

Research Paper

Proposing a Method for Anomaly Detection in Trajectory of Patients With Alzheimer's Disease Using Mobile GPS Data and Combination of Deep Neural Network and Adaptive Neuro-fuzzy Inference System



Mojtaba Banifakhr¹, *Mohammad Taghi Sadeghi²

1. Department of Electrical Engineering, Faculty of Engineering, Azadi Campus, Yazd University, Yazd, Iran.
2. Department of Electrical Engineering, Faculty of Engineering, Yazd University, Yazd, Iran.



Citation Banifakhr M, Sadeghi MT. [Proposing a Method for Anomaly Detection in Trajectory of Patients With Alzheimer's Disease Using Mobile GPS Data and Combination of Deep Neural Network and Adaptive Neuro-fuzzy Inference System (Persian)]. *Scientific Journal of Rehabilitation Medicine*. 2023; 12(2):274-291. <https://dx.doi.org/10.32598/SJRM.12.2.5>

doi <https://dx.doi.org/10.32598/SJRM.12.2.5>



ABSTRACT

Background and Aims Today, with the industrialization of societies and the reduction of the size of households and tendency to live alone, caring for the elderly and monitoring their performance in daily life has become doubly important. Carrying devices such as a GPS is one of the proposed solutions, which may not be a suitable solution due to the unpleasant feeling of carrying such equipment and due to disorders such as Alzheimer's disease. A proper solution for taking care of old people especially for their outdoor activities is to observe their behavior by using their mobile GPS sensor by which it is possible to detect possible abnormal events. An important challenge in this method is the high number of abnormal events. In this paper, this problem is solved by applying an adaptive neuro-fuzzy inference system (ANFIS). Other important challenge is how to carefully analyze the training data to achieve a powerful model. For tackling this problem, we used a deep neural network.

Methods In this paper, by combination of ANFIS and convolutional neural networks (CNN), a method was proposed for anomaly detection in trajectory of patients with Alzheimer's disease. The CNN was optimized by the Whale algorithm. The proposed method was applied on a set of movement path data with a specific origin and destination based on the mobile GPS sensor of subjects.

Results The proposed method had an accuracy of 95.5% for classification of test data, which indicated the effectiveness of the proposed method.

Conclusion It seems that the combination of ANFIS and a CNN is a good method for anomaly detection in trajectory of older people with Alzheimer's disease.

Keywords Anomaly detection, Elderly care, Deep neural network, Neuro-fuzzy inference system, Optimization

Received: 06 Dec 2020

Accepted: 27 Apr 2021

Available Online: 21 May 2023

* Corresponding Author:

Mohammad Taghi Sadeghi, PhD.

Address: Department of Electrical Engineering, Faculty of Engineering, Yazd University, Yazd, Iran.

Tel: +98 (931) 232395

E-Mail: m.sadeghi@yazd.ac.ir

Extended Abstract

Introduction

The industrialization of societies has had various consequences, one of which is the tendency or compulsion to live alone. This problem can be discussed from multiple perspectives. Older people, due to having conditions such as amnesia and Alzheimer's disease or having psychological disorders, are not interested in carrying devices such as a global positioning system (GPS) which makes it to take care of them. A suitable solution for this problem is the use of a global positioning sensor in the mobile phone, which reduces the limitations and problems caused by carrying an additional device [1]. In this study, by integrating modern techniques of deep neural networks (DNNs) and adaptive neuro-fuzzy inference system (ANFIS), a novel approach is proposed that can be used for automatic monitoring of older people's commute. An anomaly detection system is usually trained using a training data in such a way that the behaviors are first collected in a certain period of time. The collected data are then used to learn the normal behaviors. After that, when a new data is arrived, the learned system is used to decide whether the behaviors is normal or abnormal [2].

So far, many studies have been performed in this field. For example, one study proposed an anomaly detection system using the faster-region-based convolutional neural network (RCNN) and multiple object tracking (MOT) methods [10]. Their results showed that the abnormal routes from surveillance cameras can be well detected. The differences between this research and the current study are in the architecture of the adopted neural networks and the way that the routes are created. This route is used as the input of the neural networks. In our study, routes are created using the phone GPS data, while in above-mentioned study, routes were extracted from video sequences.

Materials and Methods

The main steps in proposing the method are input data preparation, data augmentation, optimization of convolutional neural network (CNN), and using ANFIS. These two networks are combined at decision level. Data augmentation is more important for training of the CNN where a large number of training data is required. Geo-Tracker software was used to extract the data related to the location sensor of a mobile. In this software, the location information is stored. The data can be downloaded and stored in the KML format in a cloud storage for fur-

ther analysis. The information in the KML format can be transferred to QGIS software. By using this software, the traveled path is extracted and presented in the form of an image. A pre-processing step is then performed to convert it to a binary image. In this study, 72 separate routes were extracted from the mobile phone of older people. Of these, 70 % were used for training and the rest were used as the test data. The selection of data was done in an equally weighted and random manner. Finally, 22 normal routes and 8 abnormal routes were used as the test data. The used mobile phone was Samsung Galaxy S7 SM-G930FD, with Android 6.0.1 operating system. The GPS sensor of this device uses the GLONASS technology and record the position with a 30-cm accuracy. A data augmentation process was also applied to increase the number of training samples. For this purpose, several augmentation methods including rotation and transferring in several directions were used. A two-stream classification approach was used in this study containing CNN and ANFIS. In the CNN stream, as a 15-layer DNN, the network was configured to use a random initial learning rate (α), and momentum learning rule (μ) where the number of epochs was 50. A L2 regularization rate (R) and a membership withdrawal rate of 0.1 were used to increase the data from the rule. To increase the number of data, the rule of rotation and transfer in X and Y directions with a rotation rate of -10 to +10 degrees and a transfer rate of -4 to +4 pixels were used which increased the number of data up to 1280 (from 42 routes to 5370 routes). The values of initial learning rate, momentum, and L2 regularization were optimized in each iteration by using the Whale optimization algorithm with the initial population of 100. We compared this algorithm with two other methods: a) The genetic algorithm (GA) with an initial population of 100, 10 iterations (generations) and a mutation rate of 1%, and b) The particle swarm optimization (PSO) algorithm with an initial population of 100, a damping rate of 0.99, a personal acceleration coefficient of 2, and a collective acceleration coefficient of 2. The ANFIS network used in this work was based on the Takagi-Sugeno fuzzy inference system [13] which composed of a triangular function ($RMSE=0.1514$, $R^2=0.97$), 10 rules, and two membership functions.

Results

By comparing the simulation results, it was found that the whale optimization algorithm was better than the PSO and GA for optimizing the CNN parameters. Moreover, our results showed that the ANFIS algorithm had a good recognition ability for detecting abnormal routes, while the CNN had better performance in detecting complex

patterns in normal routes. As a result, it is expected that the integration of these two systems can lead to an overall better performance. Our experimental results confirmed this hypothesis. The F-RCNN method proposed in Zhao et al.'s study [2] was also implemented. The experimental results demonstrated that this method had poorer performance compared to the proposed method. A 10-fold cross-validation method was also used, resulting in an average accuracy of 94.28% for 10 executions, which is consistent with the previous results. Overall, it can be said that the proposed method is able to discriminate abnormal and normal routes with a good accuracy.

Conclusions

In this study, a new method was proposed for detecting abnormalities in the GPS-based path data of patients with Alzheimer's disease. This method which consists of two classification streams (an optimized CNN and an ANFIS) showed very good results. One of the advantages of this study was the use of whale optimization algorithm for optimizing some of the hyper-parameters in the CNN. This optimization process led to an efficient structure with a 95.5% accuracy compared to a non-optimized network with 77.3% accuracy and Zhao et al.'s method with 81.8% accuracy.

Ethical Considerations

Compliance with ethical guidelines

In this study, there was no experiments on human or animal samples. Therefore, there were no ethical principles to be considered.

Funding

This study was extracted from the PhD dissertation of Mojtaba Banifakhr, approved by the Department of Electrical Engineering, [Yazd University](#).

Authors' contributions

The authors contributed equally to preparing this paper.

Conflict of interest

The authors declared no conflict of interest.

Acknowledgments

The authors would like to thank the Centre of Excellence on Soft Computing and Intelligent Information Processing of [Ferdowsi University of Mashhad](#) for their hardware support.



مقاله پژوهشی

پیشنهاد روشی برای تشخیص ناهنجاری در مسیر حرکت بیماران مبتلا به آلزایمر با استفاده از داده‌های موقعیت تلفن همراه و بهره‌گیری از شبکه‌های عصبی عمیق و شبکه‌های فازی

مجتبی بنی فخر^۱، *محمدتقی صادقی^۲

۱. گروه مهندسی برق، دانشکده مهندسی، پردیس آزادی، دانشگاه یزد، یزد، ایران.

۲. گروه مهندسی برق، دانشکده مهندسی، دانشگاه یزد، یزد، ایران.

Use your device to scan and read the article online



Citation Banifakhr M, Sadeghi MT. [Proposing a Method for Anomaly Detection in Trajectory of Patients With Alzheimer's Disease Using Mobile GPS Data and Combination of Deep Neural Network and Adaptive Neuro-fuzzy Inference System (Persian)]. *Scientific Journal of Rehabilitation Medicine*. 2023; 12(2):274-291. <https://dx.doi.org/10.32598/SJRM.12.2.5>

doi <https://dx.doi.org/10.32598/SJRM.12.2.5>

چکیده



مقدمه و اهداف امروزه با صنعتی شدن جوامع و کوچک‌تر شدن تعداد افراد خانوارها و گسترش زندگی انفرادی، مراقبت از سالمندان و نظارت بر عملکرد آن‌ها در زندگی روزمره اهمیتی دوچندان یافته است. حمل دستگاه‌های مراقبتی یکی از راهکارهای پیشنهادی است که البته به علت احساس ناخوشایند حمل چنین تجهیزاتی و با توجه به اختلالاتی چون فراموشی ناشی از آلزایمر شاید راه حل مناسبی نباشد. یکی از راهکارهای مورد توجه پژوهشگران بررسی رفتار انسان از طریق داده‌های حسگرهای موجود در تلفن همراه است که با کمک آن امکان تشخیص رویدادهای غیرطبیعی ممکن خواهد بود. در این زمینه، یکی از چالش‌های پیش‌رو تنوع بالای رویدادهای ناهنجار است که در این پژوهش برای حل آن از شبکه‌های عصبی فازی استفاده می‌شود. چالش دیگر، نیاز به تحلیل دقیق داده‌های آموزشی برای دستیابی به مدلی قدرتمند است که برای مواجهه با این چالش استفاده از شبکه‌های عصبی عمیق پیشنهاد می‌شود.

مواد و روش‌ها در این مقاله، تشخیص ناهنجاری در مسیر حرکت با استفاده از ترکیب طبقه‌بند مبتنی بر سیستم تطبیقی استنتاج عصبی فازی و یک شبکه عصبی عمیق کانولوشنی مورد توجه قرار گرفته است. این شبکه عمیق با بهره‌گیری از الگوریتم تکاملی وال بهینه‌سازی می‌شود. روش پیشنهادی، بر روی مجموعه‌ای از داده‌های مسیر حرکت با مبدأ و مقصد مشخص که مربوط به حسگر تلفن همراه کاربر است، مورد ارزیابی قرار می‌گیرد.

یافته‌ها نتایج به دست آمده از شبیه‌سازی سیستم پیشنهادی که با درصد صحت ۹۵/۵ درصد برای دسته‌بندی داده‌های آزمایش همراه بوده است، گواهی بر عملکرد مطلوب روش پیشنهادی است.

نتیجه‌گیری به نظر می‌رسد بهره‌گیری از ترکیب طبقه‌بند مبتنی بر سیستم تطبیقی استنتاج عصبی فازی و یک شبکه عصبی عمیق کانولوشنی در تشخیص ناهنجاری مسیر طی شده توسط افراد مبتلا به فراموشی ناشی از بیماری آلزایمر موفق عمل کرده است.

کلیدواژه‌ها تشخیص ناهنجاری مسیر، مراقبت از سالمندان، شبکه عصبی عمیق، شبکه فازی، بهینه‌سازی

تاریخ دریافت: ۱۶ آذر ۱۳۹۹

تاریخ پذیرش: ۰۷ اردیبهشت ۱۴۰۰

تاریخ انتشار: ۱۱ اردیبهشت ۱۴۰۲

* نویسنده مسئول:

دکتر محمدتقی صادقی

نشانی: یزد، دانشگاه یزد، دانشکده مهندسی، گروه مهندسی برق.

تلفن: ۲۳۲۳۹۵ (۹۱۳) ۰۹۸+

رایانامه: m.sadeghi@yazd.ac.ir

مقدمه

برای حل این مشکلات، استفاده از روشی پیشنهاد می‌شود که در آن علاوه بر آموزش سیستم با داده‌های آموزشی، امکان اضافه کردن قوانین نزدیک به فهم و درک انسان تحت عنوان قوانین فازی ایجاد شده است. این کار با انتخاب خودکار تعداد مشخصی از قوانین و توابع عضویت از درون داده‌ها امکان‌پذیر شده است. باتوجه به این نکته که استفاده از داده‌های آموزشی به‌تنهایی در یک سامانه تشخیص ناهنجاری، موجب می‌شود سیستم طراحی شده از انعطاف لازم برای مواجهه با رویدادهای جدیدی که تاکنون رخ نداده و تشخیص آن نیاز به درک و فهم سطح بالایی دارد، با دشواری‌هایی همراه باشد و خواسته‌های موردنظر را در کاربرد تعریف شده برآورده نکند. پیش‌بینی می‌شود بهره‌گیری از فرایندهای منطبق بر منطق فازی که با ساختارهایی مشابه آنچه در شبکه‌های عصبی در جریان است بهینه‌شده باشد، بتواند مثر ثمر واقع شود.

علاوه بر موضوع انعطاف، سیستم پیشنهادی باید از ویژگی دیگری نیز برخوردار باشد که بتواند عملکرد خوبی را تضمین کند و آن استفاده به بهترین نحو ممکن از داده‌های آموزشی در قالب استخراج ویژگی‌هایی کارآمد است. برای این مورد نیز بهترین گزینه بهره‌گیری از شبکه‌های عصبی عمیق است. ساختار این شبکه‌ها به گونه‌ای است که علاوه بر امکان دستیابی به ویژگی‌های مرتبه بالاتر با استفاده از داده‌های آموزشی، امکان دسته‌بندی را نیز ممکن می‌کند. تاکنون شمار گسترده‌ای از روش‌های مبتنی بر شبکه‌های عصبی عمیق به‌طور گسترده در کاربردهای مختلف از قبیل فناوری اطلاعات زیستی [۳]، بازشناسی گفتار [۴]، داده کاوی [۵]، بازیابی اطلاعات و شناسایی الگو [۶] مورد استفاده قرار گرفته است و این خود گویای این موضوع است که شبکه‌های عصبی عمیق ابزاری قوی برای کاربردهای مختلف می‌باشند.

رویکرد خاص دیگری که در این پژوهش مدنظر قرار گرفته است، بهینه‌سازی شبکه عصبی عمیق با بهره‌گیری از الگوریتم بهینه‌سازی وال یا نهنگ^۳ با هدف بهینه‌سازی ابرپارامترهای این شبکه است که منجر به بهبود نتایج دسته‌بندی با بهره‌گیری از ارائه ساختاری با ابر پارامترهای بهینه‌شده با داده ورودی خواهد شد.

از جمله پژوهش‌های صورت گرفته در زمینه تشخیص ناهنجاری با استفاده از داده‌های مربوط به مسیر می‌توان به پژوهش زونیک و همکاران [۷] اشاره کرد که در آن استفاده از روش‌های مرسوم یافتن پیک QRS در سیگنال ECG، برای تشخیص ناهنجاری‌ها در مسیرهای ثبت شده توسط دستگاه GPS مستقر در خودرو مورد توجه قرار گرفته است. این ناهنجاری‌ها که بعضاً به دلیل بروز اختلال در عملکرد دستگاه به صورت عمدی یا غیرعمدی رخ می‌دهد برای سازمان‌ها و نیروهای هر سازمان، هزینه‌هایی دربر دارد که پژوهش گفته شده با یافتن این ناهنجاری در اطلاعات

در سال‌های اخیر با پیشرفت فناوری و گسترش و ارتقا بسترهای سخت‌افزاری مناسب برای پردازش‌های نرم‌افزاری، استفاده از فناوری و یاری جستن از آن در کاربردهای تشخیص هوشمند فراهم شده است. یکی از این موارد تشخیص هوشمند که می‌تواند تا حدود زیادی در پیشگیری از سوانح و رویدادهای بعضاً جبران‌ناپذیر مؤثر باشد، تحلیل و تشخیص ناهنجاری در مسیر حرکت افراد مسن است که به‌طور ویژه‌ای در سال‌های اخیر مورد توجه پژوهشگران این حوزه قرار گرفته است.

صنعتی شدن جوامع، پیامدهای متفاوتی را در برداشته است که یکی از پیامدهای اجتماعی آن، تمایل یا اجبار به زندگی به صورت انفرادی در افراد کهن‌سال است. این مشکل از جوانب متعددی می‌تواند مورد بحث قرار گیرد که در این مقاله مشکلات نظارتی مربوط به رفت‌وآمد فرد کهن‌سال مورد توجه قرار گرفته است.

افراد کهن‌سال بعضاً باتوجه به مواردی چون فراموشی و آلزایمر و یا به دلیل مسائل روحی روانی، عموماً رغبتی به همراه داشتن دستگاهی اضافی مانند دستگاه‌های مبتنی بر موقعیت‌یابی جهانی^۱ نداشتند و این کار را برای افرادی که وظیفه مراقبت از آن‌ها را به عهده دارند، دشوار می‌کند. یک راه حل مناسب برای این مشکل، بهره‌گیری از حس گر موقعیت‌یاب جهانی تعبیه شده در تلفن همراه فرد است که تا حدودی محدودیت‌ها و مشکلات مطرح شده برای حمل دستگاه اضافی را کاهش می‌دهد [۱]. در این پژوهش با بهره‌گیری از تلفیق روش‌هایی نوین چون شبکه‌های عصبی عمیق و روش‌هایی کارآمد چون شبکه‌های فازی عصبی^۲، فرایندی پیشنهاد شده است که بتوان با کمک آن در جهت نظارت خودکار بر عبور و مرور افراد کهن‌سال گامی مؤثر برداشت.

اساس کار در یک سیستم خودکار تشخیص ناهنجاری بر پایه آموزش سیستم از طریق داده‌های آموزشی است. به این صورت که در ابتدا رفتارهای موردنظر در دوره زمانی مشخص جمع‌آوری و با استفاده از این داده‌های آموزشی، الگوریتم موردنظر آموزش داده می‌شود تا پس از آن، با دریافت داده‌های جدید به عنوان ورودی و بررسی وضعیت آن، هنجار یا ناهنجار بودن رفتار کاربر موردنظر گزارش شود [۲].

در این زمینه، مشکلاتی وجود دارد، از جمله این که در فرایند آموزش چنین فرایندی، به دلیل پیچیدگی موجود، داده‌های آموزشی برچسب‌دار بسیار زیادی مورد نیاز خواهد بود. همچنین به دلیل تنوع بالای ناهنجاری‌ها، سیستم فراتر از فرایند آموزش با داده‌های آموزشی، باید به یک فهم و درک از فرایند فوق دست یابد تا بتواند نمونه‌های نوین ناهنجاری را آشکار سازد. در این مقاله

1. Global Position System (GPS)

2. Adaptive Neuro-Fuzzy Inference System (ANFIS)

3. Whale Optimization Algorithm (WOA)

موقعیت ثبت شده در پی کاهش این خسارت ها است. در پژوهش حاضر هدف نهایی دستیابی به دریافت دقیقی از نوع مسیر است و با این فرض صورت گرفته که داده های ثبت شده از تلفن همراه کاملاً صحیح و بدون خطا ثبت شده است.

در پژوهش باروسیا و همکاران [۸]، با استفاده از تحلیل اطلاعات مربوط به تلفن همراه رانندگان، فرایند تشخیص ناهنجاری با هدف ایجاد یک بستر امن برای رانندگی پیاده سازی شده است. در این پژوهش با تحلیل داده های مربوط به مسیر وسایل نقلیه، فرایند تشخیص ناهنجاری صورت گرفته و ویژگی های مختلف کاربر در بازه زمانی مشخص، ملاک رفتار هنجار یا ناهنجار قرار گرفته است. ویژگی های مورد استفاده در این پژوهش شامل مسافت طی شده، متوسط سرعت، میانگین حساسی سرعت است و این ویژگی ها بر روی مجموعه داده گانی متشکل از ۶۸۵۳ مسیر واقعی، پیاده سازی شده است. دستیابی به ۹۸ درصد تشخیص صحیح بیانگر عملکرد خوب آن در فرایند تشخیص ناهنجاری است. تفاوت این پژوهش با فرایند صورت گرفته در مقاله حاضر، نوع ویژگی هایی است که برای آموزش شبکه های عصبی عمیق مورد بهره برداری واقع شده است.

در پژوهش دبیری و همکاران [۹]، با بهره گیری از اطلاعات حس گر GPS دستگاه تلفن همراه فرد و همچنین شبکه عصبی عمیق کانولوشنی به تشخیص نوع وسیله نقلیه مورد استفاده توسط فرد برای رفت و آمد پرداخته شده است. برای این منظور، ورودی ها به صورت دنباله های زمانی متشکل از اطلاعات سرعت، شتاب، حرکت های ناگهانی و نرخ تحمل در نظر گرفته شده است که به یک شبکه عصبی عمیق کانولوشنی برای دسته بندی وارد می شوند. کلاس های مورد نظر در این پژوهش شامل پیاده روی، دوچرخه سواری، اتوبوس، رانندگی با خودرو شخصی و قطار است. در پژوهش حاضر، علاوه بر شبکه عصبی عمیق کانالوشنال از طبقه بندی های دیگری چون RF، DT، SVM، KNN و MLP جهت مقایسه نتایج بهره گرفته شده است. دستیابی به درصد صحت ۸۴/۸ درصد که بالاترین میزان را در میان کلیه طبقه بندی های فوق از آن خود کرده است، بیانگر عملکرد بسیار خوب شبکه های عصبی عمیق کانولوشنی نسبت به سایر روش های مرسوم طبقه بندی است. در پژوهش دبیری و همکاران [۹]، از داده های GPS موبایل در چارچوب مسئله طبقه بندی داده ها استفاده شده است؛ در حالی که در این مقاله، تشخیص هنجار یا ناهنجار بودن یک عمل با استفاده از چنین داده هایی مطرح است.

در مقاله شاین و همکاران [۱۰]، روشی برای تشخیص ناهنجاری با بهره گیری از روش هایی چون Faster-RCNN و MOT⁺ پیشنهاد شده است و در نهایت اطلاعات به دست آمده از این ابزارها برای تعیین احتمال ناهنجاری ها و تشخیص آن ها ترکیب می شود. این مقاله با توجه به این نکته که داده های ناهنجار

از تنوع بسیار بالایی برخوردارند، فرایند تشخیص ناهنجاری را به صورت بدون مربی پیشنهاد کرده است. داده های مورد استفاده در این پژوهش شامل مجموعه داده گانی است که در سال ۲۰۱۹ برای تشخیص مسیرهای ناهنجار شهری از روی دوربین های نظارتی طرح ریزی شده است. تفاوت این پژوهش با مقاله پیش رو در نحوه ایجاد مسیرهای موجود به عنوان ورودی شبکه های عصبی عمیق و همچنین نوع شبکه عصبی عمیق مورد استفاده است. در پژوهش حاضر مسیرها از روی داده های GPS تلفن همراه ایجاد می شود، در حالی که در این پژوهش مسیرها از دنباله های ویدیویی استخراج می شود. علاوه بر آن در مقاله پیش رو از شبکه عصبی عمیق کانولوشنی با مشخصات مخصوص به خود بهره گرفته شد، در حالی که در این مقاله از ساختارهایی استفاده شده که به صورت مشخص پیش از این ارائه شده است.

در پژوهش دویس و همکاران [۱۱] نیز یک مدل تشخیص ناهنجاری بر پایه شبکه های عصبی عمیق با بهره گیری از داده های زمانی مربوط به شبکه حمل و نقل ارائه شده است. در پژوهش مورد اشاره، از شبکه های مرسوم حافظه طولانی-کوتاه مدت^۵ بهبود یافته با کمک یک تابع برازش برگرفته شده از تحلیل مقدار حدی^۶ در فرایند تشخیص ناهنجاری استفاده شده است. روش پیشنهادی در مقاله یاد شده، ۷ مجموعه داده متنوع را که برگرفته از داده های واقعی مانند تاکسی های شهر نیویورک یا مسیر تاکسی های شهر بنگلور هند است و در حوزه تشخیص ناهنجاری شناخته شده است، مورد ارزیابی قرار داده است. تفاوت پژوهش گفته شده با روش پیشنهاد شده در این مقاله، این است که در آن پژوهش، از اطلاعات حوزه زمان در قالب شبکه های حافظه دار طولانی-کوتاه مدت بهره برداری شده است. حال آنکه در این پژوهش، کل اطلاعات مسیر حرکت در قالب یک تصویر به شبکه کانولوشنی داده می شود و از ترکیب یک شبکه فازی با شبکه کانولوشنی بهره برداری می شود.

در ادامه این مقاله، ابتدا در بخش دوم مبانی مورد استفاده برای روش پیشنهادی ارائه می شود. سپس در بخش سوم روش پیشنهادی در قالب سه بخش استخراج داده، آموزش سیستم و ارزیابی سیستم مورد بررسی قرار خواهد گرفت. در بخش چهارم آزمایش های انجام شده همراه با نتایج حاصله ارائه خواهد شد. در نهایت قسمت انتهایی نیز به جمع بندی و نتیجه گیری از پژوهش صورت گرفته اختصاص دارد.

مواد و روش ها

به منظور ایجاد بستری مناسب برای مطرح کردن روش پیشنهادی، این بخش به ارائه ابزارهایی اختصاص دارد که در روش پیشنهادی مورد استفاده قرار گرفته است. اولین ابزاری که در این بخش مورد بررسی قرار می گیرد، شبکه عصبی عمیق کانولوشنی است.

5. Long short-term memory (LSTM)
6. Extreme Value Theory/Analysis (EVT)

4. Multiple Object Tracking

شبکه عصبی عمیق کانولوشنی

بهینه‌سازی ۳ ابرپارامتر نرخ آموزش، نرخ مومنتوم در فرایند گرادیان نزولی و نرخ متعادل‌سازی بهره موردتوجه قرار گرفته است که در ادامه بررسی می‌شود.

نرخ آموزش و مومنتوم

استفاده از الگوریتم مومنتوم^{۱۴} در چارچوب گرادیان نزولی تصادفی^{۱۵} یکی از بهترین و شناخته‌شده‌ترین شیوه‌های مورد استفاده برای به‌روزرسانی وزن‌ها در شبکه‌های عصبی به شمار می‌رود. در این روش ماتریس وزن شبکه، W ، با ترکیب خطی منفی گرادینانت تابع هزینه یعنی $-\nabla L(W)$ و مقدار تغییرات وزن در مرحله قبل V_t به‌روزرسانی می‌شود (فرمول شماره ۱):

$$V_{t+1} = \mu V_t - \alpha \nabla L(W_t + \mu V_t)$$

$$1. W_{t+1} = W_t + V_{t+1}$$

در این رابطه، α نرخ یادگیری نامیده می‌شود که تأثیر مقدار گرادینانت در فرایند به‌روزرسانی را تعیین می‌کند و μ مقدار مومنتوم است که وزن آپدیت قبلی را تعیین می‌کند.

به‌طور کلی به‌منظور محاسبه مقدار جدید تغییرات بردار پارامترها، V_{t+1} و بنابراین محاسبه ماتریس W_{t+1} در تکرار $t+1$ با داشتن مقدار به‌روزرسانی قبلی V_t و ماتریس وزن فعلی W_t از عبارت فوق استفاده می‌شود:

یکی از چالش‌های مهم برای به دست آوردن بهترین نتایج، مشخص کردن ابرپارامترهای α و μ است که کمی تغییر می‌تواند جواب نهایی را دستخوش تغییرات زیادی کند.

بهره نرخ متعادل‌سازی

معمولاً در فرایندهای یادگیری عمیق هدف کلی کمینه کردن تابع هزینه‌ای است که در فرمول شماره ۲ قابل مشاهده است:

$$2. J(w^{[1]}, b^{[1]}, \dots, w^{[L]}, b^{[L]}) = \frac{1}{m} \sum_{i=1}^m L(\hat{y}^{(i)}, y^{(i)})$$

در عبارت فوق، L می‌تواند هر تابع هزینه‌ای از جمله خطای دسته‌بندی در نظر گرفته شود. برای بهبود نتایج دسته‌بندی متعادل‌سازی به‌عنوان ابزاری کارآمد پیشنهاد می‌شود و پارامتری به‌منظور تنظیم وزن‌ها اضافه می‌شود و فرمول شماره ۳ حاصل خواهد شد:

$$3. J(w^{[1]}, b^{[1]}, \dots, w^{[L]}, b^{[L]}) = \frac{1}{m} \sum_{i=1}^m L(\hat{y}^{(i)}, y^{(i)}) + \frac{\lambda}{2m} \sum_{l=1}^L \|w^{(l)}\|_F^2$$

14. Momentum
15. Stochastic Gradient Descent (SGD)

شبکه‌های عصبی عمیق کانولوشنی یکی از پرکاربردترین ساختارهایی هستند که در پژوهش‌های نوین حوزه بازشناسی الگو و بینایی ماشین مورد استفاده قرار می‌گیرند.

در این شبکه‌ها لایه‌های متنوعی تعریف شده است که با استفاده از اصول و قواعدی منسجم، عملکردی مشخص دارند. به‌طور کلی، یک شبکه کانولوشنی از سه لایه اساسی، شامل لایه کانولوشن^۷، لایه پولینگ^۸ و لایه تماماً متصل^۹ تشکیل شده است. هر کدام از لایه‌های یادشده، وظیفه‌ای مشخص را به عهده دارند.

برای این دسته از شبکه‌های عصبی فرایند آموزش شامل دو مرحله اصلی است. ابتدا مرحله جلوسو^{۱۰} و سپس مرحله پس انتشار خطا^{۱۱}. در مرحله جلوسو، ورودی به لایه ابتدایی شبکه وارد می‌شود و فرایند ضرب نقطه‌ای بین ورودی و مؤلفه‌های هر نورون و نهایتاً فرایند کانولوشن در هر لایه صورت می‌گیرد. در نهایت خروجی شبکه محاسبه می‌شود. در اینجا به‌منظور تنظیم پارامترهای شبکه و یا به‌عبارت دیگر فرایند آموزش، از نتیجه خروجی به‌دست‌آمده برای اندازه‌گیری خطای شبکه استفاده می‌شود. برای این منظور، خروجی شبکه را با استفاده از یک تابع خطا^{۱۲} با پاسخ صحیح مقایسه می‌شود و بدین صورت میزان خطا مورد محاسبه قرار می‌گیرد.

در مرحله بعدی، براساس خطای محاسبه‌شده، مرحله پس انتشار خطا آغاز می‌شود. در این مرحله با لحاظ کردن الگوریتم‌هایی مانند گرادیان نزولی، مشتق تابع خطا نسبت به هر پارامتر باتوجه به قانون زنجیره‌ای^{۱۳} محاسبه و تمامی پارامترها باتوجه به تأثیری که بر خطای ایجادشده در شبکه دارند، تغییر پیدا می‌کنند. بعد از به‌روزرسانی پارامترها مرحله جلوسو و پس از آن مرحله پس انتشار تکرار می‌شود و نهایتاً بعد از تکرار تعداد مناسبی از این مراحل، آموزش شبکه به اتمام می‌رسد. در این فرایند، ابرپارامترهایی از قبیل نرخ آموزش، نرخ مومنتوم در فرایند گرادیان نزولی، نرخ متعادل‌سازی و غیره تعریف می‌شوند که تغییر در آن‌ها می‌تواند با تغییر در نرخ نهایی طبقه‌بندی همراه باشد.

در مرحله آزمایش نیز پس از وارد کردن داده تحت آزمایش به ورودی شبکه عصبی از پیش آموزش‌دیده‌شده در خروجی لایه انتهایی که لایه تماماً متصل است، میزان تعلق هر داده به کلاس‌های مختلف مشخص می‌شود.

در این پژوهش، برای بهبود عملکرد شبکه عصبی عمیق،

7. Convolution layer
8. Pooling layer
9. Fully connected layer
10. Feed forward
11. Backpropagation
12. Loss function
13. Chain rule

در فرمول شماره ۴ و ۵ منظور از «.» ضرب داخلی است. همچنین k معرف تکرار جاری بوده، \vec{O} و \vec{F} بردارهای ضرایب، \vec{X}^* بردار مکان بهترین راه حل به دست آمده جاری و نهایتاً \vec{X} بردار مکان است. در صورت وجود راه حل بهتر، \vec{X}^* در هر تکرار باید به روزرسانی شود. بردار \vec{O} و \vec{F} به صورت فرمول شماره ۶ و ۷ محاسبه می شود [۱۲]:

$$6. \vec{O} = 2\vec{a} \cdot \vec{r} - \vec{a}$$

$$7. \vec{F} = 2(\vec{r})$$

که \vec{a} به صورت خطی از مقدار ۲ تا صفر و در طی تکرارهای متوالی کم می شود (در هر ۲ فاز اکتشاف و استخراج) و \vec{F} نیز بردار تصادفی در فاصله صفر تا ۱ است. حاصل فرمول شماره ۶ با محاسبه ضرب داخلی مورد محاسبه قرار می گیرد.

روش حمله حباب تور (فاز استخراج)

برای مدل سازی رفتار حباب تور، ۲ روش زیر طراحی شده است که مورد بررسی قرار می گیرد:

مکانیسم محاصره انقباضی^{۱۹}

این رفتار از طریق افزایش مقدار \vec{a} در فرمول شماره ۶ حاصل می شود. به یاد داشته باشید که محدوده نوسان \vec{O} به وسیله \vec{a} کاهش می یابد. به عبارت دیگر، \vec{A} مقداری تصادفی در فاصله \vec{a} تا $-\vec{a}$ است و \vec{a} در طی تکرارها، از مقدار ۲ تا صفر کاهش می یابد. با انتخاب مقادیر تصادفی \vec{O} در فاصله ۱- تا ۱، می توان مکان جدید عامل جست و جو را در هر جایی بین مکان اصلی عامل و مکان بهترین عامل کنونی تعریف کرد.

مکان در حال به روزرسانی مارپیچی^{۲۰}

این روش در ابتدا فاصله بین نهنگ قرار گرفته در مختصات \vec{X} و \vec{Y} طعمه موجود در \vec{X}^* و \vec{Y}^* را محاسبه می کند. معادله ای مارپیچی بین موقعیت نهنگ و طعمه تشکیل شد تا حرکت حلزونی شکل نهنگ گوژپشت را تقلید کند (فرمول شماره ۸):

$$8. \vec{X}_{k+1} = \vec{D}' \cdot e^{bl} \cdot \cos(2\pi l) + \vec{X}_k^*$$

فرمول فوق به فاصله اولین نهنگ تا طعمه اشاره دارد (بهترین راه حل به دست آمده تا اینجا)، b ثابتی برای تعریف شکل مارپیچ لگاریتمی است و l عددی تصادفی بین ۱- تا ۱ است. نهنگ گوژپشت، حول طعمه در امتداد یک دایره انقباضی و هم زمان در مسیر مارپیچی شکلی شنا می کند. برای مدل سازی این رفتار هم زمان، فرض شده است که نهنگ با احتمال ۵۰ درصد از بین مکانیسم محاصره انقباضی و یا مدل مارپیچی یکی را انتخاب

در فرمول شماره ۳، λ پارامتر تنظیم است و F به عنوان پارامتر نرمال فروبینیوس^{۱۶} شناخته می شود و در واقع برابر با مجذور نرمال یک ماتریس خواهد بود. تعیین مقدار مناسب λ نیز از مسائل مهمی است که باید مدنظر قرار گیرد. این پارامتر وابسته به شرایط می تواند تنظیم شود؛ یعنی مقدار بالای وزن ها با در نظر گرفتن یک مقدار کم برای λ قابل کنترل خواهد بود و به طور مشابه مقدار زیاد برای λ به منظور تنظیم تأثیر بیشتر وزن ها در نظر گرفته می شود. از آنجایی که تابع هزینه باید حداقل سازی شود، تناسب مطرح شده منطقی به نظر می رسد و با اضافه کردن مجذور نرم ماتریس وزن ها و ضرب آن در پارامتر نظم دهی، وزن ها تنظیم می شوند و تابع هزینه کاهش می یابد.

در این مقاله، یکی از بهترین الگوریتم های تکاملی مورد استفاده قرار می گیرد، تا با کمک آن مقدار بهینه برای این ۳ ابرپارامتر پیدا شود. الگوریتم در نظر گرفته شده، الگوریتم وال نامیده می شود که در ادامه مورد بررسی قرار خواهد گرفت.

الگوریتم وال

در این بخش به معرفی الگوریتم فرا ابتکاری وال^{۱۷} پرداخته می شود که میرجلیلی و همکاران در سال ۲۰۱۶ (۱۳۹۴) ارائه کرده اند [۱۲]. نهنگ ها که یکی از بزرگترین موجودات عالم هستند، با نژادهای متفاوتی در سراسر گیتی حضور دارند. یکی از بزرگترین نژاد نهنگ ها، نهنگ گوژپشت است که ابعاد نهنگ گوژپشت حدود اندازه یک اتوبوس یا حتی بیشتر از آن است. نکته جالب در مورد این دسته از نهنگ ها، روش شکار کردن آن ها است. این رفتار تحت عنوان روش تغذیه حباب تور^{۱۸} نام گذاری شده است. اولویت نهنگ های گوژپشت شکار کریل ها و یا ماهی های کوچکی است که به صورت دسته ای در مجاورت سطح آب شنا می کنند. برای این منظور وال ها حباب های شاخصی در امتداد یک دایره یا مسیریابی مشخص ایجاد می کند و با این فرایند امکان تشخیص مکان شکار و محاصره ماهی ها برای نهنگ های گوژپشت فراهم خواهد شد. به دلیل اینکه مکان طراحی بهینه در فضای جست و جو از راه مقایسه تشخیص داده نمی شود، WOA فرض می کند که بهترین راه حل حاضر، شکار هدف است و بعد از اینکه بهترین عامل جست و جو شناسایی شد، سعی می شود عوامل دیگر جست و جو مکان خود را نسبت به بهترین عامل جست و جو، به روزرسانی کنند. این رفتار از طریق فرمول های ۴، ۵، ۶ و ۷ زیر بیان شده است [۱۱]:

$$4. \vec{D} = \left| \vec{F} \cdot \vec{X}_k^* - \vec{X}_k \right|$$

$$5. \vec{X}_{k+1} = \vec{X}_k^* - \vec{O} \cdot \vec{D}$$

16. Frobenius
17. Whale Optimization Algorithm
18. Bubble-net

19. Shrinking encircling mechanism
20. Spiral updating position

یافته‌ها

روش پیشنهادی

در این بخش، روش پیشنهادی که شامل قسمت‌های اساسی استخراج داده‌های ورودی و ازدیاد آن (داده افزایی)، شبکه عصبی عمیق کانولوشنی بهبودیافته و شبکه عصبی فازی تطبیقی است، به تفصیل بررسی می‌شود. در تصویر شماره ۲، این بخش‌های اساسی قابل ملاحظه است.

همان‌طور که در تصویر شماره ۲ قابل مشاهده است، اولین بخش مربوط به مجموعه داده‌ها است که در ادامه مورد بررسی قرار می‌گیرد. تلفیق ۲ طبقه‌بند موردنظر در سطح تصمیم است و مدل نهایی ساختاری دراد که از مزیت‌های هر ۲ طبقه‌بند بهره می‌گیرد. در توضیح بیشتر این شکل می‌توان به این نکته اشاره کرد که برای آموزش بهتر شبکه عصبی عمیق باتوجه به ضروری بودن تعداد بالای داده آموزشی استفاده از فرایند ازدیاد داده بسیار حائز اهمیت است، درحالی که برای سیستم تطبیقی استنتاج عصبی فازی^{۲۱} این نیاز کمتر محسوس است. نکته دیگر در این شکل، تلفیق ۲ طبقه‌بند در دستیابی به مدلی است که می‌توان از آن برای دسته‌بندی نهایی استفاده کرد. این مدل از ۲ طبقه‌بند آموزش دیده تشکیل شده است که نتایج پیاده‌سازی آن بر روی داده‌های جدید با ادغام در سطح تصمیم به دست می‌آید.

استخراج داده‌های ورودی

برای استخراج مجموعه داده‌گان مربوط به حس گر تلفن همراه از نرم‌افزار GeoTracker استفاده می‌شود. در تصویر شماره ۳ شمای کلی از نرم‌افزار موردنظر قابل مشاهده است.

در این نرم‌افزار اطلاعات مربوط به حس گر موقعیت تلفن همراه در مدت‌زمانی که فرد موردنظر از منزل خارج می‌شود، ذخیره می‌شود و در صورت اتصال به اینترنت در فضای ابری قابل بارگذاری و استفاده خواهد بود. این ذخیره‌سازی با فرمت KML صورت می‌گیرد. گام دوم انتقال اطلاعات با فرمت KML به نرم‌افزار QGIS است. با بهره‌گیری از این نرم‌افزار مسیر موردنظر استخراج می‌شود و در قالب یک تصویر در اختیار قرار می‌گیرد. روش پیشنهادی برای استخراج داده به صورت گرافیکی در تصویر شماره ۴ ارائه شده است. در این تصویر برای نمایش بهتر مسیر از نرم‌افزار گوگل ارث^{۲۲} بهره گرفته شده است. قبل از استفاده از مسیرها، فرایند پیش‌پردازش روی آن صورت می‌گیرد تا تصویر نهایی به صورت باینری آماده استفاده شود. مبدا و مقصد انتخاب شده شامل منزل تا نزدیک‌ترین مرکز درمانی به آن است که فرد سالمند جهت دریافت خدمات درمانی دوره‌ای به آنجا مراجعه می‌کند. داده‌های ثبت شده که در قالب ۷۲ مسیر

می‌کند تا موقعیت نهنگ‌ها در طول بهینه‌سازی به روزرسانی شود. مدل ریاضی بدین صورت است (فرمول شماره ۹):

$$9. \bar{X}_{k+1} = \begin{cases} \bar{X}_k^* - \bar{O} \cdot \bar{D} & \text{if } \varsigma < 0.5 \\ \bar{D}' \cdot e^{bl} \cdot \cos(2\pi Il) + \bar{X}_k^* & \text{if } \varsigma > 0.5 \end{cases}$$

در این فرمول ς عددی تصادفی بین صفر تا ۱ است. علاوه بر روش حساب تور، نهنگ‌های گوژپشت به صورت تصادفی به دنبال طعمه می‌گردند. مدل ریاضی جست‌وجو بدین صورت است:

جست‌وجوی برای طعمه (فاز اکتشاف)

روشی مشابه بر مبنای واریانس بردار \bar{O} را می‌توان جهت جست‌وجوی شکار (اکتشاف) به کار گرفت. در حقیقت، نهنگ‌های گوژپشت، بر طبق مکان یکدیگر، به صورت تصادفی به جست‌وجو می‌پردازند. بنابراین، بردار \bar{O} را با مقادیر تصادفی بزرگتر از ۱ و یا کمتر از ۱- به کار گرفته شد تا عامل جست‌وجو را مجبور به دور شدن از نهنگ مرجع کند. برخلاف فاز استخراج، برای به روزرسانی موقعیت عامل جست‌وجو در فاز اکتشاف به جای استفاده از داده‌های بهترین عامل جست‌وجو، از انتخاب تصادفی عامل بهره برده شده است. این مکانیسم به همراه $O > 1$ بر اکتشاف تأکید دارند و به WOA اجازه می‌دهند تا جست‌وجویی سراسری را انجام دهند. مدل ریاضی در فرمول شماره ۱۰ قابل مشاهده است:

$$10. \bar{D} = |\bar{F} \cdot \bar{X}_{rand} - \bar{X}|$$

$$11. \bar{X}_{k+1} = \bar{X}_{rand} - \bar{O} \cdot \bar{D}$$

در فرمول شماره ۱۱، \bar{X}_{rand} بردار موقعیت تصادفی انتخاب شده (نهنگ تصادفی) از جمعیت جاری است. الگوریتم WOA با مجموعه‌ای از راه‌حل‌های تصادفی شروع به کار می‌کند. در هر تکرار، عوامل جست‌وجو، موقعیت خود را باتوجه به عامل جست‌وجویی که تصادفی انتخاب شدند و با بهترین راه‌حل به دست آمده جاری، به روزرسانی می‌کنند. مؤلفه a برای فراهم آوردن اکتشاف و استخراج، به ترتیب از مقدار ۲ تا صفر کاهش می‌یابد. یک عامل جست‌وجوی تصادفی در حالت $|O| > 1$ انتخاب می‌شود، این در حالی است که بهترین راه‌حل زمانی انتخاب می‌شود که جهت به روزرسانی موقعیت عوامل جست‌وجو، $|O| < 1$ باشد. بسته به مقدار ς ، وال این قابلیت را دارد تا بین حرکت دایروی و یا مارپیچی، یکی را انتخاب کند. در نهایت، الگوریتم وال با ارضای شرایط خاتمه، پایان می‌گیرد. شبهه‌کد مربوط به الگوریتم فوق در تصویر شماره ۱ ارائه شده است [۱۲].

در انتها باید خاطرنشان کرد خروجی به دست آمده در این شبهه‌کد، عبارت است از مقدار بهینه ۳ ابرپارامتر که در نهایت در شبکه عصبی عمیق نهایی پیشنهادی این پژوهش مورد استفاده قرار خواهد گرفت.

21. ANFIS

22. Google Earth

1. مقداردهی اولیه به اجتماع نهنگ‌ها
 $X_i (i = 1, 2, 3, \dots, n)$ حداکثر تکرار در این الگوریتم است
2. محاسبه تناسب برای هر عامل جست‌وجو و تعیین بهترین عامل جست‌وجو X^*
3. تا زمانی که k از حداکثر تعداد تکرار کمتر باشد فرایند زیر را انجام بده:
4. برای هر عامل جست‌وجو
 O, F و l و ζ را به‌روزرسانی کن.
 اگر ζ کوچک‌تر از 0/5 بود.
 اگر O کوچک‌تر از l بود.
 با کمک معادله 4 موقعیت جست‌وجوی جاری را به‌روزرسانی کن.
 در غیر این صورت یک موقعیت جست‌وجوی تصادفی انتخاب کن.
 با معادله 11، موقعیت جست‌وجوی جاری را به‌روزرسانی کن.
 در غیر این صورت موقعیت جست‌وجو را با کمک معادله 8 به‌روزرسانی کن.
5. بررسی کن اگر هر موقعیت جست‌وجو از محدوده فضای جست‌وجو خارج شد، اصلاح شود.
6. تناسب برای هر موقعیت جست‌وجوی جدید محاسبه شود. مقدار X^* اگر پاسخ بهتری موجود بود، به‌روزرسانی شود.
- مقدار k را یکی اضافه کن.
7. مقدار X^* را در خروجی قرار بده.

طب توانبخش

تصویر ۱. روندنمای الگوریتم وال

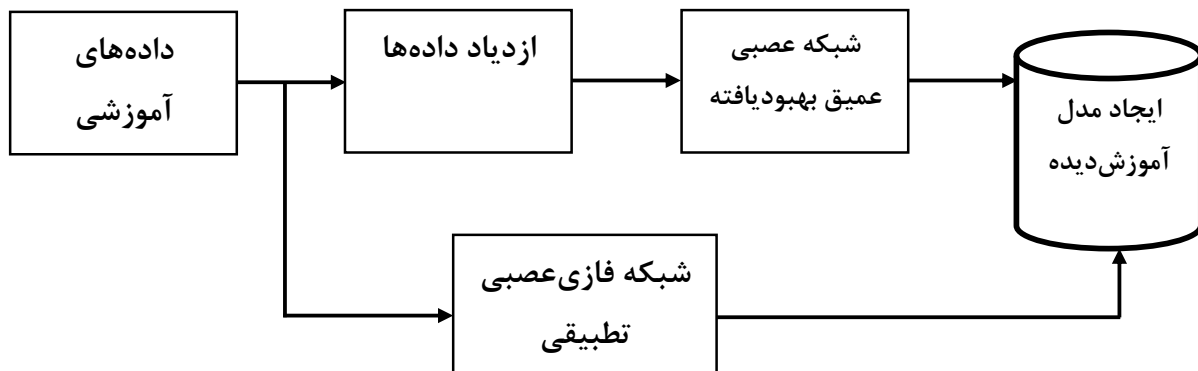
نیاز، گام بعد به آموزش طبقه‌بندی اختصاص خواهد یافت.

آموزش طبقه‌بندی

همان‌طور که در مقدمه بیان شد یکی از مهم‌ترین نوآوری‌های این پژوهش، بهره‌گیری از تلفیق ۲ طبقه‌بند است. طبقه‌بند شبکه عصبی عمیق بهبودیافته برای دستیابی به مدلی مناسب از داده‌های ورودی و طبقه‌بند مبتنی بر شبکه عصبی فازی برای دستیابی به انعطاف لازم در مواجهه با داده‌های ناهنجار جدید. در ابتدا شبکه عصبی عمیق کانولوشنی مورداستفاده همراه با فرایند موردنظر برای بهینه‌سازی آن مطرح و سپس طبقه‌بند بر پایه شبکه عصبی فازی بررسی می‌شود.

مجزا ذخیره‌شده است، دربرگیرنده جزئیات مسیر ثبت‌شده توسط حس‌گر موقعیت‌یاب تلفن همراه فرد سالمند طی ارتباط برخط با ماهواره‌های GPS بوده و به‌صورت آنی ذخیره شده است. دستگاه تلفن همراه مورداستفاده از برند سامسونگ مدل Galaxy S7 SM-G930FD بوده که به سیستم‌عامل اندروید نسخه ۶،۰،۱ مجهز است. حس‌گر موقعیت‌یاب این دستگاه دارای فناوری GLONASS است و با دقت ۳۰ سانتی‌متر به ثبت موقعیت می‌پردازد.

پس از فراهم کردن مجموعه داده‌ها برای ایجاد بستری مناسب در جهت آموزش بهتر شبکه عصبی عمیق، از فرایند ازدیاد داده بهره گرفته شده است. برای این منظور از شیوه‌های متعددی چون چرخش و انتقال در راستای عرض و انتقال در راستای طول استفاده شده است. در نتیجه پس از فراهم کردن داده‌های مورد



طب توانبخش

تصویر ۲. قسمت آموزش روش پیشنهادی

در فرایند بهینه‌سازی ابر پارامترها، ابتدا مقادیری تصادفی در محدوده‌های مشخص برای حالت اولیه ابر پارامترها تعیین می‌شود و با بهره‌گیری از آن‌ها شبکه عصبی کانولوشنی اولیه شکل می‌گیرد. در گام بعد با این مقادیر بر روی مجموعه دادگان اعتبارسنجی، شبکه فوق اجرا شد و باتوجه‌به اینکه برچسب داده‌های پیش‌گفت مشخص است، تابع هزینه محاسبه می‌شود. با بهره‌گیری از الگوریتم بهینه‌سازی وال و بهبود مقادیر ابر پارامترها در هر تکرار توسط آن، پیش‌بینی می‌شود که شبکه عصبی کانولوشنی مورد استفاده برای دسته‌بندی نهایی، همواره به سمت ساختار مناسب و قابل اطمینان تری پیش رود.

طبقه‌بندی مبتنی بر سیستم تطبیقی استنتاج عصبی فازی

سیستم تطبیقی استنتاج عصبی فازی را می‌توان یکی از کارآمدترین فرایندهای استنتاج فازی به شمار آورد که به‌علت بهره‌گیری از قاعده و قانون، همانند فرایندهای فازی است و به این دلیل که به‌صورت یک شبکه عصبی آموزش می‌بیند، شبکه عصبی است. به‌بیانی دیگر می‌توان گفت سیستم تطبیقی استنتاج عصبی فازی، یک شبکه قابل آموزش است که از نظر عملکرد کاملاً مشابه فرایند استنتاج فازی است و از مزیت‌های شبکه عصبی بهره می‌برد. در اینجا مفروض است که x و y دو ورودی شبکه مورد نظر و خروجی این شبکه نیز متغیر z است [۱۳]. حال اگر قوانین به‌صورت فرمول شماره ۱۲ باشند:

12.

Rule1: $f: x \in A_1 \text{ and } y \in B_1 \text{ then } f_1 = p_1x + q_1y + r_1$

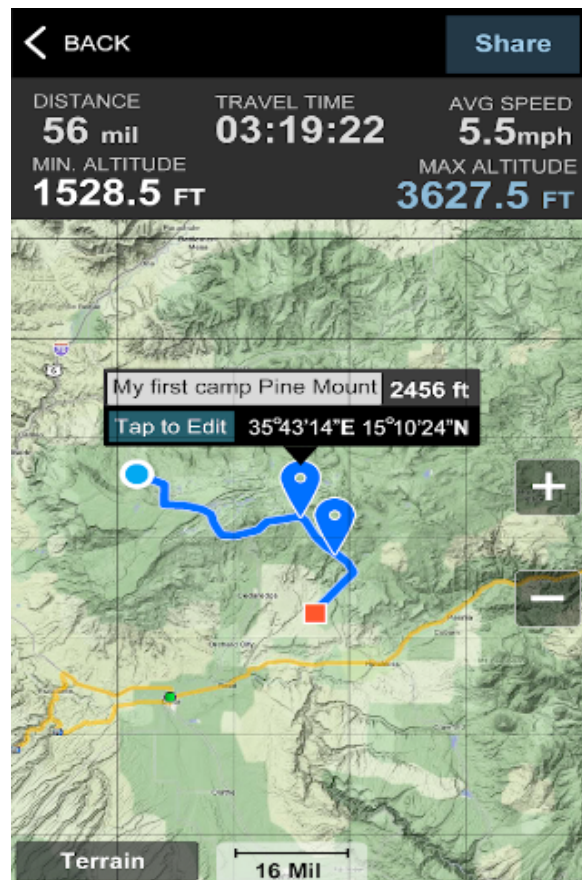
Rule2: $f: x \in A_2 \text{ and } y \in B_2 \text{ then } f_2 = p_2x + q_2y + r_2$

و اگر برای غیرفازی‌سازی از غیرفازی‌سازی میانگین مراکز استفاده شود، در نهایت ساختار معادل سیستم تطبیقی استنتاج عصبی فازی به‌صورت تصویر شماره ۶ خواهد بود:

در ادامه به تشریح لایه‌های انتخابی در فرمول‌های شماره ۱۳، ۱۴، ۱۵، ۱۶، ۱۷، ۱۸ و ۱۹ پرداخته می‌شود.



طب توانبخشی

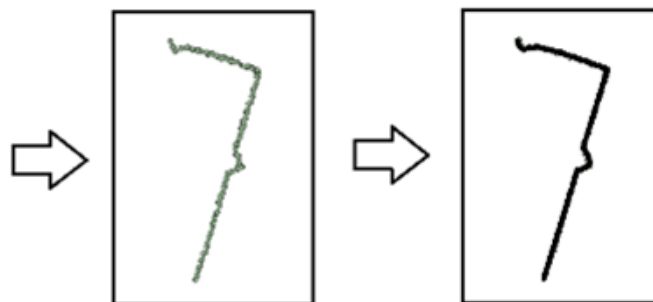


طب توانبخشی

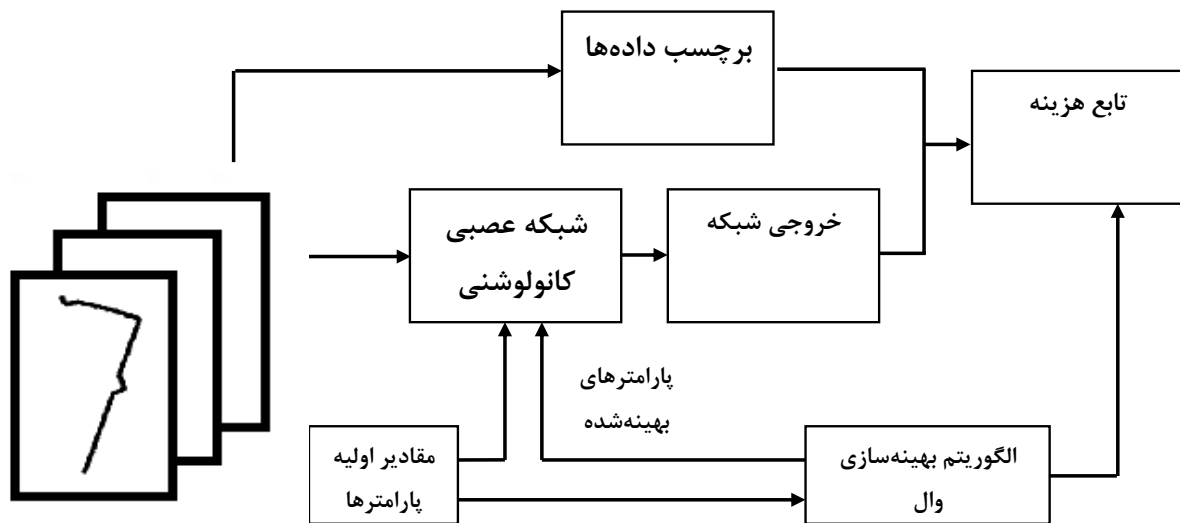
تصویر ۳. شمای کلی از نرم‌افزار GeoTracker

شبکه عصبی عمیق بهبود یافته

چنانچه در قسمت‌های قبل عنوان شد، نرخ آموزش اولیه، مومنتوم و نرخ متعادل‌سازی L2، ابرپارامترهایی هستند که ضرورت دارد تحت فرایند بهینه‌سازی مقدار مناسب آن‌ها با به‌کارگیری فرایند بهینه‌سازی تعیین شود. در این بخش ساختاری که در آن ابر پارامترها بهینه‌سازی می‌شوند، ارائه می‌شود. در تصویر شماره ۵ بلوک دیاگرام مربوط به این ساختار قابل مشاهده است.



تصویر ۴. فرایند استخراج مسیر



تصویر ۵. ساختار بهینه‌سازی شبکه عصبی کانولوشنی

طب توانبخش

مجموع ساختار تشریح شده در بالا شبکه سیستم تطبیقی استنتاج عصبی فازی مورد استفاده را شکل می‌دهد. باتوجه به حاصل پژوهش‌های صورت گرفته بر روی طبقه‌بندی‌هایی بر مبنای این ساختار، می‌توان درصد صحت بسیار خوبی را از آن متصور شد.

اعتبارسنجی

در پژوهش‌های مرتبط با حوزه بینایی ماشین و بازشناسی الگو از معیارهای متفاوتی جهت اعتبارسنجی مدل و ارزیابی نتایج استفاده می‌شود، از جمله این معیارها می‌توان به صحت^{۲۴}، حساسیت^{۲۵} و قدرت تشخیص^{۲۶} اشاره کرد که ۳ مؤلفه مهم برای ارزیابی نتیجه یک دسته‌بندی دوحالتی یا دودویی هستند. زمانی که بتوان داده‌ها را به ۲ گروه تقسیم کرد، دقت نتایج یک آزمایش که اطلاعات را به این ۲ دسته تقسیم می‌کند، با استفاده از این ۳ شاخص قابل اندازه‌گیری و توصیف است. حساسیت بیانگر نسبتی از موارد مثبت است که آزمایش، آن‌ها را به درستی به عنوان مثبت علامت گذاری می‌کند. قدرت تشخیص به معنا و مفهوم نسبتی از موارد منفی است که آزمایش، آن‌ها را به درستی به عنوان منفی علامت گذاری می‌کند. میزان صحت نیز عملکرد طبقه‌بند را روی هر ۲ دسته به طور هم‌زمان مورد سنجش قرار می‌دهد.

به طور کلی برای محاسبه معیارهای صحت، قدرت تشخیص و حساسیت، ابتدا چهار مؤلفه زیر باید مورد محاسبه قرار گیرند: مثبت صحیح^{۲۷}: داده ناهنجار، به درستی ناهنجار تشخیص داده شود.

لایه ۱: در این لایه ورودی‌ها از توابع عضویت^{۲۳} عبور می‌کنند.

$$13. O_{1,i} = \mu A_i(x), \quad \text{for } i = 1, 2$$

$$14. O_{1,i} = \mu B_i(x), \quad \text{for } i = 3, 4$$

توابع عضویت هر تابع در اکثر موارد به صورت توابع گوسی انتخاب می‌شود که به صورت یک تابع زنگی شکل خواهد بود:

$$15. \mu A(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b_i}}$$

که $\{a_i, b_i, c_i\}$ مجموعه پارامترها هستند. پارامترهای این لایه به پارامترهای اولیه معروف هستند.

لایه ۲: خروجی این لایه ضرب سیگنال‌های ورودی است که درواقع معادل قسمت اگر قوانین هستند.

$$16. O_{2,i} = w_i = \mu A_i(x) \mu B_i(y) \quad i = 1, 2$$

لایه ۳: خروجی این لایه متعادل سازی شده لایه قبلی است:

$$17. O_{3,i} = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2$$

لایه ۴: خروجی این لایه نیز به صورت زیر خواهد بود:

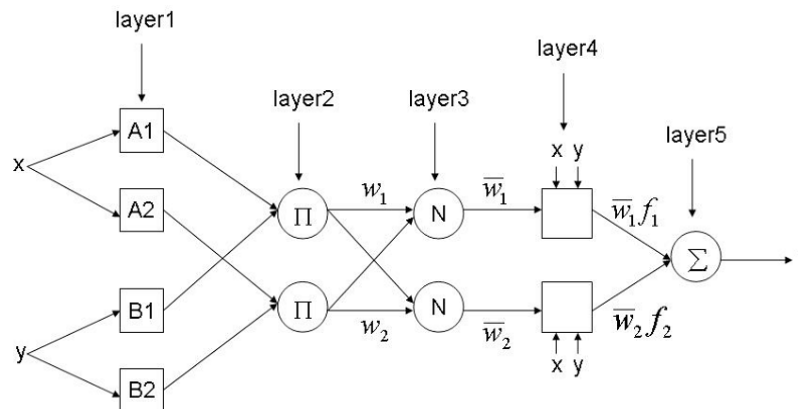
$$18. O_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i)$$

لایه ۵: خروجی این لایه نیز خروجی کلی سیستم است:

$$19. O_{5,i} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$$

- 24. Accuracy
- 25.1 Sensitivity
- 26.2 Specificity
- 27. True Positive

23. Membership Functions (MF)



تصویر ۶. ساختار شبکه سیستم تطبیقی استنتاج عصبی فازی

$$22. Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

ابزار دیگری که می‌توان در جهت ارزیابی استفاده کرد، ابزار ماتریس درهم‌ریختگی است که به‌صورت بصری تمام مؤلفه‌های فوق را دربر می‌گیرد. در تصویر شماره ۷ این اطلاعات قابل ملاحظه است.

پس از بررسی جزئیات روش پیشنهادی و معیارهای ارزیابی، به شبیه‌سازی و یافتن نتایج خروجی پرداخته می‌شود تا در نهایت بتوان شیوه پیشنهادی را تحلیل کرد.

آزمایش‌ها و نتایج شبیه‌سازی

پس از مطرح کردن جزئیات، قواعد و اصول روش پیشنهادی در این قسمت، شبیه‌سازی آن بررسی شده است و نتایج حاصل از آن هم بررسی می‌شود.

معرفی پایگاه داده

یکی از مهم‌ترین بخش‌های پیاده‌سازی هر روش، ماشین بینایی و بازشناسی الگویی بهره‌گیری از پایگاه داده‌ای است که قابلیت بالایی از خود در ارزیابی مناسب از روش پیشنهادی ارائه دهد. برای این پژوهش از مجموعه دادگانی متشکل از ۴۶ مسیر نرمال و ۲۶ مسیر ناهنجار که در تصویر شماره ۸ قابل مشاهده می‌باشند، استفاده شده است.

در شکل فوق، مسیرهای هنجار در سمت چپ بالا و پایین و با رنگ قرمز و مسیرهای ناهنجار در قسمت راست بالا و پایین و با رنگ سبز قابل مشاهده است. مسیرهای هنجار مسیریایی هستند که در دسته مسیرهای عادی فرد، از مبدأ منزل به مقصد مرکز درمانی موردنظر قرار می‌گیرند و مسیرهای ناهنجار مواردی هستند که با طی مسیری غیرعادی بین این دونقطه برقرار می‌شوند. از میان ۷۲ مسیر فوق، ۷۰ درصد برای آموزش

مثبت کاذب^{۲۸}: داده هنجار، به اشتباه ناهنجار تشخیص داده شود.

منفی صحیح^{۲۹}: داده هنجار، به‌درستی هنجار تشخیص داده شود.

منفی کاذب^{۳۰}: داده ناهنجار، به اشتباه هنجار تشخیص داده شود.

به بیان ریاضی، حساسیت حاصل تقسیم موارد مثبت واقعی به حاصل جمع موارد مثبت واقعی و موارد منفی کاذب است (فرمول شماره ۲۰).

$$20. Sensitivity = \frac{TP}{TP + FN}$$

منظور از TP مثبت صحیح و FN منفی کاذب است.

به همین ترتیب، قدرت تشخیص حاصل تقسیم موارد منفی واقعی به حاصل جمع موارد منفی واقعی و مثبت کاذب است (فرمول شماره ۲۱).

$$21. Specificity = \frac{TN}{TN + FP}$$

منظور از TN منفی صحیح و FP مثبت کاذب است.

مؤلفه صحت، متداول‌ترین، اساسی‌ترین و ساده‌ترین معیار اندازه‌گیری کیفیت یک دسته‌بند است و عبارت است از میزان تشخیص صحیح دسته‌بند در مجموع ۲ دسته. این کمیت درواقع نشان‌گر میزان الگوهایی است که درست تشخیص داده شده‌اند و براساس ماتریس درهم‌ریختگی، به شکل فرمول شماره ۲۲ تعریف می‌شود.

- 28. False Positive
- 29. True Negative
- 30. False Negative

سیستم و ۳۰ درصد برای آزمودن آن مورداستفاده قرار گرفته است. انتخاب داده‌ها به صورت هم وزن و تصادفی انجام شده که در نهایت ۲۲ مسیر هنجار و ۸ مسیر ناهنجار را در زمره داده‌های آزمون قرار می‌دهد.

تنظیمات شبکه عصبی کانولوشنی

برای شبیه‌سازی روش پیشنهادی از یک شبکه عصبی عمیق با لایه‌های زیر استفاده شده است که در ادامه به تشریح آن پرداخته می‌شود.

لایه ورودی با ابعاد (۱، ۳۲، ۳۲) مطابق ورودی است که البته تمام تصاویر مربوط به داده‌ها به این ابعاد تغییر سایز پیدا می‌کنند تا یکسان‌سازی صورت گیرد.

۱. لایه کانولوشنی ابعاد فیلترها (۳، ۳)، اندازه گام ۱؛

۲. لایه متعادل‌سازی دسته‌ای؛

۳. لایه رلو؛

۴. جمع‌بندی بیشینه؛

۵. لایه کانولوشنی ابعاد فیلترها (۳، ۳)، اندازه گام ۱؛

۶. لایه متعادل‌سازی دسته‌ای؛

۷. لایه رلو؛

۸. جمع‌بندی بیشینه؛

۹. لایه کانولوشنی ابعاد فیلترها (۳، ۳)، اندازه گام ۱؛

۱۰. لایه متعادل‌سازی دسته‌ای؛

۱۱. لایه رلو؛

۱۲. لایه جمع‌بندی میانگین؛

۱۳. لایه تماماً متصل؛

۱۴. لایه سافتمکس؛

۱۵. لایه طبقه‌بندی خروجی.

تنظیمات آموزش شبکه نیز به این صورت در نظر گرفته شده است که نرخ آموزش اولیه α و قاعده یادگیری بر مبنای گرادیان نزولی با مومنتوم μ و تعداد تکرارها ۵۰ و نرخ متعادل‌سازی R ، نرخ کناره‌گیری از عضویت $0/1$ مورداستفاده قرار گرفته برای ازدیاد داده‌ها نیز از قاعده چرخش و انتقال در جهت x و y با نرخ چرخش منفی ۱۰ تا مثبت ۱۰ درجه و نرخ انتقال منفی ۴ تا مثبت ۴ پیکسل بهره گرفته شده است. تعداد داده‌ها را تا ۱۲۸۰ برابر افزایش می‌دهد، به عبارت دیگر تعداد مسیرهای آموزشی از ۴۲ مسیر به ۵۳۷۶۰ مسیر ارتقا پیدا می‌کند. مقادیر نرخ آموزش اولیه، مومنتوم و نرخ متعادل‌سازی $L2$ در هر تکرار تحت بهینه‌سازی قرار می‌گیرد تا نهایتاً به بهینه‌ترین مقدار خود دست پیدا کند.

تنظیمات شبکه سیستم تطبیقی استنتاج عصبی فازی

شبکه سیستم تطبیقی استنتاج عصبی فازی مورداستفاده در این پژوهش از نوع سوگنو [۱۳] و تابع مثلثی با $E=0/1514$ و $R^2=0/97$ که در آن تعداد قوانین ۱۰ در نظر گرفته شده است. تعداد توابع عضویت مورداستفاده برابر ۲ و تعداد تکرارها برابر ۵۰ لحاظ شده است.

کلاس واقعی

ناهنجار (۰) هنجار (۱)

کلاس خروجی	ناهنجار (۰)	مثبت صحیح (TP)	منفی کاذب (FN)	حساسیت $Sensitivity = \frac{TP}{TP + FN}$
	ناهنجار (۰)	مثبت کاذب (FP)	منفی صحیح (TN)	قدرت تشخیص $Specificity = \frac{TN}{TN + FP}$
	ناهنجار (۰)	دقت $Precision = \frac{TP}{TP + FP}$	ارزش پیشگویی منفی $Negative p.v. = \frac{TN}{TN + FN}$	صحت $Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$



تصویر ۸. نمونه‌های از مسیرهای مورد استفاده (سمت چپ: مسیرهای هنجار، سمت راست: مسیرهای ناهنجار)

طبتوانبخش

نتایج شبیه‌سازی

شبکه CNN در تشخیص داده‌های هنجار بهتر عمل می‌کند.

در مجموع روش سیستم تطبیقی استنتاج عصبی فازی روی تمام داده‌ها عملکرد بهتری دارد. در **تصاویر شماره ۹-الف**، عملکرد شبکه کانولوشنی قبل از بهینه‌سازی ابرپارامترهای آن نشان داده شده است و در این پژوهش در نهایت از الگوریتم بهینه‌سازی شده CNN استفاده شد که متعاقباً توضیحات لازم ارائه می‌شود. این **شکل** تنها برای یک مقایسه اولیه مورد استفاده قرار گرفته است. با توجه به تفاوت عملکرد این ۲ شبکه بر روی داده‌های هنجار و داده‌های ناهنجار، پیش‌بینی می‌شود تلفیق این ۲ شبکه بتواند با نتایج خوبی همراه باشد، اما قبل از آن در ادامه به بهینه‌سازی شبکه CNN با الگوریتم‌های متنوع بهینه‌سازی پرداخته می‌شود تا مناسب‌ترین شبکه CNN را برای دستیابی به نتیجه بهتر با سیستم تطبیقی استنتاج عصبی فازی تلفیق شود.

تصاویرهای ۹-ج، ۹-د و ۹-ه دربرگیرنده نتایج حاصل از طبقه‌بند مبتنی بر شبکه CNN می‌باشند که به ترتیب با استفاده از الگوریتم‌های PSO، GA و وال ابرپارامترهای آن بهینه‌سازی شده است.

با ارزیابی نتایج حاصله در حالات مختلف بهینه‌سازی شبکه CNN و بدون بهینه‌سازی آن، می‌توان دریافت که ایده مورد استفاده در زمینه بهینه‌سازی ابرپارامترها با کمک الگوریتم‌های تکاملی مؤثر واقع شده است و بهبود چشمگیری در درصد صحت به دست آمده حاصل شده است.

با مقایسه تصاویر **۹-ج، ۹-د و ۹-ه** می‌توان دریافت که الگوریتم بهینه‌سازی وال نسبت به دو الگوریتم PSO و GA عملکرد بهتری از خود در بهینه‌سازی ابرپارامترهای CNN نشان داده که در نهایت به نتیجه بهتری منجر شده است.

با مقایسه نتایج حاصل از **تصاویر ۹-ب و ۹-ه** نیز می‌توان ملاحظه کرد که همچنان استفاده از الگوریتم سیستم تطبیقی استنتاج عصبی فازی شناخت خوبی در تشخیص موارد ناهنجاری

در این بخش نتایج حاصل از شبیه‌سازی مورد بررسی قرار می‌گیرد. قبل از آن باید خاطرنشان شد کلیه نتایج حاصل از شبیه‌سازی در رایانه‌ای با مشخصات CORI9 GPU 1080TITAN و GEFORCE 64GRAM واقع در مرکز محاسبات سنگین دانشگاه فردوسی مشهد پیاده‌سازی شده است. سیستم عامل مورد استفاده ویندوز ۱۰ و کلیه محاسبات با نرم افزار متلب^{۳۱} انجام شده است. در ابتدا مقدار بهینه به دست آمده برای مؤلفه‌های شبکه CNN را در **جدول شماره ۱** ملاحظه می‌شود. برای به دست آوردن نتایج **جدول شماره ۱**، ۲۰ بار مقدار تصادفی برای مقدار اولیه ابرپارامترها در محدوده مشخص قابل تعریف، تعیین شد و میانگین و واریانس مقادیر نهایی به دست آمده برای آن‌ها پس از اجرای کد برای این ۲۰ مرتبه در **جدول شماره ۱** گزارش شد. برای مقایسه بهتر روش پیشنهادی، به جای الگوریتم وال از الگوریتم PSO و GA نیز برای بهینه‌سازی پارامترها بهره گرفته شد که در نهایت مقادیر نهایی برای این ۳ حالت نیز در **جدول شماره ۱** قابل مشاهده است. برای این شبیه‌سازی از الگوریتم GA با اندازه جمعیت اولیه ۱۰۰، تعداد دفعات تکرار الگوریتم (تعداد نسل‌ها) ۱۰ و نرخ جهش ۱ درصد استفاده شده است. الگوریتم PSO با مشخصات ابعاد جمعیت اولیه ۱۰۰، نرخ میرایی ۰/۹۹، ضریب شتاب شخصی ۲، ضریب شتاب جمعی ۲ و الگوریتم وال نیز با مشخصات جمعیت اولیه ۱۰۰ مورد استفاده قرار گرفته است.

در این قسمت برای ارائه نتایج در گام نخست، ابتدا شبکه CNN بدون بهینه‌سازی مورد استفاده قرار گرفت که در **تصویر ۹-الف** نتیجه حاصل مشاهده می‌شود. در گام بعد شبکه سیستم تطبیقی استنتاج عصبی فازی مورد استفاده را به داده‌ها اعمال شدند. در **تصویر ۹-ب**، نتایج حاصله نشان داده شده است. با مقایسه **تصاویر ۹-الف و ۹-ب** می‌توان دریافت که عملکرد شبکه سیستم تطبیقی استنتاج عصبی فازی روی داده‌های ناهنجار و

31. MATLAB 2019a

جدول ۱. مقدار نهایی به دست آمده برای ابر پارامترها در فرایند بهینه سازی

ابری پارامتر	مقادیر نهایی با الگوریتم GA		مقادیر نهایی با الگوریتم PSO		مقادیر نهایی با الگوریتم وال	
	واریانس	میانگین	واریانس	میانگین	واریانس	میانگین
نرخ آموزش اولیه (α)	۰/۰۰۰۲	۰/۰۱۱۳	۰/۰۰۰۱	۰/۰۱۱	$6e^{-2}$	۰/۰۱۰۶
مومنتوم (μ)	۰/۰۰۱۷	۰/۹۱۳	۰/۰۰۰۹	۰/۹۴۲	$8e^{-2}$	۰/۹۷۱
نرخ تنظیم L2 (R)	$9e^{-10}$	$3/7e^{-8}$	$7e^{-11}$	$6/3e^{-9}$	$1e^{-12}$	$4/77e^{-9}$

طب توانبخش

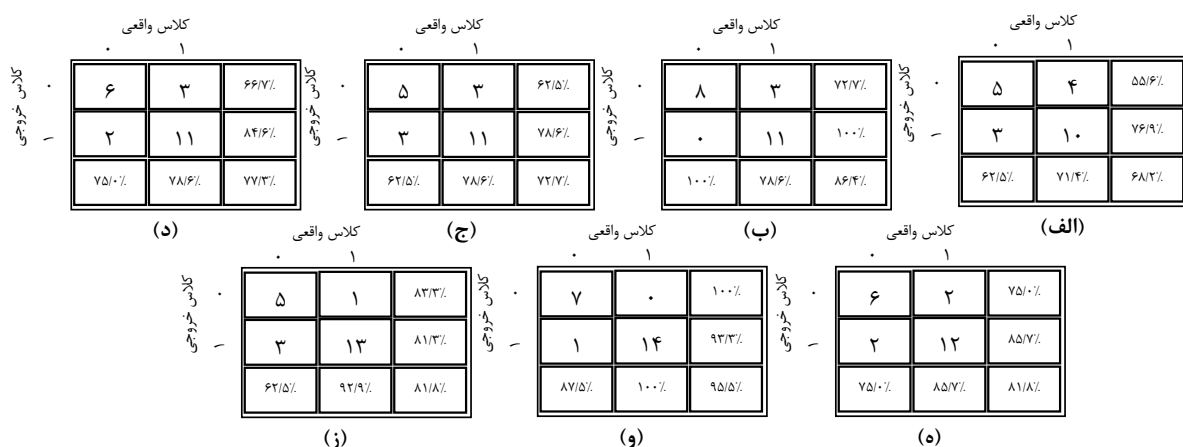
در پی داشته است، در حالی که CNN در تشخیص الگوهای پیچیده در داده های هنجار موفق تر عمل کرده است. در نتیجه پیش بینی می شود تلفیق این دو ابزار امکان تشخیص ناهنجاری را در کنار رویدادهای هنجار با دقت خوبی فراهم آورد. در نهایت با مشخص شدن عملکرد بهتر الگوریتم وال و بهره گیری از آن در بهینه سازی ابر پارامترها و تلفیق آن با سیستم تطبیقی استنتاج عصبی فازی نتایج حاصل این حالت نهایی، در تصویر شماره ۹-و قابل مشاهده است.

نتایج حاصل در تصویر شماره ۹-و حاکی از صحت فرضیه در نظر گرفته شده برای کارآمد بودن این حالت نهایی است. با این حال برای ارزیابی کامل تر روش پیشنهادی روش F-RCNN که در پژوهش [۱۰] پیشنهاد شده است نیز بر روی مجموعه دادگان پیاده سازی شده که حاصل اعمال آن و عملکردش روی مجموعه داده های فوق به صورت تصویر شماره ۹-ز خواهد بود. همان طور که در تصویر ۹-ز مشهود است، این روش عملکرد ضعیف تری نسبت به روش پیشنهادی دارد.

برای ارزیابی بهتر روش پیشنهادی، علاوه بر فرایند فوق از روش ارزیابی متقابل ۱۰ بخشی^{۳۲} نیز استفاده شد. در این رویکرد، نخست کل داده ها به ۱۰ بخش که در هر قسمت به تعدادی یکسان داده از هر کلاس وجود داشت، تقسیم شد. سپس از ۹ بخش برای آموزش سیستم به کیفیتی که در بخش پیشین ارائه شد، استفاده و از ۱ بخش برای آزمودن آن بهره گرفته شد. این فرایند تا زمانی که تمام داده ها در فرایند آموزش و آزمایش حضور داشته باشند، ادامه یافت. درصد صحت به دست آمده از این رویکرد به صورت میانگین برای ۱۰ بار اجرا برابر با ۹۴/۲۸ درصد به دست آمد که با نتایج قبلی سازگار است.

با ارزیابی نتایج حاصل از تمامی شکل ها و نتایج فوق می توان دریافت که روش پیشنهادی امکان تشخیص ناهنجاری را در کنار رویدادهای هنجار با دقت خوبی در پی داشته است، به عبارت دیگر می تواند نتایج حاصل از شبیه سازی صورت گرفته را سندی بر عملکرد خوب روش پیشنهادی و جوابگو بودن ایده پیشنهادی در فرایند تشخیص ناهنجاری دانست.

32. 10 fold cross validation



طب توانبخش

تصویر ۹-الف) ماتریس درهم ریختگی در حالت استفاده مجدد از CNN قبل از بهینه سازی ابر پارامترها، (ب) ماتریس درهم ریختگی در حالت استفاده مجدد از ANFIS (ج) ماتریس درهم ریختگی در حالت استفاده از CNN بعد از بهینه سازی ابر پارامترها با الگوریتم بهینه سازی GA، (د) ماتریس درهم ریختگی در حالت استفاده از CNN بعد از بهینه سازی ابر پارامترها با الگوریتم بهینه سازی PSO، (ه) ماتریس درهم ریختگی در حالت استفاده از CNN بعد از بهینه سازی ابر پارامترها با الگوریتم بهینه سازی وال، (و) ماتریس درهم ریختگی در حالت بهینه سازی شده نهایی، (ز) ماتریس درهم ریختگی در حالت روش F-RCNN.

نتیجه گیری

تشکر و قدردانی

از مرکز محاسبات نرم و پردازش هوشمند اطلاعات در دانشگاه فردوسی مشهد به دلیل پشتیبانی سخت افزاری از این تحقیق قدردانی می شود.

در این مقاله، روشی نوین در جهت تشخیص ناهنجاری در مسیر ثبت شده توسط حس گر GPS تلفن همراه برای مراقبت از سالمندان ارائه شده است. روش پیشنهادی بر پایه بهره گیری از ۲ طبقه بند شبکه های عصبی عمیق کانولوشنی بهینه سازی شده و شبکه سیستم تطبیقی استنتاج عصبی فازی استوار است.

یکی از نوآوری های مطرح شده در این مقاله بهره گیری از الگوریتم بهینه سازی وال برای دستیابی به ساختار مناسب شبکه عصبی کانولوشنی با تعیین بهترین مقدار برای ابر پارامترهای نرخ آموزش اولیه، نرخ مومنتوم و نرخ متعادل سازی مربوط به آن است.

در این مقاله نشان داده شد، در نهایت این فرایند بهینه سازی به یک ساختار کارآمد منتهی خواهد شد و دستیابی به صحت ۹۵/۵ درصد در قیاس با صحت ۷۷/۳ درصد روی داده های آزمایشی برای حالت بدون بهینه سازی و صحت ۸۱/۸ درصد برای روش رقیب نیز خود گواهی بر عملکرد مطلوب روش است.

در نهایت در تشریح بیشتر یافته های این پژوهش می توان اظهار کرد که با ارزیابی نتایج حاصل از تمامی شکل ها و نتایج فوق می توان دریافت که روش پیشنهادی امکان تشخیص ناهنجاری را در کنار رویدادهای هنجار با دقت خوبی در پی داشته است. به عبارت دیگر می تواند نتایج حاصل از شبیه سازی صورت گرفته را سندی بر عملکرد خوب روش پیشنهادی و جوابگو بودن ایده پیشنهادی در فرایند تشخیص ناهنجاری دانست.

ملاحظات اخلاقی

پیروی از اصول اخلاق پژوهش

در این مقاله هیچ نمونه انسانی و حیوانی ندارد و ملاحظات اخلاقی وجود نداشته است تا ضرورت رعایت در این تحقیق در نظر گرفته شود.

حامی مالی

این مقاله برگرفته از پایان نامه مجتبی بنی فخر با راهنمایی دکتر محمد تقی صادقی گروه برق دانشگاه یزد می باشد.

مشارکت نویسندگان

تمام نویسندگان در آماده سازی این مقاله مشارکت داشتند.

تعارض منافع

بنابر اظهار نویسندگان، این مقاله تعارض منافع ندارد.

References

- [1] Lin Q, Zhang D, Connelly K, Ni H, Yu Z, Zhou X. Disorientation detection by mining GPS trajectories for cognitively-impaired elders. *Pervasive and Mobile Computing*. 2015; 19:71-85. [DOI:10.1016/j.pmcj.2014.01.003]
- [2] Zhao J, Yi Z, Pan S, Zhao Y, Zhao Z, Su F, et al. Unsupervised traffic anomaly detection using trajectories. Paper presented at: 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). 20 June 2019; Long Beach, California. [Link]
- [3] Angermueller C, Pärnamaa T, Parts L, Stegle O. Deep learning for computational biology. *Molecular Systems Biology*. 2016; 12(7):878. [DOI:10.15252/msb.20156651] [PMID] [PMCID]
- [4] Amodei D, Ananthanarayanan S, Anubhai R, Bai J, Battenberg E, Case C, et al. Deep speech 2: End-to-end speech recognition in english and mandarin. Paper presented at: Proceedings of The 33rd International Conference on Machine Learning. 11 June 2016; New York, US. [Link]
- [5] Witten IH, Frank E. Data mining: Practical machine learning tools and techniques with Java implementations. *ACM SIGMOD Record*. 2002; 31(1):76-7. [DOI:10.1145/507338.507355]
- [6] LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015; 521(7553):436-44. [DOI:10.1038/nature14539] [PMID]
- [7] Žunić E, Delalić S, Hodžić K, Tucaković Z. Innovative GPS data anomaly detection algorithm inspired by qrs complex detection algorithms in ECG signals. Paper presented at: IEEE EUROCON 2019 -18th International Conference on Smart Technologies. 1 July 2019; Novi Sad, Serbia. [DOI:10.1109/EUROCON.2019.8861619]
- [8] Barucija E, Mujcinovic A, Muhovic B, Zunic E, Donko D. Data-driven approach for anomaly detection of real GPS trajectory data. Paper presented at: 2019 XXVII International Conference on Information, Communication and Automation Technologies (ICAT). 20 October 2019; Sarajevo, Bosnia and Herzegovina. [DOI:10.1109/ICAT47117.2019.8938938]
- [9] Dabiri S, Heaslip K. Inferring transportation modes from GPS trajectories using a convolutional neural network. *Transportation Research Part C: Emerging Technologies*. 2018; 86:360-71. [DOI:10.1016/j.trc.2017.11.021]
- [10] Shine L, Edison A, Jiji CV. A comparative study of faster R-CNN models for anomaly detection in 2019 AI city challenge. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. 2019; 306-14. [Link]
- [11] Davis N, Raina G, Jagannathan K. A framework for end-to-end deep learning-based anomaly detection in transportation networks. *Transportation Research Interdisciplinary Perspectives*. 2020; 5:100112. [DOI:10.1016/j.trip.2020.100112]
- [12] Mirjalili S, Lewis A. The whale optimization algorithm. *Advances in Engineering Software*. 2016; 95:51-67. [DOI:10.1016/j.advengsoft.2016.01.008]
- [13] Jang JSR. ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*. 1993; 23(3):665-85. [DOI:10.1109/21.256541]