

طراحی مدلی برای طبقه‌بندی داده‌های جریانی با استفاده از یادگیری تقویتی و گرادیان کاهشی تصادفی

سمیرا فرزانه^۱، دانشجوی کارشناسی ارشد، جواد سلیمی سرتختی^{۲*}، استادیار

^۱ دانشکده مهندسی برق و کامپیوتر - دانشگاه کاشان - کاشان - ایران - samira.farzaneh@grad.kashanu.ac.ir

^۲ دانشکده مهندسی برق و کامپیوتر - دانشگاه کاشان - کاشان - ایران - salimi@kashanu.ac.ir

چکیده: حجم وسیعی از تحقیقات در زمینه یادگیری برخط به مسئله غلبه بر فراموشی فاجعه‌بار تمرکز کرده‌اند و تحقیقات اندکی در زمینه طبقه‌بندی داده‌های جریانی با صحت و زمان اجرای مناسب تمرکز کرده‌اند. از سوی دیگر، به دلیل حجم و نوع داده‌های جریانی بسیاری از الگوریتم‌های سنتی یادگیری ماشین به خود کارایی لازم هنگام مواجهه با آنها را ندارند. بنابراین، در این مقاله برای طبقه‌بندی داده‌های جریانی با صحت و زمان یادگیری مناسب یک مدل جدید با استفاده از یادگیری تقویتی و الگوریتم گرادیان کاهشی تصادفی ارائه شده است. یکی از قابلیت‌های مهم یادگیری تقویتی این است که عامل می‌تواند رفتار خود را به تدریج با تغییراتی که رخ می‌دهد سازگار کند و به صورت تدریجی بر دانش قبلی خود بیافزاید. در این پژوهش به دلیل استفاده از یادگیری تقویتی و تعریف پاداش، عامل عملکرد بهتری در محیط دارد. الگوریتم پیشنهادی بر روی داده‌های مختلف از جمله مجموعه داده جریانی تشخیص فعالیت‌های انسانی آزمایش شده و از لحاظ صحت و زمان اجرا با چندین الگوریتم افزایشی مقایسه شده است. طبق نتایج آزمایشگاهی الگوریتم پیشنهادی بهترین کارایی را هم از نظر صحت و هم از نظر زمان اجرا در مقایسه با سایر الگوریتم‌های افزایشی دارد.

واژه‌های کلیدی: داده‌های جریانی، صحت و زمان اجرا، گرادیان کاهشی تصادفی، یادگیری افزایشی، یادگیری

تقویتی

* نویسنده مسئول: جواد سلیمی سرتختی، ایمیل: salimi@kashanu.ac.ir

Designing a Model for Data Stream Classification Using RL and SGD

Samira Farzaneh ¹, Masters Student, Javad Salimi Sartakhti ^{2*}, Assistant Professor

¹ Faculty of Electrical and Computer Engineering, University of Kashan, Kashan, Iran,
samira.farzaneh@grad.kashanu.ac.ir

² Faculty of Electrical and Computer Engineering, University of Kashan, Kashan, Iran, salimi@kashanu.ac.ir

Abstract: A large amount of research in the field of online learning has focused on the problem of overcoming catastrophic forgetting, and few researches have been focused on the classification of the data stream with appropriate accuracy and running time. On the other hand, due to the volume and type of data stream, many traditional machine learning algorithms do not have the necessary efficiency when faced with it.

Thus, in this paper, a novel model using reinforcement learning and stochastic gradient descent algorithm is presented for classification stream data with appropriate accuracy and running time. One of the important features of reinforcement learning is that the agent can adapt its behaviour gradually to the changes that occur and gradually add to its previous knowledge. In this research, because of the using of reinforcement learning and definition of reward, the agent has a better performance in the environment. The proposed algorithm has been tested on various data, including the dataset of human activity recognition, and compared with several incremental algorithms in terms of accuracy and running time. According to the experimental results, the proposed algorithm has the best performance both in terms of accuracy and running time compared to other incremental algorithms.

Keywords: *Accuracy and Running Time; Data Stream; Incremental Learning; Reinforcement Learning; Stochastic Gradient Descent.*

* corresponding author: Javad Salimi Sartakhti, Email: salimi@kashanu.ac.ir

۱. مقدمه

می‌شود. در این نوع یادگیری مرحله‌ی آموزش و یادگیری در طول زمان و به طور مداوم صورت می‌گیرد.

الگوریتم گرادیان کاهش تصادفی^۳ قدمت طولانی در حوزه یادگیری ماشین دارد و توسط بهینه‌ساز گرادیان کاهش بهینه شده است [۳]. الگوریتم مذکور برای حل انواع مسائل مختلف همانند طبقه‌بندی داده‌ها، پردازش متن و... استفاده می‌شود. اما الگوریتم مذکور هنگام مواجهه با داده‌های جریانی کارایی مناسبی ندارد.

به صورت کلی، بهترین حالت از نظر صحت طبقه‌بندی داده‌های جریانی حالتی است که با ورود هر نمونه‌ی جدید، مدل بازآموزش شود. اما چنین روشی بسیار زمانبر و غیر ممکن است.

از این‌رو، برای طبقه‌بندی نمودن داده‌های فوق‌الذکر با صحت و زمان یادگیری مناسب با دو چالش روبه‌رو هستیم که عبارتند از: (۱) انتخاب نمونه‌های بهینه جهت کاهش زمان اجرا. (۲) پیروی داده‌های جریان‌های مختلف از توزیع‌های متفاوت. بنابراین، سوالی که مطرح می‌شود، آیا با ورود هر نمونه‌ی جدید باید مدل بازآموزش شود یا خیر؟

در این مقاله قصد بر این است به چالش‌ها و سوال ذکر شده پرداخته شود و مدلی مبتنی بر یادگیری تقویتی به همراه دسته‌بند گرادیان کاهش تصادفی تحت عنوان Inc-RL-SGD برای دستیابی به صحت و زمان اجرای مناسب در راستای طبقه‌بندی داده‌های جریانی به منظور یادگیری افزایشی طراحی شود تا هر نمونه‌ای که به عنوان ورودی برای مدل در نظر گرفته شد را

امروزه حجم عظیمی از داده‌ها در حوزه‌ها و زمینه‌های مختلف تولید می‌شوند و اغلب داده‌های تولیدشده به صورت جریانی هستند. داده‌های جریانی^۱ داده‌هایی هستند که در طول زمان تولید می‌شوند و در هر لحظه دسترسی به همه داده‌ها وجود ندارد [۱]. از این‌رو، حجم داده‌های تولیدشده و نوع آنها باعث به وجود آمدن چالش‌هایی شده‌اند. یکی از مسائل چالش برانگیز، مسئله‌ی طبقه‌بندی کردن داده‌های جریانی است.

در راستای طبقه‌بندی کردن داده‌های جریانی با صحت مناسب الگوریتم‌های سنتی یادگیری ماشین با مشکل مواجه می‌شوند. زیرا در الگوریتم‌های سنتی فرض بر این است که تمامی داده‌ها به صورت یک‌جا و با توزیع یکسان در اختیار مدل قرار دارند و مدل می‌تواند از تمامی داده‌های جمع‌آوری شده در راستای دستیابی به بیشترین صحت طبقه‌بندی استفاده نماید. اما داده‌های جریانی در طول زمان، در حجم و سرعتی بالا تولید می‌شوند. به عنوان مثال، می‌توان به داده‌هایی که در کاربردهای اینترنت اشیا، لاگ‌های امنیتی تولید می‌شوند اشاره نمود [۱]. از سوی دیگر، داده‌های جریانی عموماً همراه با تغییرتوزیع هستند؛ به این معنا که داده‌ها تا یک زمان خاص از یک توزیع مشخص تبعیت می‌کنند اما به تدریج توزیع داده‌ها تغییر می‌کند. این ویژگی سبب می‌شود که الگوریتم‌های سنتی یادگیری ماشین به خودی خود کارایی لازم را هنگام مواجهه با آنها نداشته باشند و دچار بیش‌برازش شوند. بدین ترتیب، برای طبقه‌بندی نمودن داده‌های مذکور الگوریتم‌های یادگیری افزایشی^۲ مطرح شده است [۲]. این نوع الگوریتم غالباً برای کلان داده‌ها اعمال

³ Stochastic Gradient Descent

¹ Data Stream

² Incremental Learning

بررسی کند که آیا نمونه به مدل اضافه شود و مدل مجددا اجرا شود یا خیر.

در مدل پیشنهادی از چندین مجموعه داده‌ی متعلق به بانک داده‌ی UCI و مجموعه داده‌های جریانی تشخیص فعالیت‌های انسانی برای آزمایش عملکرد مدل استفاده شده است. شایان ذکر است، عملکرد مدل پیشنهادی با سایر الگوریتم‌های یادگیری افزایشی مقایسه شده است و نشان داده شده است که مدل پیشنهادی نسبت به سایر الگوریتم‌های افزایشی دارای عملکرد بهتری است.

ادامه‌ی مقاله به صورت زیر سازماندهی شده است. در بخش دوم به تعریف مفاهیم اولیه، در بخش سوم بطور مختصر کارهای گذشته مرور می‌شود، در بخش چهارم به توضیح الگوریتم پیشنهادی و در بخش پنجم به ارزیابی پرداخته می‌شود. در نهایت در بخش پایانی نتیجه‌گیری ارائه می‌شود.

۲. مفاهیم پایه

به منظور طبقه‌بندی نمودن داده‌های جریانی با صحت و زمان اجرای مناسب از الگوریتم‌های سنتی یادگیری ماشین نمی‌توان استفاده نمود. بنابراین، مدلی مبتنی بر یادگیری تقویتی به همراه دسته‌بند گرادیان کاهشی تصادفی به منظور یادگیری افزایشی طراحی شده است. در ادامه تمامی موارد فوق به تفصیل توضیح داده شده است.

۱.۲. گرادیان کاهشی تصادفی

گرادیان کاهشی تصادفی یک الگوریتم بهینه‌سازی ساده و در عین حال کارآمد برای بهینه‌سازی تابع زیان^۴ است که این روش یک تقریب تصادفی از روش گرادیان کاهشی است [۳]. تابع

زیان، معیاری برای سنجش مناسب بودن مدل از نظر قابلیت و توانایی در پیش‌بینی مقدارهای جدید است [۴]. انتخاب تابع زیان مناسب به عوامل متعددی نظیر وجود نقاط یا داده‌های پرت، نوع الگوریتم یادگیری ماشین و عوامل دیگر بستگی دارد.

در الگوریتم مذکور به ازای تمامی نمونه‌هایی که در مجموعه داده آموزشی وجود دارند میانگین گرادیان طبق رابطه (۱) بدست می‌آید و سپس برای هر تکرار t گرادیان تخمین زده می‌شود:

$$g_{GD} = \frac{1}{n} \sum_{i=1}^n \nabla_{\theta} \mathcal{L}(x^i, y^i, \theta_t) \quad (1)$$

که n برابر با تعداد کل نمونه‌های مجموعه آموزشی و \mathcal{L} تابع زیاتی است که باید کمینه شود.

همانگونه که در رابطه (۱) مشاهده می‌گردد برای تخمین گرادیان باید میانگین همه نمونه‌ها محاسبه شود. بنابراین، اگر داده‌ها از نوع کلان داده باشند، محاسبه گرادیان به روش فوق-الذکر بسیار زمانبر است. برای ممانعت از بروز چنین مشکلی گرادیان کاهشی تصادفی مطرح شد. در این نوع گرادیان طبق رابطه (۲) در هر تکرار برای دسته‌ای از نمونه‌ها به جای کل نمونه‌ها، گرادیان تخمین زده می‌شود:

$$g_{GD} = \frac{1}{n'} \sum_{i=1}^{n'} \nabla_{\theta} \mathcal{L}(x^i, y^i, \theta_t) \quad (2)$$

که n' بیانگر نمونه‌هایی هستند که از مجموعه آموزشی انتخاب می‌شوند و اندازه‌اش نسبت به مجموعه آموزشی کوچکتر است.

۲.۲. یادگیری تقویتی

یکی از تکنیک‌های اصلی یادگیری ماشین، یادگیری تقویتی است. این نوع یادگیری برای محیط‌هایی که عامل هیچ نوع شناختی نسبت به آنها ندارد، مناسب است [۵]. در این نوع

⁴ Loss Function

هدف از یادگیری افزایشی این است که مدل با داده‌های جدید سازگار شود بدون اینکه دانش موجود خود را فراموش کند. تاکنون الگوریتم‌های یادگیری افزایشی متعددی ارائه شده است. به صورت کلی، الگوریتم‌های یادگیری افزایشی را می‌توان به دو دسته‌ی بازآموز و غیر بازآموز تقسیم نمود. در الگوریتم‌های غیر بازآموز هنگامی که نمونه‌های جدیدی به مدل اضافه می‌شوند، نیازی به بازآموزی با تمام نمونه‌های آموزشی نیست. بنابراین، مصرف حافظه و هزینه‌ی زمان آموزش کاهش می‌یابد. اما در الگوریتم‌های بازآموز، تمامی نمونه‌ها نگهداری می‌شوند و هنگامی که نمونه‌ی جدیدی به مدل اضافه می‌شود نیازمند بازآموزی مدل با تمام نمونه‌های آموزشی است. بنابراین، مصرف حافظه و زمان آموزش افزایش می‌یابد.

۳. مرور کارهای گذشته


در دهه‌های گذشته محققان از الگوریتم‌های سنتی یادگیری ماشین مانند شبکه‌های بیزین، درخت تصمیم، جنگل‌های تصادفی و ... به منظور طبقه‌بندی نمودن داده‌ها استفاده می‌کردند [۷-۱۲]. اما الگوریتم‌های مذکور هنگام مواجهه با کلان داده‌ها و داده‌های جریانی ممکن است با شکست روبه‌رو شوند. برای غلبه بر این موضوع، برخی از محققین الگوریتم‌های یادگیری افزایشی [۲] را مطرح کردند. در ادامه به توضیح موارد فوق پرداخته می‌شود.

لوزینگ و همکاران [۱۳] در پژوهشی اغلب الگوریتم‌های معروف یادگیری افزایشی را بر روی مجموعه داده‌های مختلفی آزمایش کردند که در ادامه به توضیح آنها پرداخته می‌شود.

برخی از محققین [۳, ۱۴, ۱۵] الگوریتم‌هایی مبتنی بر یادگیری افزایشی با استفاده از الگوریتم گرادین کاهشی تصادفی با به حداقل رساندن تابع ضرر برای یادگیری یک مدل خطی ارائه کرده‌اند. به عنوان مثال، الگوریتم گرادین کاهشی تصادفی

یادگیری به عامل^۵ اجازه داده می‌شود تا از طریق تعامل با محیط و نشان دادن عکس‌العمل به آن، پاداش تجمعی را به حداکثر برساند. عناصر یادگیری تقویتی عبارتند از: مجموعه حالت‌ها^۶ $S = \{s_i\}$ ، مجموعه کنش‌ها^۷ $A = \{a_i\}$ ، تابع انتقال حالت^۸ $T(s, a, s')$ که حالت بعدی پس از اجرای کنش a را مشخص می‌کند، تابع پاداش^۹ $R(s, a)$ که بیانگر میزان پاداش انتخاب کنش a در حالت s است.

در شکل (۱) می‌توان نحوه‌ی عملکرد یادگیری تقویتی را مشاهده کرد. ابتدا عامل کنش A_t را بر روی محیط انجام می‌دهد. سپس محیط که در حالت S_t بود، عامل کنش A_t را انتخاب می‌کند و به حالت بعدی S_{t+1} می‌رود و پاداش R_{t+1} را به عامل گزارش می‌دهد [۶].



شکل (۱): معماری یادگیری تقویتی

۳.۲ یادگیری افزایشی

الگوریتم‌های یادگیری افزایشی به منظور طبقه‌بندی نمودن کلان داده‌ها و داده‌های جریانی مطرح شده‌اند [۲]. این نوع الگوریتم‌ها به طور کامل دانش مدل موجود را یاد می‌گیرند. رویه‌ی یادگیری افزایشی بدین صورت است که داده‌های ورودی به طور مداوم برای گسترش دانش موجود به مدل اضافه می‌شوند. بنابراین، مرحله‌ی آموزش به طور مداوم انجام می‌شود.

⁵ Agent

⁶ States

⁷ Actions

⁸ Transition Function

⁹ Reward

رشد متوالی درختان جدید، وزندهی زمانی دانش را امکان پذیر می‌کند. از این‌رو، رویکردشان می‌تواند در برنامه‌هایی با نویز زمانی یا تغییرات ظاهری بالا در طول ردیابی بصری مفید باشد.

لوزینگ و همکاران [۲۲] یک الگوریتم کوانتیزه سازی بردار یادگیری افزایشی^{۱۸} که اقتباسی از کوانتیزه سازی بردار یادگیری تعمیم‌یافته‌ی استاتیک^{۱۹} [۲۳] است، ارائه کرده‌اند. در رویکردشان رویکردشان تابع ضرر را به گونه دیگری تعریف می‌کنند که در صورت لزوم نمونه‌های اولیه جدیدی را به مدل اضافه می‌کند. نرخ درج بر اساس تعداد نمونه‌های طبقه‌بندی اشتباه صورت می‌گیرد.

پلیکار و همکاران [۲] الگوریتم Learn++ را مطرح نموده‌اند. در الگوریتم آنها نمونه‌های دریافتی در تکه‌هایی^{۲۰} با اندازه‌ی از پیش تعریف‌شده پردازش می‌شود. برای هر قسمت، گروهی^{۲۱} از طبقه‌بندی‌کننده‌های پایه آموزش داده می‌شوند و از طریق رای اکثریت وزنی به «گروهی از گروه‌ها» ترکیب می‌شوند. مشابه الگوریتم AdaBoost [۲۰]، هر طبقه‌بندی‌کننده با زیر مجموعه‌ای از نمونه‌های قسمتی که بر اساس توزیع داده‌ها است، آموزش داده می‌شود.

سید و همکاران [۲۴] رویکرد ماشین بردار پشتیبان افزایشی به منظور طبقه‌بندی داده‌ها ارائه کرده‌اند. رویکرد آنان بدین صورت است که مجموعه داده‌ها به چندین دسته تقسیم می‌شوند و دسته‌ها به ترتیب به عنوان ورودی دسته‌بندها در نظر گرفته می‌شوند. از این‌رو، طبقه‌بند برای هر دسته، بردارهای پشتیبان را کسب می‌کند و تمامی داده‌های قبلی به جز بردارهای پشتیبان

یک روش بهینه‌سازی کارآمد برای یادگیری یک مدل متمایز با به حداقل رساندن تابع ضرر مانند تابع لاجستیک^{۱۰} یا تابع هینج^{۱۱} است. الگوریتم آنها برای داده‌های پراکنده و با ابعاد بالا که اغلب در حوزه‌ی طبقه‌بندی متن یا پردازش زبان طبیعی مورد استفاده قرار می‌گیرند، عملکرد خوبی داشته است.

ژانگ [۱۶] الگوریتم بیزین ساده با یک توزیع گاوسین موازی محور^{۱۲} ارائه کرده است. مدل خلوت^{۱۳} امکان یادگیری بسیار کارآمد را از نظر زمان پردازش و نیازهای حافظه فراهم می‌کند. این الگوریتم به طور موثر چندین مثال آموزشی را یاد می‌گیرد [۱۷] و در مواردی مانند فیلتر کردن هرزنامه و طبقه‌بندی اسناد نتایج قابل قبولی داشته است [۱۸, ۱۹].

فروند و همکاران [۲۰] یک الگوریتم یادگیری متوالی برخط را برای شبکه‌های فیدفوروارد^{۱۴} تک لایه ارائه کردند. الگوریتمشان به عنوان ماشین یادگیری افراطی متوالی آنالین^{۱۵} شناخته می‌شود و می‌تواند داده‌ها را تک به تک یا قسمت به قسمت (یک بلاک از داده‌ها) با اندازه‌ی قسمت ثابت یا متغیر یاد بگیرد که به طور قابل توجهی زمان پردازش کلی را کاهش می‌دهد.

صفری و همکاران [۲۱] یک نسخه‌ی افزایشی از الگوریتم جنگل تصادفی تحت عنوان جنگل تصادفی برخط^{۱۶} را ارائه کرده‌اند. رویکرد آنها ترکیب کیسه‌بندی^{۱۷} برخط و جنگل‌های تصادفی است. رویکردشان با حذف کردن کل درختان (بر اساس خطاهای تخمینی خارج از کیسه آنها) در فواصل زمانی ثابت و

¹⁰ Logistic Loss

¹¹ Hinge Loss

¹² Naive Bayesian Gauss

¹³ Sparse

¹⁴ Feed Forward

¹⁵ Online Sequential Extreme Learning Machine

¹⁶ Online Random Forest

¹⁷ Bagging

¹⁸ Incremental Learning Vector Quantization

¹⁹ Generalized Learning Vector Quantization

²⁰ Chunks

²¹ Ensemble

حذف می شوند. ولی هرگاه نمونه جدیدی به مجموعه داده قبلی اضافه می شود، مدل از ابتدا اجرا می شود. با این حال، رویکرد مذکور دارای معایبی است که عبارتند از: ۱- نیاز به حافظه‌ی بزرگ. ۲- زمان اجرای طولانی. ۳- فرض یکسان بودن توزیع داده‌ها.

همانطور که قبلاً بیان کردیم، یکی از معایب یادگیری افزایشی مشکل فراموشی فاجعه‌بار است. از این رو، برخی از محققین الگوریتم‌هایی را برای مقابله با مسئله مذکور ارائه کردند، اما اکثر الگوریتم‌های ارائه شده دارای بار محاسباتی زیادی هستند و به حافظه بزرگی نیاز دارند. بنابراین، ژاو و همکاران [۲۵] یک الگوریتم یادگیری افزایشی مبتنی بر بافر حافظه محدود مطرح کردند. در الگوریتم مذکور به منظور حفظ دانش قدیمی تعدادی نمونه در حافظه نگهداری می شود. شایان ذکر است، اگر تعداد نمونه‌های ذخیره شده در حافظه کم باشد، سبب کاهش دقت مدل می شود. از سوی دیگر، برای افزایش دقت مدل نیاز به ذخیره نمونه‌های زیادی است که این امر منجر به افزایش هزینه می شود. بنابراین، در الگوریتم مذکور از یک روش نمونه‌کاهی^{۲۲} به منظور افزایش تعداد نمونه‌ها در بافر حافظه و کاهش هزینه استفاده می شود و هنگام اضافه شدن نمونه جدید، مدل با استفاده از این نوع نمونه و نمونه‌های ذخیره شده قبلی بازآموز می شود. اگرچه الگوریتم مذکور از دقت خوبی برخوردار است، اما زمانبر است.

وکیلی و همکاران [۲۶] برخی از دسته‌بندها را همانند دسته‌بند بیزین ساده، دسته بند k نزدیکترین همسایه، دسته‌بند جنگل تصادفی و...، همچنین برخی از الگوریتم‌ها همانند الگوریتم‌های [۲] و [۲۰] را به نسخه افزایشی تبدیل کرده‌اند. آنها مجموعه داده‌ی تشخیص فعالیت‌های انسانی را به منظور

بررسی صحت و صحت الگوریتم‌هایشان استفاده نموده‌اند.

داده‌های ترافیک شبکه گونه‌ای از داده‌های جریانی هستند که به طور مداوم و در طول زمان می‌رسند. لی و همکاران [۲۷] الگوریتمی مبتنی بر یادگیری افزایشی با استفاده از الگوریتم گرادیان کاهش تصادفی برای شناسایی ترافیک‌های بدافزار رمز-گذاری شده در شبکه‌ها را طراحی نموده‌اند.

دوو و همکاران [۲۸] برای طبقه‌بندی مجموعه کلان داده‌های تصاویر الگوریتمی مبتنی بر یادگیری افزایشی به همراه الگوریتم گرادیان کاهش تصادفی محلی طراحی کرده‌اند. گرادیان کاهش تصادفی محلی بلوک داده را با استفاده از الگوریتم میانگین $k^{۳۳}$ به k قسمت تقسیم می‌کند و سپس به صورت موازی مدل گرادیان کاهش تصادفی را در هر قسمت به صورت محلی می‌آموزد.

آگروال و همکاران [۲۹] برای تشخیص اثر انگشت جعلی و واقعی یک الگوریتم یادگیری افزایشی با استفاده از دسته‌بند ماشین بردار پشتیبان و الگوریتم‌های خوشه‌بندی ارائه کرده‌اند. در الگوریتم آنها از شباهت ذاتی موجود در داده‌ها استفاده می‌شود. بنابراین، ابتدا داده‌ها خوشه‌بندی می‌شوند و سپس خوشه‌ها با استفاده از ماشین بردار پشتیبان طبقه‌بندی می‌شوند. مزیت این الگوریتم بدین صورت است که هنگام اضافه شدن نمونه جدید به مدل، نیازی به بازآموزی مجدد مدل نیست. بنابراین، برای تشخیص اثر انگشت جعلی نیازی به دسترسی به اثر انگشت‌های آموزش دیده قبلی در حین یادگیری اثر انگشت‌های جدید نیست، که این امر منجر به نیاز به حافظه کم می‌شود. با این حال، اگر از مجموعه داده خیلی بزرگ استفاده شود، سبب افزایش بار محاسباتی می‌شود.

²³ k-means

²² Down Sampling

داده‌های مختلف نشان می‌دهد که الگوریتم مذکور از عملکرد خوبی برخوردار است.

لموس و همکاران [۳۲] یک الگوریتم یادگیری افزایشی مبتنی بر شبکه عصبی حافظه کوتاه مدت طولانی برای طبقه‌بندی داده‌های جریانی پیشنهاد کردند. ایده اصلی الگوریتم به این صورت است که از ویژگی‌های ذاتی شبکه عصبی مذکور برای کنترل کردن مسئله فراموشی فاجعه‌بار، تغییر توزیع داده‌ها و مدیریت حافظه استفاده شود. نتایج تجربی نشان می‌دهد که الگوریتم مذکور به تغییر توزیع داده‌ها واکنش نشان می‌دهد و همچنین در برابر داده‌های نویزی مقاوم است.

بوشانکومار و همکاران [۳۳] یک الگوریتم یادگیری افزایشی تطبیقی جدید برای طبقه‌بندی کیفیت آب هوشمند مبتنی بر اینترنت اشیا را مطرح کردند. در الگوریتم آنها برای رسیدگی به مشکل نامتوازن بودن داده‌ها از الگوریتم ژنتیک و SMOTE، استخراج ویژگی‌ها و طبقه‌بندی کیفیت آب از شبکه عصبی استفاده شده است. از این‌رو، ابتدا داده‌های کیفیت آب با استفاده از حسگرهای اینترنت اشیا جمع‌آوری می‌شود. سپس، ویژگی‌ها استخراج می‌شوند و ویژگی‌های زائد و نامربوط حذف می‌شوند. سپس، برای متوازن‌سازی داده‌ها دو الگوریتم ژنتیک و SMOTE با یکدیگر ترکیب می‌شوند. در گام بعد، از یک شبکه عصبی عمیق برای طبقه‌بندی استفاده می‌شود. ذکر این نکته الزامی است که هنگام اضافه شدن نمونه جدید مدل از ابتدا اجرا نمی‌شود بلکه از دانش قبلی کسب‌شده برای طبقه‌بندی کیفیت آب استفاده می‌شود. اگرچه الگوریتم مذکور از عملکرد خوبی برخوردار است، اما به دلیل استفاده از شبکه عصبی عمیق و تعداد زیاد لایه‌های پنهان زمانبر است.

برخی از محققان برای طبقه‌بندی داده‌ها از شبکه‌های عصبی به همراه الگوریتم‌های یادگیری افزایشی استفاده کرده‌اند که در ادامه به توضیح آنها پرداخته می‌شود.

هوو و همکاران [۳۰] الگوریتم یادگیری افزایشی مبتنی بر شبکه عصبی خود رمزگذار متغیر^{۲۴} را برای طبقه‌بندی داده‌ها مطرح کردند. به منظور استخراج ویژگی‌ها از شبکه عصبی خود رمزگذار متغیر استفاده می‌شود. سپس از یک شبکه از پیش‌آموزش‌دیده برای طبقه‌بندی داده‌ها استفاده می‌شود. همچنین خروجی‌های خود رمزگذار متغیر به عنوان داده کمکی برای داده‌های جدید استفاده می‌شود. بنابراین، هنگام اضافه شدن داده جدید مدل از ابتدا بازآموزی نمی‌شود. در نتیجه هزینه حافظه و محاسبات کاهش می‌یابد. با این حال، اگر از مجموعه داده خیلی بزرگ استفاده شود زمان آموزش مدل افزایش می‌یابد و سبب افزایش بار محاسباتی می‌شود.

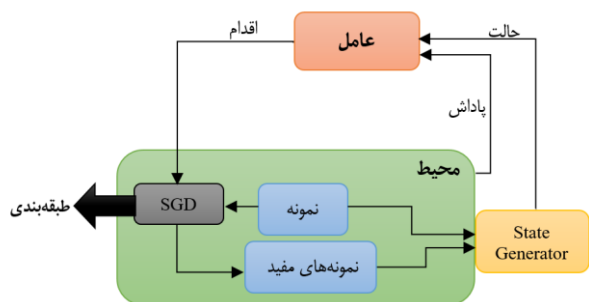
شان و همکاران [۳۱] به منظور طبقه‌بندی داده‌های متنی الگوریتمی مبتنی بر شبکه عصبی حافظه کوتاه مدت طولانی^{۲۵} را مطرح کردند. الگوریتم آنها شامل ۴ مولفه دانش‌آموز، یادگیری تقویتی، معلم و متمایزکننده است. در مولفه دانش‌آموز ابتدا پیش-بینی‌های اولیه توسط شبکه عصبی مذکور صورت می‌گیرد. سپس مولفه یادگیری تقویتی نتایج چندین مولفه دانش‌آموز را فیلتر می‌کند. پس از آن، مولفه معلم نتایج فیلترشده را مجدداً طبقه‌بندی می‌کند و طبقه‌بندی متون نهایی را بدست می‌آورد و در نهایت برای جلوگیری از تعداد افزایش نامحدود مولفه‌های دانش‌آموز با افزایش تعداد نمونه‌ها، از مولفه متمایزکننده برای فیلتر کردن مولفه‌های دانش‌آموز بر اساس شباهت آنها استفاده می‌شود. آزمایش‌ها بر روی مجموعه

کانگ و همکاران [۳۴] یک الگوریتم یادگیری افزایشی مبتنی بر شبکه عصبی عمیق برای طبقه‌بندی داده‌ها و اضافه شدن کلاس جدید به مجموعه کلاس‌های قدیمی داده‌ها پیشنهاد

²⁴ Variational Autoencoder

²⁵ Long-Short Term Memory (LSTM)

دارد. معماری الگوریتم پیشنهادی Inc-RL-SGD در شکل (۲) نشان داده شده است.



شکل (۲): معماری الگوریتم پیشنهادی Inc-RL-SGD

همانگونه که قبلاً بیان کردیم، گرادیان کاهشی تصادفی یک الگوریتم بهینه‌سازی است. برخی از محققان یک الگوریتم یادگیری افزایشی مبتنی بر گرادیان کاهشی تصادفی و دسته‌بندی مطرح کردند [۳، ۱۴]. آنها در الگوریتمشان ثابت کردند که اگر گرادیان کاهشی تصادفی با تابع زیان هینج برای یادگیری یک مدل خطی استفاده شود، می‌توان به دسته‌بندی معادل دسته‌بندی ماشین بردار پشتیبان دست یافت [۱۳].

همانطور که قبلاً ذکر شده است؛ هدف از یادگیری تقویتی به حداکثر رساندن پاداش تجمعی است [۵] و هدف در این پژوهش دستیابی به صحت و زمان اجرای مناسب است. نحوه یادگیری تقویتی برای دستیابی به پاداش مورد نظر بدین صورت است که ابتدا مقداره‌ی اولیه مدل صورت می‌گیرد و سپس وارد مرحله‌ی آموزش می‌شود. در این مرحله تعداد محدودی از نمونه داده‌ها با کمک دسته‌بند گرادیان کاهشی تصادفی مدل آموزش داده می‌شود. بدین ترتیب، نمونه‌ها به عنوان ورودی دسته‌بند مذکور در نظر گرفته می‌شوند و گرادیان کاهشی تصادفی آنها را طبقه‌بندی می‌کند.

از سوی دیگر، یادگیری تقویتی شامل مجموعه حالت‌ها است [۵]. بردار حالت در یادگیری تقویتی نمایشی از محیط فعلی است که عامل در آن قرار دارد و این حالت توسط عامل قابل

کردند. در الگوریتم آنها به طور مداوم دانش جدید با حافظه محدود یاد گرفته می‌شوند در حالیکه دانش قدیمی حفظ می‌شود. در الگوریتم مذکور احتمال اهمیت هر ویژگی تخمین زده می‌شود. سپس ویژگی‌هایی که بیشترین احتمال اهمیت را داشته باشند نگهداری شده و برای طبقه‌بندی استفاده می‌شوند. از سوی دیگر، هنگام اضافه شدن نمونه جدید ابتدا ویژگی‌های آن استخراج می‌شود. سپس، ویژگی‌های استخراج شده و ویژگی‌هایی که در مراحل قبلی نگهداری شده بودند با یکدیگر به منظور بررسی این که آیا نمونه جدید متعلق به کلاس جدید است یا خیر، مقایسه می‌شوند. بنابراین، هنگام اضافه شدن نمونه جدید الگوریتم از ابتدا اجرا نمی‌شود. اگرچه الگوریتم از عملکرد خوبی برخوردار است، اما به دلیل استفاده از شبکه عصبی عمیق زمانبر است.

۴. الگوریتم پیشنهادی

همانطور که قبلاً بیان کردیم، الگوریتم‌های ارائه‌شده از یادگیری افزایشی به همراه دسته‌بندی‌های مختلف برای طبقه‌بندی نمودن داده‌ها استفاده شده است، اما اکثر الگوریتم‌ها هنگام مواجهه با داده‌های جریانی با شکست مواجه شده‌اند یا عملکرد ضعیفی از خودشان نشان می‌دهند. از سوی دیگر، یکی از معیارهای اصلی در یادگیری افزایشی زمان اجرا است ولی در راهکارهایی که به آنها اشاره شده است به این معیار توجهی نشده است. بنابراین، در این پژوهش قصد بر این است که برای طبقه‌بندی داده‌های مورد بررسی با صحت و زمان اجرای مناسب از یادگیری تقویتی به همراه دسته‌بند گرادیان کاهشی تصادفی به منظور یادگیری افزایشی استفاده شود. شایان ذکر است، الگوریتم پیشنهادی محدود به استفاده از دسته‌بند گرادیان کاهشی تصادفی نیست و امکان استفاده از دسته‌بندی‌های دیگر به شرط آنکه تعداد پارامترهای آن دسته‌بند کم باشد، بتوان دسته‌بند را در قالب یک بردار نمایش داد و برای آن تعدادی کنش تعریف کرد، وجود

سربار ناشی از بازآموزی به صرفه نیست که با این نمونه بازآموزی انجام شود.

از سوی دیگر، اگر هدف دستیابی به بیشترین صحت ممکن باشد، بهترین راهکار این است که تمامی نمونه‌های جدید را بپذیریم و مدل را مجدداً بازآموزی کنیم؛ اما این روش بسیار زمانبر است. بنابراین، کنش جدیدی را می‌توان تعریف کرد تا به هدف اصلی پژوهش دست یافت. از این رو، به جای بازآموزی مدل با تمامی نمونه داده‌ها، صرفاً مدل با استفاده از نمونه‌های مفیدی که جمع‌آوری شده است، بازآموزی می‌شود. مزیت این روش این است که تعداد این نوع نمونه‌ها نسبت به تمام نمونه‌ها کمتر است. بنابراین، زمان بازآموزی کاهش می‌یابد.

حال عامل با توجه به موقعیت دریافتی از بین سه کنش موجود بهترین کنش ممکن را انتخاب می‌کند. پس از دریافت حالت و کنش، پاداش محاسبه می‌شود.

اگر صرفاً هدف دستیابی به بیشترین صحت طبقه‌بندی باشد تنها معیار صحت کافی است و می‌توان با پذیرش نمونه جدید مدل را مجدداً بازآموزی نمود تا به بهترین صحت ممکن دست یافت. ولی عملاً این روش بسیار زمانبر است. بنابراین، می‌بایست توازنی بین صحت و زمان در نظر گرفته شود تا هر دفعه با اضافه شدن نمونه جدید، مدل از ابتدا بازآموزی نشود. به همین دلیل، تابع پاداش به صورت رابطه (۳) تعریف می‌شود:

$$Reward^t = \frac{Acc^t}{Training Time^t} \quad (3)$$

که Acc^t بیانگر صحت یادگیرنده در واحد درصد در دوره t و $Training Time^t$ بیانگر زمان یادگیری در دوره t و در واحد ثانیه است.

مشاهده است و شامل تمام اطلاعات مربوط به محیط است که عامل برای تصمیم‌گیری باید بداند. در این پژوهش بردار حالت شامل دو مولفه نمونه دریافتی x_t و مدل M_{t-1} است. حال می‌بایست راهکاری ارائه شود که مدل در قالب یک بردار بیان شود. در مدل‌های مختلف این کار متغیر است. به عنوان مثال در دسته‌بند ماشین بردار پشتیبان، مدل یک ابرصفحه است. در دسته‌بند گرادیان کاهشی تصادفی یک رابطه خط همانند ابرصفحه SVM وجود دارد که این رابطه خط توسط الگوریتم گرادیان کاهشی تصادفی محاسبه می‌شود. بنابراین، می‌توان پارامترهای رابطه خط بدست‌آمده را به عنوان بازنمایی مدل در نظر گرفت و به بردار حالت اضافه نمود.

از سوی دیگر، نمونه دریافتی x_t در قالب یک بردار دریافت می‌شود. بنابراین، دو مولفه مذکور را می‌توان در کنار یکدیگر قرار داد و در قالب یک بردار حالت در نظر گرفت. هنگامی که حالت جدید دریافت می‌شود از بین کنش‌های موجود، عامل باید بهترین کنش را انتخاب کند.

در حالت کلی، برای مسئله مورد نظر سه کنش تعریف شده است که عبارتند از:

- TA: پذیرفتن نمونه جدید و بازآموزی مجدد مدل.
- TUS: پذیرفتن نمونه جدید و بازآموزی مدل به وسیله نمونه‌های مفید؛ در هر گام نمونه‌هایی که حاوی خطای کمتری هستند و به رابطه خط نزدیکتر هستند، ذخیره می‌شوند. ذکر این نکته الزامی است، با توجه به نوع داده‌ها تعداد نمونه‌های مفید متغیر است.
- NT: نپذیرفتن نمونه جدید با فرض اینکه نمونه حاوی اطلاعات جدیدتری نیست یا حاوی اطلاعات کم ارزشی است و با در نظر گرفتن

- $US_{t+1} = US_t \cup \text{New useful samples} \in M_t$;
- If $a_t = \text{TUS}$
 - $M_{t+1} \leftarrow \text{Train SGD by } US_t$;
 - $US_{t+1} = US_t \cup \text{New useful samples} \in M_t$;
- If $a_t = \text{NT}$
 - $M_{t+1} \leftarrow M_t$;
- Compute accuracy and running time of M_t on the test data;
- $r_t = \frac{\text{Accuracy}(M_t)}{\text{Training Time}(M_t)}$;
- Return r_t, M_t ;

همانطور که در الگوریتم (۱) مشاهده می‌شود، ورودی مدل، مجموعه داده D است. در گام‌های بعدی تعداد دوره‌های یادگیری و مقداردهی اولیه تعیین می‌شود. سپس مقداردهی اولیه دسته‌بند به صورت تصادفی انجام می‌شود. در گام بعد دسته‌بند توسط مجموعه آموزشی، آموزش داده می‌شود. سپس مقداردهی اولیه محیط صورت می‌گیرد. در گام بعد نمونه جدید دریافت می‌شود. پس از دریافت نمونه، بردار حالت که شامل نمونه و مدل است، تشکیل می‌شود و به عامل فرستاده می‌شود. سپس عامل با استفاده از سیاست ϵ -حریصانه و از بین مجموعه کنش‌های تعریف‌شده، کنشی را انتخاب می‌کند. شایان ذکر است، در هر دور از مرحله یادگیری نمونه‌های مفید تولید شده ذخیره می‌شوند. در گام بعد بردار حالت و کنش انتخاب‌شده به محیط ارسال می‌شوند.

همانطور که در الگوریتم (۲) مشاهده می‌شود، آرگومان‌های تابع STEP نمونه، مدل و کنش انتخاب‌شده از مجموعه کنش‌های A است. اگر عامل کنش TA را انتخاب کرد، آنگاه دسته‌بند با تمام نمونه‌ها بازآموزی می‌شود و همچنین نمونه مفید جدید بدست‌آمده در این مرحله به مجموعه نمونه‌های مفید قبلی اضافه می‌شود. در غیر اینصورت اگر عامل کنش TUS را انتخاب کرد، آنگاه دسته‌بند با تمام نمونه‌های مفید بدست‌آمده بازآموزی می‌شود و همچنین نمونه مفید جدید بدست‌آمده در

همانطور که مشاهده می‌شود اگر در تابع پاداش دو معیار صحت و زمان یادگیری در نظر گرفته شود، طبقه‌بندی داده‌ها با صحت و سرعت بالا انجام می‌شود.

شبه کد الگوریتم پیشنهادی Inc-RL-SGD در الگوریتم‌های (۱) و (۲) در دو مرحله آموزش و شبیه‌سازی محیط ارائه شده است که در ادامه به توضیح آنها پرداخته می‌شود.

الگوریتم (۱): مرحله آموزش الگوریتم Inc-RL-SGD

- INPUT: Training data $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_t, y_t)\}$
- Episode number K
- Action set $A = \{\text{TA}, \text{TUS}, \text{NT}\}$
- Initialize experience replay memory RM
- Randomly initialize neural network parameters θ (i.e., weights)
- Train model M_t (i.e., SGD classifier) with $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_t, y_t)\}$ where $t' < t$
- Initialize simulation environment
- For episode $k = 1$ to K
 - Receive sample x_t
 - Shuffle the training data D
 - Initialize state $s_t = x_t \square M_{t-1}$
 - For $i = t + 1$ to T
 - Choose an action based ϵ -greedy policy:
 - If $\epsilon < \text{random number}$
 $a_t = \text{choose a random action from } A$
 - else
 $a_t = \max_a Q(s_t, a, \theta)$
 - $r_t, M_t = \text{STEP}(a_t, (x_t, y_t), M_{t-1})$
 - Set $s_{t+1} = x_{t+1} \square M_t$
 - Store (s_t, a_t, r_t, s_{t+1}) to RM
 - Randomly sample (s_i, a_i, r_i, s_{i+1}) from RM
 - Set $O_i = (r_i + \gamma \max_{a'} Q(s_{i+1}, a', \theta))$
 - Calculate loss function $L(\theta)$

الگوریتم (۲): مرحله شبیه‌سازی محیط الگوریتم Inc-RL-SGD

- FUNCTION: $\text{STEP}(a_t \in A, (x_t, y_t) \in D, M_{t-1})$
- If $a_t = \text{TA}$
 - $M_{t+1} \leftarrow \text{Train SGD by all samples} \in D_t$;

است تا مقایسه در شرایط عادلانه صورت گیرد. بنابراین، در الگوریتم‌های مورد مقایسه نسبت نمونه‌های آموزشی به تست ۸۰ به ۲۰ در نظر گرفته شده است و در این پژوهش نسبت مذکور لحاظ شده است. از سوی دیگر، برخی از داده‌های مورد استفاده داده‌های کثیفی^{۲۶} هستند. بنابراین، ابتدا داده‌ها با استفاده از روش‌های مرسوم پاکسازی که سایر الگوریتم‌ها از آنها استفاده کرده‌اند، پاکسازی می‌شوند. سپس از آنها در الگوریتم پیشنهادی استفاده می‌شود.

در ابتدا به علت عدم شناخت محیط و نبودن نمونه‌های مفید عامل به صورت تصادفی یکی کنش‌های (۱) پذیرفتن نمونه‌ی جدید و بازآموزی مدل توسط گرادین کاهشی تصادفی یا (۲) پذیرفتن نمونه‌ی جدید را انتخاب می‌کند. سپس با طی کردن ۱۰۰ دور از آموزش و بازآموزی مدل توسط دسته‌بند گرادین کاهشی تصادفی در جهت کسب نمونه‌های مفید، عامل با محیط آشنا می‌شود و دانش موردنظر را کسب می‌کند. بنابراین، عامل کنشی متناسب با شرایط کنونی انتخاب می‌کند. در بخش نتایج نشان داده می‌شود که مدل پیشنهادی نسبت به سایر رویکردهای افزایشی مورد مقایسه از عملکرد بهتری برخوردار است.

۶. نتایج

در این بخش ابتدا به معرفی داده‌های مورد استفاده پرداخته می‌شود. سپس، نتایج حاصل از الگوریتم پیشنهادی بر روی داده‌های مورد بررسی بیان می‌شود و در ادامه معیارهای ارزیابی دسته‌بند معرفی و نهایتاً نتایج حاصل از اعمال الگوریتم پیشنهادی بر روی مجموعه داده‌های مورد بررسی به تفصیل بیان می‌شود.

این مرحله به مجموعه نمونه‌های مفید قبلی اضافه می‌شود. در غیر اینصورت اگر عامل کنش NT را انتخاب کرد، آنگاه نمونه پذیرش نمی‌شود و مدل تغییری نمی‌کند. پس از اینکه کنش مورد نظر انتخاب شد نوبت به محاسبه پاداش از سوی محیط است. از سوی دیگر، یادگیری تقویتی با توجه به بردار حالت و میزان پاداش تصمیم می‌گیرد که نمونه دریافتی را بپذیرد یا حذف کند. در نهایت دو مقدار پاداش و مدل از سمت محیط به عامل برگردانده می‌شود. در نهایت به منظور سنجش مدل از نظر قابلیت و توانایی در پیش‌بینی مقدارهای جدید از تابع زیان استفاده می‌شود.

۵. ارزیابی

برای پیاده‌سازی مدل پیشنهادی و پیش‌پردازش داده‌های ورودی از زبان برنامه نویسی پایتون و کتابخانه Pytorch استفاده شده است. آزمایش‌ها بر روی پردازنده 1.80 GHz Intel Core i5 و رم 8.0 GB انجام شده است.

شایان ذکر است، الگوریتم پیشنهادی با چندین الگوریتم افزایشی مقایسه شده است. بنابراین، در هر بار مقایسه با الگوریتم مورد بررسی پارامترهایی از قبیل نرخ یادگیری، وزن‌های شبکه، تابع زیان، تعداد دورهای اجرا و... همانند الگوریتم مورد بررسی در نظر گرفته شده است تا شرایطی عادلانه برای مقایسه وجود داشته باشد.

در این پژوهش الگوریتم پیشنهادی Inc-RL-SGD با الگوریتم‌های ژانگ [۳]، ژانگ [۱۶]، فروند [۲۰]، صفری [۲۱]، لوزینگ [۲۲]، پلیکار [۲] و سید [۲۴] و وکیلی [۲۶] با استفاده از تعدادی مجموعه داده‌های بانک مخزن UCI و مجموعه داده-ی تشخیص فعالیت‌های انسانی مقایسه شده است.

از این‌رو، مدل پیشنهادی با شرایطی مشابه الگوریتم‌های مورد مقایسه [۲، ۳، ۱۳، ۱۶، ۲۰-۲۲، ۲۴، ۲۶، ۳۵] پیاده‌سازی شده

²⁶ Dirty Data

۱.۶. مجموعه داده‌ها

3	Standing Still	13	Arm Swings
4	Sitting on a chair	14	Forearm Rotation
5	Side Leg Lifts	15	Dumbbell Biceps Curl
6	Boxer Shuffle	16	Jumping Jack
7	Knee Lifts	17	Chest Expansion
8	Cycling using Exercise Bicycle	18	Cross Toe Touch
9	Forward Lunge	19	Straight Punch
10	Torso Rotation	20	Big Arm Circles

۲.۶. نتایج اعمال الگوریتم پیشنهادی بر روی داده‌ها

برای مقایسه الگوریتم‌های افزایشی چندین معیار وجود دارد که در این پژوهش به علت نامتوازن بودن داده‌ها از معیارهای صحت، $F1$ -score و زمان اجرا استفاده شده است که در ادامه به توضیح آنها پرداخته می‌شود.

در ابتدا با استفاده از مجموعه داده‌های بانک مخزن UCI الگوریتم پیشنهادی Inc-RL-SGD از نظر صحت با چندین الگوریتم افزایشی که عبارتند از: ژانگ [۳]، ژانگ [۱۶]، فروند [۲۰]، صفری [۲۱]، لوزینگ [۲۲]، پلیکار [۲] و سید [۲۴] مقایسه می‌شود و نشان داده می‌شود که الگوریتم پیشنهادی دارای صحت بهتری نسبت به سایر الگوریتم‌ها است. شایان ذکر است، الگوریتم پیشنهادی در شرایطی مشابه با [۲، ۳، ۱۳، ۱۶، ۲۰-۲۲، ۲۴، ۳۵] پیاده‌سازی شده است و نتایج مربوط به الگوریتم‌های افزایشی از [۱۳، ۳۵] اخذ شده است تا شرایطی عادلانه برای مقایسه وجود داشته باشد. جداول (۳) و (۵) نتایج حاصل از الگوریتم پیشنهادی و الگوریتم‌های مورد مقایسه را نشان می‌دهد. همانگونه که مشاهده می‌شود الگوریتم پیشنهادی در همه مجموعه داده‌ها از صحت بهتری نسبت به سایر الگوریتم‌های افزایشی برخوردار است.

برای بررسی قدرت و صحت الگوریتم پیشنهادی از چندین مجموعه داده‌ی متعلق به بانک مخزن UCI و مجموعه داده‌های مربوط به تشخیص فعالیت‌های انسانی استفاده شده است. طبق مرجع [۲۶] داده‌های تشخیص فعالیت‌های انسانی توسط حسگرهای گوشی‌های هوشمند و از طریق جریان‌های بلادرنگ اینترنت اشیا تولید شده است. در این مجموعه داده حداکثر ۲۰ فعالیت وجود دارد. در این پژوهش منظور از فعالیت همان برجسب^{۲۷} داده‌ها است. در جدول (۱) مشخصات کلی داده‌های بانک مخزن UCI و در جدول (۲) کلاس‌هایی که در داده‌های مربوط به تشخیص فعالیت‌های انسانی وجود دارد، نشان داده شده است.

جدول (۱): توصیف ویژگی‌های مجموعه داده‌های بانک مخزن UCI

Datasets	#Features	#Classes	#Samples
Australians	14	2	270
Heart-C	13	2	303
Ionosphere	34	2	354
Votes	16	2	445
Gisette	5000	2	7000
Letter	16	26	20000
Mnist	784	10	70000
Susy	18	2	500000

جدول (۲): توصیف کلاس‌های مجموعه داده تشخیص فعالیت‌های انسانی

NO	Activity	NO	Activity
1	Walking	11	Squats
2	Running	12	Mountain Climber Twist

²⁷ Label

شایان ذکر است، در الگوریتم [۲، ۳، ۱۳، ۱۶، ۲۰-۲۲، ۲۴، ۳۵] هنگام دریافت نمونه جدید، تمامی مقادیر قبلی دسته‌بند براساس آن به‌روزرسانی و بازآموزی می‌شود، اما در الگوریتم Inc-RL-SGD با استفاده از یادگیری تقویتی میزان مفید بودن نمونه بررسی می‌شود. سپس یادگیری تقویتی با توجه به داده‌های دریافتی تصمیم می‌گیرد که مدل را بپذیرد یا آن را نادیده بگیرد. بنابراین، الگوریتم Inc-RL-SGD در همه مجموعه داده‌ها از لحاظ صحت و زمان اجرا عملکرد بهتری نسبت به الگوریتم [۲۴، ۳۵] دارد.

یکی دیگر از معیارهای مهم زمان اجرا است. لازم به ذکر است که تمامی نسخه‌های افزایشی الگوریتم‌ها از نسخه غیر افزایشی آنها زمان اجرای به مراتب بیشتری دارند. این امر هم به آن دلیل است که عموماً در یک الگوریتم افزایشی یک مدل ممکن است هزاران بار اجرا شود که قاعداً منجر به افزایش زمان خواهد شد. با این حال فقط در الگوریتم افزایشی کاهشی ماشین بردار پشتیبان [۲۴، ۳۵] معیار زمان اجرا در نظر گرفته شده است و در مابقی الگوریتم‌های افزایشی مذکور به زمان اجرا توجهی نشده است. در جداول (۴) و (۶) زمان اجرای مجموعه داده‌های مذکور نشان داده شده است و همانطور که مشاهده می‌شود الگوریتم پیشنهادی از زمان اجرای خوبی برخوردار است.

لازم به ذکر است که به دلیل ناموازن بودن مجموعه داده‌ها، از معیار F1-score استفاده شده است و نتایج حاصل در جدول (۷) نشان داده شده است.

از سوی دیگر، در الگوریتم Inc-SVM [۲۴، ۳۵] علاوه بر معیار صحت از معیار F1-score استفاده کرده‌اند. از این‌رو، در جدول (۸) میزان F1-score الگوریتم پیشنهادی یا الگوریتم Inc-SVM مقایسه شده است. همانطور که مشاهده می‌شود،

الگوریتم پیشنهادی به دلیل استفاده از یادگیری تقویتی از عملکرد بهتری برخوردار است.

در کاربردی دیگر به منظور بررسی صحت و دقت الگوریتم پیشنهادی از مجموعه داده‌های مربوط به تشخیص فعالیت‌های انسانی استفاده شده است. شایان ذکر است الگوریتم پیشنهادی در شرایطی مشابه با الگوریتم‌های افزایشی [۲۶] پیاده‌سازی شده است. در شکل (۳) و جدول (۹) صحت، F1-score و زمان اجرای الگوریتم پیشنهادی با الگوریتم‌های افزایشی [۲۶] مقایسه شده است و نشان داده شده است که الگوریتم پیشنهادی نه تنها دارای صحت و F1-score بهتری نسبت به سایر الگوریتم‌های افزایشی [۲۶] است بلکه از نظر زمان اجرا هم زمان اجرای کمتری دارد.

صحت مجموعه داده‌های مورد بررسی در شکل (۴) نشان داده شده است. همانطور که مشاهده می‌شود در تمامی نمودارها پس از طی کردن تقریباً ۱۰۰ دور از آموزش صحت روند صعودی پیدا می‌کند و این ثمره استفاده از یادگیری تقویتی در الگوریتم پیشنهادی می‌باشد.

نتیجه گیری

در این مقاله برای طبقه‌بندی داده‌های جریانی با صحت و زمان اجرای مناسب یک الگوریتم افزایشی با استفاده از یادگیری تقویتی به همراه دسته‌بند گرادیان کاهشی تصادفی به منظور یادگیری افزایشی ارائه شد. در الگوریتم پیشنهادی از دسته‌بند گرادیان کاهشی تصادفی به منظور طبقه‌بندی داده‌ها و از یادگیری تقویتی برای انتخاب کنش مناسب استفاده می‌شود. الگوریتم ارائه شده بر روی انواع مجموعه داده‌ها اجرا شد که نتایج آزمایشگاهی از کارایی بالای این الگوریتم نسبت به نمونه‌های مشابه آن در نسخه‌های متفاوت الگوریتم‌های افزایشی حکایت دارد. در الگوریتم ارائه شده بنا به دلیل ارائه کنشی جدید (باز آموزی نمونه‌های جدید به وسیله نمونه‌های مفید) زمان اجرا کاهش

یافته است و همچنین به دلیل در نظر گرفتن معیار زمان اجرا، برتری بیشتری نسبت به سایر الگوریتم‌های افزایشی ذکر شده دارد.

جدول (۳): مقایسه صحت الگوریتم پیشنهادی Inc-RL-SGD با سایر الگوریتم‌های افزایشی (برحسب درصد)

الگوریتم‌ها							
Datasets	ORF	ILVQ	LPP _{CART}	IELM	SGD _{Lin}	NB _{Gaus}	Inc-RL-SGD
Letter	۹۳/۲	۹۳/۹	۸۷/۰	۷۰/۰	۵۶/۴	۶۳/۴	۹۴/۶
Susy	۷۹/۵	۷۹/۰	-	-	۷۸/۷	۷۳/۵	۸۰/۱
Mnist	۹۴/۳	۹۴/۸	۹۲/۴	۸۹/۱	۸۶/۰	۵۵/۶	۹۵/۱
Gisette	۹۴/۶	۹۳/۰	۹۴/۲	۹۱/۴	۹۳/۱	۷۵/۴	۹۶/۰

جدول (۴): زمان اجرای الگوریتم پیشنهادی Inc-RL-SGD (برحسب ثانیه)

الگوریتم پیشنهادی	
Datasets	Inc-RL-SGD
Letter	۱۵۶/۳۶
Susy	۶۸۶/۳۴
Mnist	۷۹۶/۲۰
Gisette	۹۶/۵۳

جدول (۵): مقایسه صحت الگوریتم پیشنهادی Inc-RL-SGD با الگوریتم افزایشی Inc-SVM (برحسب درصد)

Datasets	[۳۰]Inc-SVM	Inc-RL-SGD
Australians	۸۵/۵۱	۸۸/۸۵
Ionosphere	۸۶/۸۸	۸۸/۲۳
Heart-C	۸۲/۴۸	۸۵/۵۱
Votes	۹۵/۴	۹۷/۶۵

جدول (۶): مقایسه زمان اجرای الگوریتم پیشنهادی Inc-RL-SGD با الگوریتم افزایشی Inc-SVM (برحسب ثانیه)

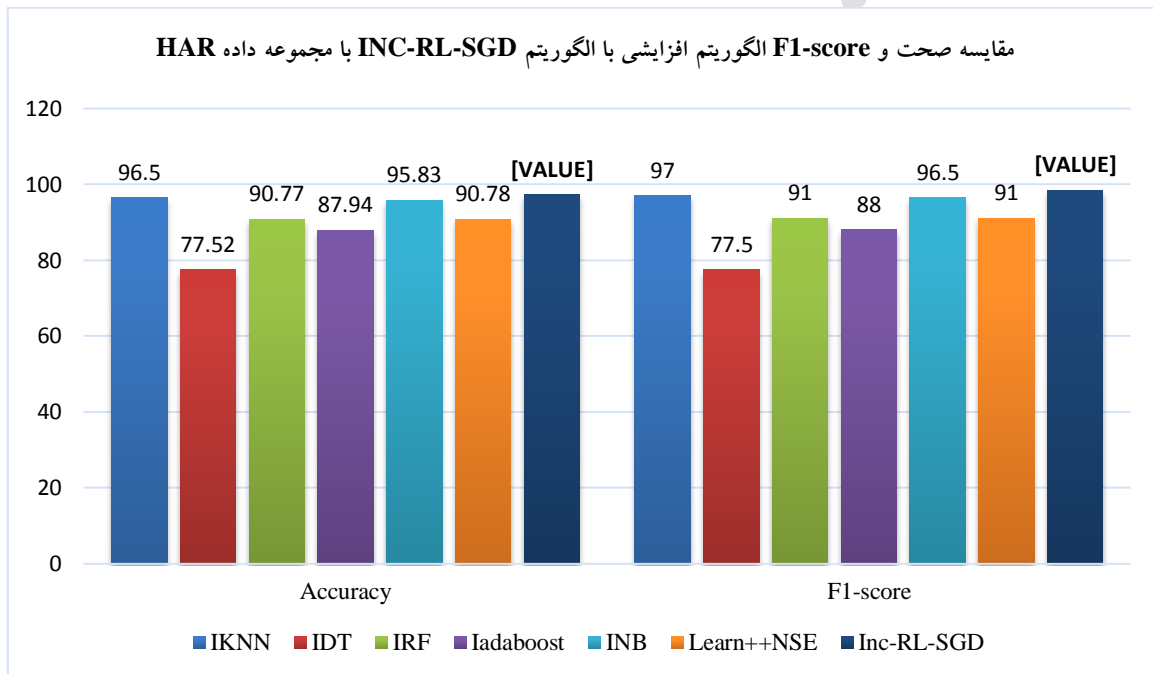
Datasets	[۳۰]Inc-SVM	Inc-RL-SGD
Australians	۱۰۵/۱۰	۱۲/۲۵
Ionosphere	۸۰/۸۴	۱۱/۳۲
Heart-C	۶۷/۴۷	۱۰/۸۴
Votes	۸۱/۶۵	۹/۷۶

جدول (۷): بررسی F1-score داده‌های مورد بررسی (برحسب درصد)

Algorithm	Heart-C	Australians	Ionosphere	Votes	Letter	Susy	Mnist	Gisette	HAR
INC-RL-SGD	۹۱/۱۵	۹۱/۳۵	۹۲/۳۹	۹۸/۰۱	۹۶/۸۵	۸۵/۷۳	۹۶/۹۹	۹۶/۵۹	۹۸/۵

جدول (۸): مقایسه F1-score الگوریتم پیشنهادی Inc-RL-SGD با الگوریتم افزایشی Inc-SVM (برحسب درصد)


Datasets	[۳۰]Inc-SVM	Inc-RL-SGD
Australians	۹۰/۸۰	۹۱/۳۵
Ionosphere	۹۰/۷۵	۹۲/۳۹
Heart-C	۸۹/۹۰	۹۱/۱۵
Votes	۹۶/۸۵	۹۸/۰۱



شکل (۳): مقایسه و بررسی صحت و F1-score الگوریتم پیشنهادی با الگوریتم افزایشی [۲۶]

جدول (۹): مقایسه زمان اجرای الگوریتم پیشنهادی Inc-RL-SGD با الگوریتم‌های افزایشی [۲۶]


Algorithms	Accuracy (برحسب درصد)	Run Time (برحسب ثانیه)
IKNN	۹۶/۵۰	۴۲
IDT	۷۷/۵۲	۳۸
IRF	۹۰/۷۷	۱۶۷
Iadaboost	۸۷/۹۴	۴۷
INB	۹۵/۸۳	۴۰
Learn++NSE	۹۰/۷۸	۷۴




Inc-RL-SGD

۹۷/۳۰

۳۳




Letter صحت داده (پ)




Susy صحت داده (ب)


Votes صحت داده (الف)




Heart-C صحت داده (ج)




Gisette صحت داده (ث)



Australians صحت داده (ت)



Ionosphere صحت داده (خ)



Mnist صحت داده (ح)

شکل (۴): نمودار صحت داده‌ها

- [۹] L.-P. Liu, Y. Yu, Y. Jiang *et al.*, "Tefe: A time-efficient approach to feature extraction." pp. 423-432.
- [۱۰] خسروی، عبدالمالکی، هادی، فیاضی، و همکاران. "پیش‌بینی وضعیت تحصیلی متقاضیان پذیرش‌شده دانشگاه، مبتنی بر داده‌های آموزشی و پذیرشی با استفاده از تکنیک‌های داده کاوی"، محاسبات نرم، 9، vol. 9، no. 2، pp. 94-113، ۲۰۲۱.
- [۱۱] زارع، مهرجردی، فاطمه، یزدیان، دهکردی، مهدی، و همکاران. "ارزیابی روش‌های یادگیری کلاسیک و یادگیری عمیق در تجزیه و تحلیل احساسات داده‌های تلگرام فارسی"، محاسبات نرم، ۲۰۲۲.
- [۱۲] ویسی، هادی، قایدشرف، و همکاران. "بهبود کارایی الگوریتم‌های یادگیری ماشین در تشخیص بیماری‌های قلبی با بهینه‌سازی داده‌ها و ویژگی‌ها"، محاسبات نرم، 8، vol. 8، no. 1، pp. 70-85، ۲۰۲۱.
- [۱۳] V. Losing, B. Hammer, and H. Wersing, "Incremental on-line learning: A review and comparison of state of the art algorithms," *Neurocomputing*, vol. 275, pp. 1261-1274, 2018.
- [۱۴] L. Bottou, "Large-scale machine learning with stochastic gradient descent," *Proceedings of COMPSTAT'2010*, pp. 177-186: Springer, 2010.
- [۱۵] P. Richtárik, and M. Takáč, "Parallel coordinate descent methods for big data optimization," *Mathematical Programming*, vol. 156, no. 1, pp. 433-484, 2016.
- [۱۶] H. Zhang, "The optimality of naive Bayes," *Aa*, vol. 1, no. 2, pp. 3, 2004.
- [۱] D. Bhattacharya, and M. Mitra, *Analytics on big fast data using real time stream data processing architecture*: EMC Corporation, 2013.
- [۲] R. Polikar, L. Upda, S. S. Upda *et al.*, "Learn++: An incremental learning algorithm for supervised neural networks," *IEEE transactions on systems, man, and cybernetics, part C (applications and reviews)*, vol. 31, no. 4, pp. 497-508, 2001.
- [۳] T. Zhang, "Solving large scale linear prediction problems using stochastic gradient descent algorithms." p. 116.
- [۴] Q. Wang, Y. Ma, K. Zhao *et al.*, "A comprehensive survey of loss functions in machine learning," *Annals of Data Science*, pp. 1-26, 2020.
- [۵] V. Mnih, K. Kavukcuoglu, D. Silver *et al.*, "Playing atari with deep reinforcement learning," *arXiv preprint arXiv:1312.5602*, ۲۰۱۳.
- [۶] M. G. Lagoudakis, and R. Parr, "Reinforcement learning as classification: Leveraging modern classifiers." pp. 424-431.
- [۷] S. Maliah, and G. Shani, "MDP-based cost sensitive classification using decision trees".
- [۸] S. Chen, A. Choi, and A. Darwiche, "Value of information based on Decision Robustness".

- Fingerprint Detection,” *arXiv preprint arXiv:2012.14639*, 2020.
- [٢٠] J. Huo, and T. L. van Zyl, “Incremental class learning using variational autoencoders with similarity learning,” *Neural Computing and Applications*, pp. 1-16, 2023.
- [٢١] G .Shan, S. Xu, L. Yang *et al.*, “Learn#: a novel incremental learning method for text classification,” *Expert Systems with Applications*, vol. 147, pp. 113198, 2020.
- [٢٢] Á. C. Lemos Neto, R. A. Coelho, and C. L. d. Castro, “An incremental learning approach using long short-term memory neural networks,” *Journal of Control, Automation and Electrical Systems*, vol. 33, no. 5, pp. 1457-1465, 2022.
- [٢٣] B. Nemade, and D. Shah, “An efficient IoT based prediction system for classification of water using novel adaptive incremental learning framework,” *Journal of King Saud University-Computer and Information Sciences*, vol. 34, no. 8, pp. 5121-5131, 2022.
- [٢٤] M. Kang, J. Park, and B. Han, "Class-incremental learning by knowledge distillation with adaptive feature consolidation." pp. 16071-16080.
- [٢٥] R. Khemchandani, Jayadeva, and S. Chandra, "Incremental twin support vector machines," *Modeling, Computation and Optimization*, pp. 263-272: World Scientific, 2009.
- [٢٦] C. Salperwyck, and V. Lemaire, "Learning with few examples: An empirical study on leading classifiers." pp. 1010-1019.
- [٢٧] V. Metsis, I. Androustopoulos, and G. Paliouras, "Spam filtering with naive bayes-which naive bayes?." pp. 28-69.
- [٢٨] S. Ting, W. Ip, and A .H. Tsang, “Is Naive Bayes a good classifier for document classification,” *International Journal of Software Engineering and Its Applications*, vol. 5, no. 3, pp. 37-46, 2011.
- [٢٩] Y. Freund, R. Schapire, and N. Abe, “A short introduction to boosting,” *Journal-Japanese Society For Artificial Intelligence*, vol. 14, no. 771-780, pp. 1612, 1999.
- [٣٠] A. Saffari, C. Leistner, J. Santner *et al.*, "On-line random forests." pp. 1393-1400.
- [٣١] V. Losing, B. Hammer, and H. Wersing, "Interactive online learning for obstacle classification on a mobile robot." pp. 1-8.
- [٣٢] A. Sato, and K. Yamada, “Generalized learning vector quantization,” *Advances in neural information processing systems*, vol. 8, 1995.
- [٣٣] N. A. Syed, H. Liu, and K. K. Sung, “Incremental learning with support vector machines,” 1999.
- [٣٤] H. Zhao, H. Wang, Y. Fu *et al.*, “Memory-Efficient Class-Incremental Learning for Image Classification,” *IEEE Transactions on Neural Networks and Learning Systems*, vol. 33, no. 10, pp. 5966-5977, 2021.
- [٣٥] M. Vakili ,and M. Rezaei, “Incremental Learning Techniques for Online Human Activity Recognition,” *arXiv preprint arXiv:2109.09435*, 2021.
- [٣٦] I. Lee, H. Roh, and W. Lee, "Encrypted malware traffic detection using incremental learning." pp. 1348-1349.
- [٣٧] T.-N. Do, “ImageNet Challenging Classification with the Raspberry Pi: An Incremental Local Stochastic Gradient Descent Algorithm,” *arXiv preprint arXiv:2203.11853*, 2022.
- [٣٨] S. Agarwal, A. Rattani, and C. R. Chowdary, “AILearn: An Adaptive Incremental Learning Model for Spoof