانه‌های خالی را با میانگین ده خانه اخیر پر می‌کنیم، اگر به این ده خانه دسترسی نداشتیم، با نزدیک‌ترین مقدار جایگزین می‌کنیم؛ همچنین اگر باز هم داده‌ای نداشتیم، مقدار هر

(جدول-۲): تأثیر افزایش c_1 در PSO
(Table-2): The effect of increasing c_1 in PSO

W=0.5; c2=1.5			
C1	Min_RMSE	Max_RMSE	Avg_RMSE
۰.۲	۰.۶۵۴۰۵۸۱۶	۴.۰۱۱۳۳۹۷	۱.۹۴۱۳۷۳۵
۰.۴	۰.۵۹۴۷۱۸۶۹	۳.۴۶۶۳۵۷۹	۱.۸۹۹۴۰۹۹
۰.۶	۰.۳۹۲۶۴۸۹۹	۴.۰۶۴۲۲۴۲	۲.۰۷۵۷۲۷۹
۰.۸	۰.۷۴۵۲۶۶۲۶	۳.۱۷۰۷۴۷۵	۱.۷۱۲۵۸۶۹
۱.۰	۰.۶۸۹۶۵۰۴۸	۲.۹۴۲۱۱۳۶	۱.۵۹۶۷۱۳۷
۱.۲	۰.۵۴۸۵۱۹۹۱	۳.۱۷۱۶۴۱۳	۱.۵۲۸۵۷۶۶
۱.۴	۰.۴۹۱۳۵۶۸۲	۳.۶۲۰۰۷۶۴	۱.۹۳۱۱۹۳۹
۱.۶	۰.۶۲۷۴۱۸۴۶	۳.۹۳۰۹۵۳۷	۲.۳۱۵۸۴۲۴
۱.۸	۰.۶۰۲۴۸۱۹	۳.۷۱۶۴۰۴۷	۱.۶۴۵۲۸۲۶



(شکل-۳): نمودار تأثیر افزایش c_1 در PSO
(Figure-3): Chart of The effect of increasing c_1 in PSO

همان‌طور که در نمودار خطا مشاهده می‌کنیم، نمودار روند نزولی دارد و بهترین مقدار آن با c_1 برابر ۱.۲ است.

۴-۸- تأثیر متمایل شدن به سمت بهترین

تجربه گروه در PSO

در این بخش، به تأثیر افزایش c_2 در شبکه می‌پردازیم. با توجه به داده‌ها، روند کلی نمودار نزولی است. بهترین خطا در c_2 برابر ۰.۶ اتفاق افتاده است.

۴-۹- مقایسه رویکرد پیشنهادی با

کارهای دیگران

مدل پیشنهادی خود را با شبکه عصبی معمول، شبکه عصبی غیرخطی خودکاهشی [۱۵] و مدل ارائه شده در زمینه پیش‌بینی مقادیر [۲۴] و همچنین پژوهش قبلی خود [۳۱ و ۳۰] مقایسه می‌کنیم.

RMSE یک قانون امتیازدهی درجه دوم است که مقدار متوسط خطا را اندازه‌گیری می‌کند. از آنجا که خطاها قبل از میانگین کردن آن‌ها مربع هستند، RMSE وزن کمابیش 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، تمام خطاها از یک اندازه است هر دو MAE و RMSE می‌توانند از صفر تا بی‌نهایت متغیر باشند. پارامترهای ذکر شده نمرات منفی گرا هستند؛ یعنی مقادیر پایین بهترند.

۴-۶- مدل استفاده شده

مدل بهینه‌شده نهایی، مطابق جدول (۱) خواهد بود:

(جدول-۱): پارامترهای اولیه مدل استفاده شده
(Table-1): Initial parameters of the model used

مرحله	توضیحات	مقدار
۱	Input Layer	۶
۲	LSTM Layer	۱۸۰
۳	LSTM Layer	۱۸۰
۴	Fully Connected Layer 1	۱۵۰
۵	dropout Layer	۰.۳
۶	Fully Connected Layer 2	۱
۷	Regression Layer	۱

مدل ما شامل دو لایه LSTM با ۱۸۰ نورون، دو لایه به‌طور کامل متصل و یک لایه dropout با مقدار ۰.۳ خواهد بود.


در الگوریتم‌های بهینه‌سازی همواره با دو مفهوم روبه‌رو هستیم:

- ۱- جست‌وجو (exploration) که به مفهوم توانایی تولید پاسخ‌های جدید و جست‌وجوی تصادفی است.
- ۲- بهره‌برداری (exploitation) که به مفهوم توانایی پروراندن پاسخ‌های فعلی و جست‌وجوی محلی است. بر همین اساس افزایش w ، c_1 و c_2 به نفع exploitation و کاهش آن‌ها به نفع exploration است.

۴-۷- تأثیر متمایل شدن به سمت بهترین

تجربه شخصی در PSO

در این ارزیابی، تأثیر افزایش c_1 در شبکه پیشنهادی را بررسی می‌کنیم.



(شکل-۴): نمودار تأثیر افزایش c_2 در PSO
(Figure-4): Chart of The effect of increasing c_2 in PSO

از لحاظ خطای پیش‌بینی، سرعت یادگیری و پیش‌بینی با سایر روش‌ها، نتایج مطابق جدول (۴) است:

(جدول-۳): تأثیر افزایش c_2 در PSO
(Table-3): The effect of increasing c_2 in PSO

$w=0.5; c1=1.5$			
C2	Min_RMSE	Max_RMSE	Avg_RMSE
۰.۲	۱.۶۳۹۶۲۳۴	۴.۳۱۷۶۱۴۱	۲.۹۱۹۵۶۶۹
۰.۴	۰.۶۸۹۶۵۰۴۸	۲.۹۴۲۱۱۳۶	۱.۵۹۶۷۱۳۷
۰.۶	۰.۷۱۴۸۴۵۷۸	۳.۲۵۱۵۵۳۳	۱.۵۸۹۸۴۱۱
۰.۸	۰.۷۵۵۶۷۳۷۱	۲.۹۷۶۴۴۳۵	۱.۵۹۰۷۴۷۲
۱.۰	۰.۶۲۷۴۱۸۴۶	۳.۹۳۰۹۵۳۷	۲.۳۱۵۸۴۲۴
۱.۲	۰.۶۰۲۴۸۱۹۰	۳.۷۱۶۴۰۴۷	۱.۶۴۵۲۸۲۶
۱.۴	۱.۶۳۹۶۲۳۴	۴.۳۱۷۶۱۴۱	۲.۹۱۹۵۶۶۹
۱.۶	۰.۷۹۹۶۴۶۷۹	۳.۸۵۴۸۰۶۷	۲.۳۶۷۶۳۰۵
۱.۸	۰.۴۴۷۹۹۱۶۷	۳.۹۸۶۵۲۷۹	۲.۰۹۱۲۸۵۰

(جدول-۴): مقایسه مدل پیشنهادی با سایر روش‌ها
(Table-4): Comparison of the proposed model with other methods

	Methods					
	Narx	NN	Deep_Sgdm	Deep_Adam ^[22]	Deep_Adam ^[24]	Deep_PSO ^[our]
RMSE	۲۷.۳۶۴۷	۲۲.۳۲۶۲	۴.۳۲۹۵	۶.۴۱۳۹	۷.۰۰۶۴	۱.۵۸۹۸
TrainTime(Secs)	۹۷۵۲	۵۰	۴۷۳۸	۸۳۸۳	۶۱۶	۳۲۰۲۷
PredictTime(Secs)		۸	۳۲	۳۴	۵	۵

6-Reference

۶-مراجع

- [1] L. Pan و J. Li ،"K-Nearest Neighbor Based Missing Data Estimation Algorithm" pp. 115-122 ،2010.
- [2] Z. Gao ،W. Cheng ،X. Qiu و L. Meng ،"A Missing Sensor Data Estimation Algorithm Based on" 2015.
- [3] 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 (IJCNCW) ،2017.
- [4] J. Pagán ،"Robust and Accurate Modeling Approaches for Migraine Per-Patient Prediction from Ambulatory Data" 2015.
- [5] 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" 2017 IEEE International Symposium on Circuits and Systems (ISCAS) ،2017.
- [6] Q. Zhen و T. Zhang ،"A Missing Data Estimation Algorithm in Wireless Sensor Networks" Boletín Técnico ،2017.
- [7] L. Zhao و F. Zheng ،"Missing Data Reconstruction Using Adaptively Updated

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

۵- جمع‌بندی و کارهای آینده

تمرکز اصلی ما در این پژوهش استفاده از الگوریتم فراابتکاری PSO جهت بهبود شبکه LSTM برای پیش‌بینی مقادیر از دست‌رفته علائم حیاتی در شبکه‌های WBAN بود که توانست به‌طور نسبی خطای کمتری نسبت به سایر روش‌های مشابه در این حوزه ارائه دهد. این در حالی است که الگوریتم‌های ابتکاری تضمین نمی‌دهند که جواب به‌دست‌آمده، بهترین جواب ممکن باشد و یکی از چالش‌های مهم در حوزه پیش‌بینی مقادیر با استفاده از الگوریتم فراابتکاری PSO، افزایش سرعت ذرات زمان نزدیک‌شدن به بهینه سراسری است که ممکن است از بهینه سراسری عبور کند. در پژوهش‌های آینده می‌توان از روش‌هایی که برای حل این مشکل در PSO ارائه شده‌اند، از جمله ضریب کاهنده سرعت و یا سرعت بیشینه برشی استفاده کرد.

- Deep Learning: A Case Study Analysis of Yu'e Bao Transaction Data," IEEE Access , 2019.
- [21] 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 ,2019.
- [22] 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 , 2019.
- [23] 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.
- [24] K. W. Minmin Luo , "Heart rate prediction model based on neural network," IOP Conference Series: Materials Science and Engineering ,2020.
- [25] L. Zhou ,C. Zhau ,N. Liu ,X. Yao و Z. Cheng , "Improved LSTM-based deep learning model for COVID-19 prediction using optimized approach ," Engineering Applications of Artificial Intelligence ۲۰۲۳ ,
- [26] H. Farrell ,T. Liang ,S. Misra , "DEEP NEURAL NETWORKS FOR ESTIMATION AND INFERENCE ," Econometrica ,2021
- [27] Y. Pan ,J. Mu , "Enhancing WBANs Network Performance Based on Deep Learning With Integrated Spatiotemporal Information" IEEE Wireless Communications , 2024
- [28] K. W. Minmin Luo , " A Short-term Time Series Predictive Algorithm Based on Rolling Prediction and PSO-SVR," 2024 IEEE 2nd International Conference on Control, Electronics and Computer Technology ,2024
- [۲۹] مشیری، مریم، قادری زفرهایی، مصطفی و قانع گل محمدی، فرزنان، " مقایسه دقت الگوریتم های یادگیری ماشین در تخمین داده های گمشده حاصل از آزمایش های ریزآرایه "DNA" ، مجله پژوهش های سلولی و مولکولی (مجله زیست شناسی ایران)، جلد ۲۸، ۱۳۹۴.
- [۳۰] ابراهیمی، ابوالفضل، شمسی، محبوبه و محجل، مرتضی، "برآورد داده های ازدست رفته علائم حیاتی در شبکه های حس گر بی سیم بدن"، ششمین کنفرانس ملی پژوهش های کاربردی در مهندسی برق، مکانیک و مکترونیک، تهران، ۱۳۹۹.
- [۳۱] ابراهیمی، ابوالفضل، شمسی، محبوبه و محجل، مرتضی، "تنظیم بهینه پارامترهای شبکه عصبی عمیق در برآورد داده های ازدست رفته علائم حیاتی در شبکه های حس گر بی سیم بدن"، مجله مدیریت مهندسی و رایانش نرم، شماره ۱۶، صفحات ۱۶۲-۱۸۸، ۱۴۰۲.
- Dictionary in Wireless Sensor Networks," تألیف Proceeding of science ,2017.
- [8] 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 ,2017.
- [9] D. Sakurai ,A. Santana و Y. Kawamura , "Estimation of Missing Data of Showcase Using Artificial Neural Networks," IEEE 10th International Workshop on Computational Intelligence and Applications ,2017.
- [10] B. Kim ,B. Lee و J. Cho , "ASRQ: Automatic Segment Repeat reQuest for IEEE 802.15.4-based WBAN," IEEE SENSORS JOURNAL , 2016.
- [11] 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," 57th Annual Conference of the Society of Instrument and Control Engineers of Japan (SICE) ,2018(8).
- [12] Y. Tian ,K. Zhang ,J. Li ,X. Lin و B. Yang , "LSTM-based Traffic Flow Prediction with Missing Data," Neurocomputing ,2018.
- [13] S. Ghazal ,M. Sauthier ,D. Brossier ,W. Bouachir ,P. Jouviet 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 ,2018.
- [14] 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 , 2019.
- [15] 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 ,2019.
- [16] R. Zhang ,Z. Chen ,S. Chen ,J. Zheng ,O. Büyükoztürk و H. Sun , "Deep long short-term memory networks for nonlinear structural seismic response prediction," Computers and Structures ,2019.
- [17] F. Rundo , "Deep LSTM with Reinforcement Learning Layer for Financial Trend Prediction in FX High Frequency Trading Systems," Applied Sciences ,2019.
- [18] 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 ,2018.
- [19] 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 ,2018.
- [20] X. Yang ,S. Mao ,H. Gao ,Y. Duan و Q. Zou , "Novel Financial Capital Flow Forecast Framework Using Time Series Theory and

[۳۲] عمرانپور، حسام و آزادیان، فهیمه، "ارائه یک رویکرد فازی برای بهینه‌سازی پیش‌بینی سری زمانی با مرتبه بالا"، فصلنامه پردازش علائم و داده‌ها، جلد ۱۵ شماره ۲، صفحات ۳-۱۶، ۱۳۹۷.

[۳۳] دانشپور، نگین و میرابوالقاسمی، سیده فاطمه، "پرکردن داده‌های گمشده در داده‌های سری زمانی چندمتغیره"، فصلنامه پردازش علائم و داده‌ها، جلد ۱۹ شماره ۲، صفحات ۳۹-۶۰، ۱۴۰۱.

[۳۴] عمرانپور، حسام و پورعلی، حدیثه، "ارائه مدل یادگیر ترکیب کرنل‌ها برای پیش‌بینی سری‌های زمانی براساس رگرسیون بردار پشتیبان و جستجوی فراابتکاری"، فصلنامه پردازش علائم و داده‌ها، جلد ۱۹ شماره ۱، صفحات ۳۹-۴۲، ۱۴۰۱.

محبوبه شمسی در حال حاضر



دانشیار دانشگاه صنعتی قم و دارای سابقه راهنمایی پایان‌نامه‌های دانشجویان کارشناسی‌ارشد است. ایشان علاقه‌مند به موضوعات اینترنت اشیا، بزرگ‌داده‌ها، پردازش تصویر است. نشانی رایانامه ایشان عبارت است از:

shamsi@qut.ac.ir

مرتضی محجل در حال حاضر



استادیار و مدیرگروه مهندسی کامپیوتر دانشگاه صنعتی قم است. ایشان علاقه‌مند به موضوعات سامانه‌های نهفته بی‌درنگ و اینترنت اشیا است. نشانی رایانامه ایشان عبارت است از:

mohajjel@qut.ac.ir

ابوالفضل ابراهیمی کارشناسی‌ارشد



مهندسی کامپیوتر دانشگاه صنعتی قم است. زمینه‌های پژوهشی مورد علاقه وی شبکه‌های عصبی و یادگیری عمیق است.

نشانی رایانامه ایشان عبارت است از:

ebrahimi.a@qut.ac.ir