تشخیص تغییر مفهوم در جریان داده با کمک رده‌بند نیمه‌نظارتی

حسین حسن‌نژاد نامقی[1]، هدی مشایخی[1]* و مرتضی زاهدی

[1]دانشکده مهندسی کامپیوتر، دانشگاه صنعتی شاهرود، شاهرود، ایران

چکیده

جریان داده به دنباله‌ای از داده‌ها گفته می‌شود که از منابع اطلاعاتی مختلف با سرعت زیاد و حجم بالا تولید می‌شوند. از مهم‌ترین چالش‌های موجود در تحلیل جریان داده وجود تغییر مفهوم در آن‌ها است. تغییر مفهوم به معنای تغییر ویژگی‌های آماری داده‌هاست. در بسیاری از پژوهش‌های موجود برای مقابله با چالش نامحدودبودن طول جریان داده و یا چالش تغییر مفهوم، از رویکردهایی با فرض موجودبودن برچسب درست برای همه داده‌ها استفاده می‌کنند؛ درحالی‌که با توجه به هزینه‌بربودن فرآیند برچسب‌دهی جریان داده، به‌طورعمومی فرض می‌شود تنها بخشی از داده‌ها دارای برچسب هستند. در این مقاله یک روش یادگیری گروهی نیمه‌نظارتی ارائه شده که از تغییر آنتروپی برای تشخیص تغییر مفاهیم در رده‌بندی جریان داده استفاده می‌کند. مدل یادگیری گروهی پیشنهادی با تعداد محدودی داده برچسب‌دار اولیه آموزش می‌بیند؛ سپس در صورت مشاهده تغییر مفهوم، از داده‌های بدون برچسب برای به‌روزرسانی مدل رده‌بند گروهی استفاده می‌کند. روش پیشنهادی قادر است تغییرات موجود در مجموعه‌داده را تشخیص داده و با به‌روزرسانی مدل یادگیری، در بهبود دقت الگوریتم مؤثر باشد. نتایج آزمایش‌ها نشان می‌دهد که روش پیشنهادی از جنبه‌های مختلف نسبت به سایر روش‌ها کارایی بالاتری دارد.

واژگان کلیدی: جریان داده، یادگیری گروهی، تغییر مفهوم، آنتروپی، رده‌بند نیمه‌نظارتی

Detecting Concept Drift in Data Stream Using Semi-Supervised Classification

Hossein Hasan Nezhad Namaghi[1], Hoda Mashayekhi*[1] & Morteza Zahedi[1]

[1]Faculty of Computer Engineering, Shahrood University of Technology, Shahrood, Iran

Abstract

Data stream is a sequence of data generated from various information sources at a high speed and high volume. Classifying data streams faces the three challenges of unlimited length, online processing, and concept drift. In related research, to meet the challenge of unlimited stream length, commonly the stream is divided into fixed size windows or gradual forgetting is used. Concept drift refers to changes in the statistical properties of data, and is divided into four categories: sudden, gradual, incremental, and recurring. Concept drift is generally dealt with by periodically updating the classifier, or employing an explicit change detector to determine the update time. These approaches are based on the assumption that the true labels are available for all data samples. Nevertheless, due to the cost of labeling instances, access to a partial labeling is more realistic. In a number of studies that have used semi-supervisory learning, the labels are received from the user to update the models in form of active learning. The purpose of this study is to classify samples in an unlimited data stream in presence of concept drift, using only a limited set of initial labeled data. To this end, a semi-supervised ensemble learning algorithm for data stream is proposed, which uses entropy variation to detect concept drift and is applicable for sudden and gradual drifts. The proposed model is trained with a limited initial labeled set. In occurrence of concept drift, the unlabeled data is used to update the ensemble model. It does not

* نویسندهٔ عهده‌دار مکاتبات

* Corresponding author

● تاریخ ارسال مقاله: ۱۳۹۸/۰۳/۱۸ ● تاریخ پذیرش: ۱۳۹۹/۱۲/۱۱ ● تاریخ انتشار: ۱۴۰۰/۱۲/۲۹ ● نوع مطالعه: پژوهشی

require receiving the labels from the user. In contrast to many of the current studies, the proposed algorithm uses an ensemble of K-NN classifiers. It constructs a group of clustering-based classification models, each of which is trained on a batch of data. On receiving each new sample, first it is determined whether the data sample is an outlier or not. If the data is included in a cluster, the sample class is determined by majority voting. When a window of the stream is received, the possibility of concept drift is examined based on entropy variation, and the classifier is updated by a semi-supervised approach if necessary. The model itself determines the required data labels. The proposed method is capable of detecting concept drift in data, and improving its accuracy via updating the learning model with appropriate samples received from the stream. Therefore, the proposed method only requires a small initial labeled data. Experiments are performed using five real and synthetic datasets, and the model performance is compared to three other approaches. The results show that the proposed method is superior in terms of precision, recall and F1 score compared to other studies.

Keywords: data stream, ensemble learning, concept drift, entropy, semi-supervised classification

۱- مقدمه

پیشرفت‌های اخیر سخت‌افزاری در زمینه‌های ذخیره‌سازی و پردازش اطلاعات، امکان جمع‌آوری خودکار داده‌ها را فراهم کرده است. به این‌گونه داده‌ها که به‌سرعت در حال تولید و افزایش بوده و نیاز به تجزیه و تحلیل آنی در هنگام ورود دارند، جریان داده[1] گفته می‌شود. برای نمونه می‌توان به تراکنش‌های مالی، داده‌های موجود در شبکه‌های اجتماعی و داده‌های به‌دست‌آمده از حس‌گرهای بی‌سیم اشاره کرد [1].

در کاوش جریان‌های داده از روش‌های گوناگونی هم‌چون رده‌بندی[2]، خوشه‌بندی[3]، درخت تصمیم[4] و شبکه‌های عصبی[5] استفاده می‌شود؛ ولی در این مقاله تمرکز بیشتر بر روی رده‌بندی است. کاوش جریان‌های داده با سه چالش طول نامحدود، پردازش برخط و تغییر مفهوم مواجه است [2]. استفاده از الگوریتم‌های متداول یادگیری به‌دلیل نامحدودبودن جریان داده، عدم توانایی ذخیره‌سازی کل داده‌ها و همچنین زمان یادگیری نامحدود آن‌ها، میسر نیست. فرآیند یادگیری در این داده‌ها باید با یک گذر روی داده‌ها انجام شود، اما الگوریتم‌های متداول داده‌کاوی نیاز به چندین گذر روی داده‌ها و دسترسی به داده‌های قدیمی دارند، که به‌دلیل محدودیت حافظه کارایی لازم را ندارند و از سوی دیگر، جهت پردازش حجم عظیم جریان‌های داده بسیار کند و غیر عملی هستند [11، 28]. تغییر مفهوم[6] زمانی اتفاق می‌افتد که توزیع داده‌ها در طول زمان به‌طور اساسی تغییر کند [12]؛ بنابراین مدل رده‌بند باید با توجه به توزیع جدید به‌صورت پیوسته به‌روز شود.

در پژوهش‌های مرتبط، برای مقابله با چالش نامحدودبودن طول جریان داده، از تقسیم جریان داده به قطعاتی با اندازه ثابت [3]، یا فراموشی تدریجی[7] [4] استفاده شده است. برای مواجهه با چالش تغییر مفهوم از به‌روزرسانی دوره‌ای رده‌بند [1]، یا تشخیص‌دهنده تغییر صریح [5] برای تشخیص زمان به‌روزرسانی استفاده شده است. این رویکردها با فرض اینکه برچسب‌های درست برای تمام نمونه‌های داده موجود است، مطرح شده‌اند. درحالی‌که به‌طورعمومی فرآیند برچسب‌گذاری داده‌ها یا توسط یک کاربر به‌صورت دستی ارائه شده و یا اینکه نیازمند وسایل خاص و آزمایش‌های کند و گران است. با توجه به محدودیت زمان و منبع، امکان اینکه برچسب درست برای همه نمونه‌ها در دسترس باشد، وجود ندارد [6]؛ بنابراین باید به‌دنبال راهی بود تا از داده‌های بدون برچسب به‌عنوان داده‌های آموزشی استفاده کرد.

روش‌های یادگیری را می‌توان با توجه به میزان داده‌های آموزشی برچسب‌دار به سه دسته با نظارت[8]، نیمه‌نظارتی[9] و بدون نظارت[10] رده‌بندی کرد. اگر همه داده‌های آموزشی برچسب‌دار باشند، یادگیری با نظارت خواهد بود. اگر هیچ یک از داده‌ها برچسب‌گذاری نشده باشند، یادگیری بدون نظارت است و درصورتی‌که علاوه‌بر داده‌های برچسب‌دار، از داده‌های بدون برچسب در یادگیری استفاده شود، یادگیری نیمه‌نظارتی خواهد بود. در روش یادگیری نیمه‌نظارتی، تعداد داده‌های برچسب‌دار در مقایسه با داده‌های بدون برچسب بسیار اندک است [11]. روش‌های گوناگونی برای رده‌بندی جریان‌های داده ارائه شده است، ولی به‌طور کلی الگوریتم‌های رده‌بندی با درنظرگرفتن تغییر مفهوم به دو دسته الگوریتم‌های کور و

[1] Data Stream
[2] Classification
[3] Clustering
[4] Decision Tree
[5] Neural Networks
[6] Concept Drift
[7] Gradual Forgetting
[8] Supervised
[9] Semi-Supervised
[10] Unsupervised

آگاه تقسیم می‌شوند. در روش‌های کور بدون توجه به تغییر مفهوم، مدل در زمان‌هایی مشخص به‌روز می‌شود؛ ولی در روش‌های آگاه با بررسی جریان داده، در صورت رخداد تغییر مفهوم مدل به‌روزرسانی خواهد شد [13].

همان‌گونه که بیان شد، تغییر مفهوم تغییر توزیع ویژگی یا برچسب نمونه‌هاست. اگر تغییر مفهوم در توزیع داده‌ها (ویژگی‌ها) رخ دهد، تغییر مفهوم مجازی[1] و اگر در توزیع برچسب داده‌ها باشد، تغییر مفهوم واقعی[2] نامیده می‌شود [12]. تغییر مفهوم به چهار دسته ناگهانی[3]، تدریجی[4]، افزایشی[5] و تکرارشونده[6] تقسیم می‌شود. با فرض این‌که فقط دو مفهوم داریم، این چهار نوع تغییر را بررسی می‌کنیم [13]:

۱. تغییر مفهوم ناگهانی: ساده‌ترین نوع تغییر مفهوم است، به‌طوری‌که در یک زمان مشخص مفهوم جدیدی جایگزین مفهوم قبلی می‌شود. برای نمونه شخصی قصد خرید خودرو دارد و برای بررسی اطلاعات خودرو و قیمت آن در اینترنت جستجو می‌کند؛ بنابراین بسیاری از جستجوها در ارتباط با خودرو است. درحالی‌که پس از خرید خودرو، جستجوها تغییر می‌کنند.

۲. تغییر مفهوم تدریجی: در این نوع تغییر مفهوم، مفهوم به‌تدریج از یک نوع به نوعی دیگر تغییر می‌کند. در یک بازه زمانی هر دو مفهوم فعال هستند؛ ولی به‌تدریج از احتمال انتخاب نمونه‌ها برای نوع اول کم شده و به‌احتمال انتخاب نمونه‌ها برای نوع دوم اضافه می‌شود. برای نمونه زمانی که سرمربی تیم یک کشور تغییر می‌کند، در آن کشور جستجوها در ارتباط با آن شخص به‌مرور کم شده و برای شخصی که به‌تازگی سرمربی تیم شده به‌تدریج زیاد می‌شود.

۳. تغییر مفهوم افزایشی: این نوع تغییر مفهوم شباهت زیادی به تغییر مفهوم تدریجی دارد، با این تفاوت که بیش از دو نوع مفهوم وجود دارد که بین این دو نوع مفهوم اصلی قرار می‌گیرند. در یک بازه زمانی توزیع نمونه‌ها به‌تدریج از نوع اول فاصله گرفته و به نوع دوم نزدیک می‌شود. برای مثال می‌توان به افزایش تدریجی محبوبیت یک نرم‌افزار پس از اضافه‌شدن قابلیت‌های جدید به آن، اشاره کرد.

۴. مفهوم تکرارشونده: در این نوع تغییر مفهوم، مفهومی که در گذشته فعال بوده، می‌تواند بعد از مدت زمانی دوباره پدیدار شود. برای مثال در مسأله جستجوی خودرو ممکن است، کاربر دوباره قصد خرید خودرو را داشته باشد.

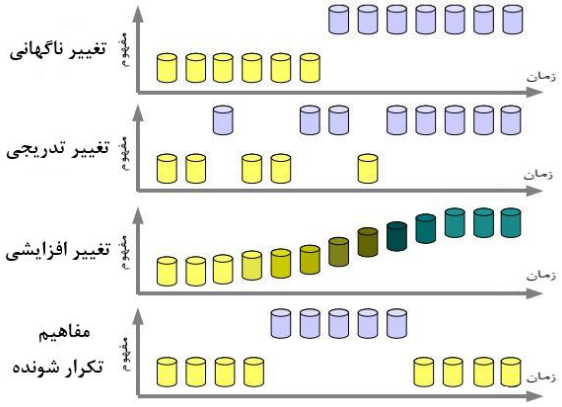

(شکل-۱): انواع تغییر مفهوم [13]
(Figure-1): The kinds of concept drift [13]

در برخی از پژوهش‌های انجام‌شده در زمینه تشخیص تغییر، روش‌هایی ارائه شده‌اند که به برچسب درست برای تمام نمونه‌ها نیاز دارند و درحقیقت از روش یادگیری نظارتی برای شناسایی تغییر استفاده می‌کنند. در تعدادی از پژوهش‌های انجام‌گرفته که از یادگیری نیمه‌نظارتی استفاده کرده‌اند، برای به‌روزرسانی مدل‌ها برچسب نمونه‌ها را از کاربر دریافت کرده و از روش یادگیری فعال استفاده می‌کنند. در این مقاله روشی برای رده‌بندی تدریجی جریان داده مبتنی بر مدل‌های گروهی ارائه شده که از آنتروپی به‌عنوان شناسایی‌کننده تغییر استفاده کرده و دو نوع تغییر مفهوم تدریجی و ناگهانی را شناسایی می‌کند. روش یادگیری به‌صورت نیمه‌نظارتی است و از داده‌های آموزشی محدودی برای ساخت مدل‌های اولیه استفاده می‌کند. روش پیشنهادی برای به‌روزرسانی مدل‌ها هیچ برچسب نمونه‌ای را از کاربر دریافت نمی‌کند.

قالب ارائه‌شده دارای گروهی از مدل‌های رده‌بند مبتنی بر خوشه‌بندی است که هر کدام روی یک قطعه[7] از داده آموزش می‌بینند؛ سپس با ورود هر نمونه آزمایش، مشخص می‌شود نمونه داده پرت[8] است یا خیر. درصورتی‌که داده درون خوشه قرار گرفت، با استفاده از رأی اکثریت ردهٔ نمونه تعیین می‌شود و با استفاده از مدل

[1] Virtual
[2] Real
[3] Sudden
[4] Gradual
[5] Incremental
[6] Recurring

[7] Chunk
[8] Outlier

ارائه‌شده، امکان وجود تغییر مفهوم بررسی می‌شود؛ درنهایت درصورت لزوم رده‌بند به‌روزرسانی می‌شود.

روش پیشنهادی با برخی از روش‌های موجود بر روی مجموعه‌داده‌های مختلف مقایسه شده است. نتایج آزمایش‌ها نمایان‌گر عملکرد بهتر روش پیشنهادی نسبت به سایر روش‌ها است. به‌طوری‌که این روش به‌خوبی توانسته تغییرات موجود در مجموعه‌داده را تشخیص داده و دقت و صحت الگوریتم را بهبود بخشد. در ادامه، در بخش ۲ مروری بر پژوهش‌های رده‌بندی جریان داده بررسی و در بخش ۳ چارچوب پیشنهادی برای رده‌بندی جریان داده با تشخیص تغییر مفهوم ارائه می‌شود. در بخش ۴ به بررسی نتایج و مقایسه آن‌ها می‌پردازیم و در پایان نتیجه‌گیری ارائه می‌شود.

۲- کارهای انجام‌شده

در یادگیری دسته‌ای[1] با میانگین‌گیری از مدل‌های تصادفی حاصل از آموزش داده‌ها، بر مشکل محدودبودن داده‌های آموزشی غلبه می‌شود [14]. اما این روش به حجم داده‌ها وابسته بوده و با افزایش حجم داده‌ها از نظر زمان اجرا برای تولید مدل‌ها و تحلیل و بررسی آن‌ها دچار مشکل می‌شود. امروزه بیش‌تر پژوهش‌های رده‌بندی جریان داده با هدف رسیدن به کارایی مطلوب و به کمینه رساندن خطا انجام می‌شوند.

روش‌های تشخیص تغییر مفهوم به‌صورت کلی به دو دسته مبتنی بر کارایی و مبتنی بر توزیع داده تقسیم می‌شوند [27]. روش‌های مبتنی بر کارایی به‌صورت پیوسته دنباله مقادیر معیارهای کارایی مثل دقت را رصد می‌کنند و کاهش عمده در این معیارها نشان‌دهنده تغییر مفهوم خواهد بود. این روش‌ها نیاز به برچسب داده‌ها داشته و با ناظر هستند. در این دسته برخی از مقالات از وزن‌دهی برای تشخیص تغییر مفهوم استفاده می‌کنند. برای نمونه *سیدو* و همکارش [8] یک روش مبتنی بر وزن‌دهی پویا برای رده‌بندی داده‌ها ارائه می‌دهد. این وزن‌دهی بر پایه دو معیار دقت رده‌بند و پیش‌بینی نهایی الگوریتم است. کابرال و همکاران [18] روشی مبتنی بر آزمایش فیشر پیشنهاد داده و سه کاربرد آن را در تشخیص تغییر مفهوم بررسی کرده‌اند. از آنجا که الگوریتم ارائه‌شده در این مقاله در دسته تشخیص تغییر مبتنی بر توزیع داده قرار می‌گیرد، در ادامه تمرکز بیشتری بر روش‌های این گروه قرار می‌دهیم.

در دسته دوم برخی از پژوهش‌ها از روش تشخیص تغییر صریح[2] برای شناسایی تغییر مفهوم در جریان داده استفاده می‌کنند. در کاوش جریان داده، این روش یا برای تشخیص تغییر در توزیع داده‌ها و یا برای تشخیص تغییر در بازخورد رده‌بند استفاده می‌شود. برای نمونه *کنچوا* و همکارش [7] تغییر توزیع داده ورودی در یک جریان داده را تشخیص می‌دهد. در پژوهشی دیگر *بیفت* و همکارش [5] با استفاده از یک روش مبتنی بر پنجره کشویی، اندازه پنجره را با توجه به میزان تغییرات موجود در داده‌های پنجره مشخص می‌کند. در این روش زمانی یک تغییر تشخیص داده می‌شود که میزان خطا در کل پنجره جاری به‌طور قابل ملاحظه‌ای از کمترین میزان خطای ثبت شده، بیشتر باشد. مشکل روش‌های بالا آن است که برای شناسایی تغییرات نیاز به برچسب درست برای تمام نمونه‌ها دارند.

هک و همکارانش [6] نیز از یک روش تشخیص صریح برای تغییر مفهوم استفاده می‌کند، با این تفاوت که تشخیص تغییر در اطمینان رده‌بند انجام می‌گیرد و با توجه به این که تشخیص بر روی میزان خطای رده‌بند نیست، نیازی به برچسب درست برای تمام داده‌ها نداشته و از یک روش نیمه‌نظارتی بهره می‌برد. با ورود هر نمونه از داده‌های جریان، همراه با پیش‌بینی برچسب نمونه، میزان اطمینان پیش‌بینی صورت گرفته محاسبه و پس از اضافه‌شدن مقدار اطمینان به یک بافر، تشخیص تغییر با توجه به تغییرات توزیع مقادیر موجود در بافر بررسی می‌شود. برای به‌روزرسانی مدل‌ها از روش یادگیری فعال استفاده کرده و تعدادی برچسب از نمونه‌ها درخواست می‌کند.

استفاده از آنتروپی اطلاعات برای تشخیص تغییر مفهوم نخستین‌بار توسط وربرگر و برنستین [24] پیشنهاد گردید. دو و همکاران [25] این روش را با استفاده از یک پنجره کشویی پویا بهبود دادند. روش آنها تلاش دارد زمان مناسب برای آموزش دوباره رده‌بند را تشخیص دهد. *مهدی* و همکارانش [9] از روشی مبتنی بر آنتروپی برای تشخیص تغییر مفهوم استفاده کرده و از یک روش نیمه‌نظارتی برای یادگیری الگوریتم بهره می‌برند. روش یادشده ابتدا دو پنجره با طول ثابت در نظر گرفته و برای هر یک از داده‌های جریان، بر مبنای احتمال وقوع نمونه مقادیری به‌دست می‌آورد و به پنجره اضافه می‌کند؛ پس از پرشدن پنجره‌ها، آنتروپی هر کدام از پنجره‌ها محاسبه و

[1] Batch

[2] Explicit Concept Drift Technique

نمونه‌های دو پنجره با هم ترکیب می‌شوند و آنتروپی مشترک[1] آن‌ها به‌دست می‌آید؛ سپس درصورتی که مقدار به‌دست‌آمده از حد آستانه‌ای[2] کمتر باشد، تغییر مفهوم تشخیص داده می‌شود. در این روش جزئیات رده‌بند و همچنین چگونگی به‌دست‌آوردن احتمال وقوع هر نمونه برای اضافه‌شدن به پنجره مشخص نشده است. در رویکردی مشابه هاگ و کاسنکی [26] روش ERICS را برای تشخیص تغییر مفهوم پیشنهاد می‌کنند که در آن از تغییر آنتروپی و معیار KL مربوط به توزیع پارامترهای مدل، استفاده می‌شود.

دمیلو و همکاران [19] به بررسی تشخیص تغییر به‌صورت بدون ناظر پرداخته و معیارهای فاصله مختلف در جریان‌داده‌ها را برای تشخیص تغییر بررسی کرده‌اند. ونگ و همکاران [20] روشی را برای تشخیص تغییر مطرح می‌کنند که در دو مقیاس مختلف کار می‌کند. ابتدا با بررسی داده‌ها در سطح ریزدانگی بالاتر، به تشخیص تغییر می‌پردازد. در صورت تشخیص تغییر، داده‌ها در ریزدانگی پایین‌تر بررسی و محل تغییر مشخص می‌شود. برای تشخیص تغییر از نمونه‌گیری و آزمایش t-student استفاده می‌شود. سانگ و همکاران [21] از روش رگرسیون مبتنی خوشه‌بندی فازی برای تشخیص الگوها به‌صورت پویا و درجه تعلق هر نمونه به الگوهای شناسایی‌شده، استفاده کرده‌اند. لی و همکاران [22] یک روش نیمه‌نظارتی افزایشی مبتنی بر یادگیری عمیق ارائه می‌کنند. برای یادگیری ویژگی از اتوانکدر استفاده کرده و برای بهبود شبکه از محدویت‌های شباهت و عدم شباهت جفت داده‌ها استفاده می‌کند. مدل آنها در مقایسه با روش‌های بررسی‌شده قبلی پیچیده‌تر بوده و پارامترهای زیادی جهت آموزش دارد.

همان‌طور که درقبل اشاره شد روش ارائه‌شده در این مقاله در دسته روش‌های مبتنی بر توزیع داده قرار دارد و نیاز به اطلاع از برچسب تمامی داده‌ها ندارد. متفاوت با بسیاری از روش‌های یادشده، در این پژوهش برای افزایش دقت از رده‌بند گروهی استفاده کرده و برای تشخیص تغییر از روشی مبتنی بر آنتروپی بهره برده‌ایم. زمانی که تغییر تشخیص داده شود، بدون نیاز به درخواست برچسب برای نمونه‌های در جریان، از روشی نیمه‌نظارتی برای به روزرسانی رده‌بند استفاده می‌شود.

۳- روش پیشنهادی

در این پژوهش از یک رده‌بند گروهی نیمه‌نظارتی شامل مدل‌های K-NN استفاده کرده‌ایم. گروهی‌بودن رده‌بند موجب می‌شود بتوان علاوه‌بر داده‌های اولیه، از داده‌های جریان نیز برای رده‌بندی بهره برد و به‌مرور از داده‌های جدیدتر برای مدل‌سازی استفاده کرد. بدین ترتیب با توجه به این که مدل پیوسته با داده‌های جدید به‌روزرسانی می‌شود، دقت رده‌بندی بالا می‌رود. این روش نیازی به برچسب برای تمام داده‌ها نداشته و فقط به مجموعه کوچکی از داده‌های برچسب‌دار اولیه نیاز دارد. همچنین برای به‌روزرسانی رده‌بند، هیچ برچسب نمونه‌ای درخواست نمی‌کند؛ بنابراین روش ارائه‌شده برای مجموعه‌داده‌هایی که تعداد کمی از نمونه‌های آن برچسب درست در اختیار دارند، مناسب است. روش پیشنهادی برای تشخیص تغییر از روشی مبتنی بر آنتروپی استفاده می‌کند. این تشخیص تغییر موجب می‌شود درصورتی‌که در توزیع داده‌ها تغییر قابل توجهی اتفاق بیافتد مدل با به‌روزرسانی، خود را با این تغییر تطبیق داده و در بهبود دقت رده‌بندی مؤثر عمل کند.

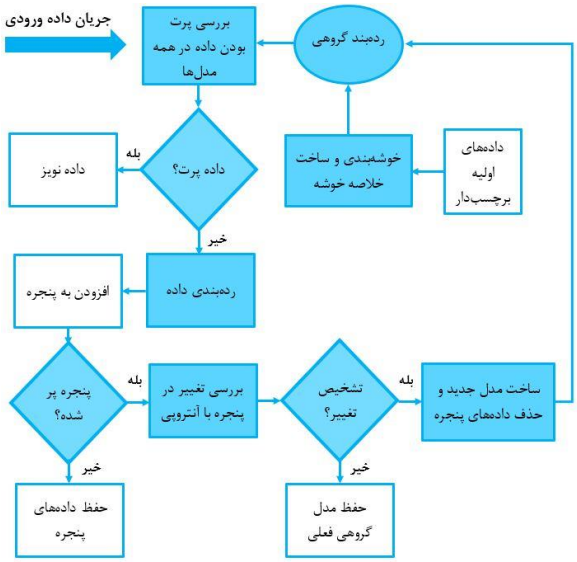

(شکل-۲): شمای کلی روش پیشنهادی

(Figure-2): High level work flow of the proposed method

در شکل (۲) شمای کلی الگوریتم پیشنهادی نشان داده شده است. در ابتدا رده‌بند گروهی شامل مدل‌هایی است که روی داده‌های آموزشی اولیه آموزش دیده‌اند؛ سپس با ورود داده‌های جریان و در نظر گرفتن دو پنجره، احتمال تعلق هر کدام از این داده‌ها به‌ازای هر کدام از مدل‌ها محاسبه و میانگین آن‌ها به دو پنجره وارد می‌شوند؛ سپس اختلاف آنتروپی دو پنجره به‌دست آمده و درصورتی‌که اختلاف آن‌ها از حد آستانه‌ای بیشتر بود، تغییر مفهوم شناسایی می‌شود. زمانی که تغییر تشخیص

[1] Joint Entropy
[2] Threshold

داده شود، مدل گروهی به‌روزرسانی و داده‌های دو پنجره حذف می‌شود.

۳-۱- آموزش و رده‌بندی

مجموعه‌داده‌ای که برای رده‌بندی به الگوریتم داده می‌شود، شامل مجموعه‌داده محدود اولیه برچسب‌دار که برای آموزش استفاده می‌شود و جریان داده ورودی که با طول نامحدود وارد می‌شود. به‌طوری‌که تعداد داده‌های آموزشی اولیه نسبت به تعداد داده‌های جریان کم بوده و فقط به برچسب داده‌های آموزشی برای اجرا بر روی الگوریتم نیاز داریم.

رده‌بند گروهی شامل مدل‌هایی است که با استفاده از الگوریتم K-NN روی داده‌های آموزشی اولیه، آموزش دیده‌اند. برای ساخت هر مدل، تعدادی از این نمونه‌ها را که به آن قطعه داده می‌گوییم، با استفاده از یک الگوریتم خوشه‌بندی مانند K-means یا DBSCAN [10] خوشه‌بندی کرده و پس از خلاصه‌سازی، داده‌ها را حذف می‌کنیم. هر خلاصه خوشه شامل مرکز، شعاع و تعداد نقاط داده مربوط به هر یک از رده‌ها است. شعاع یک خوشه، فاصله بین مرکز و دورترین نقطه داده درون خوشه در نظر گرفته می‌شود.

پس از حذف داده‌ها با ورود هر داده از جریان داده ورودی و با توجه به ویژگی‌های داده و شعاع خوشه، بررسی می‌شود که داده درون خوشه قرار می‌گیرد یا خیر. در صورتی که داده درون یکی از خوشه‌ها قرار گیرد، رأی بیشینه روی خوشه گرفته‌شده و رده با بیشترین تعداد تکرار در خوشه یادشده، به‌عنوان رده داده جریان در آن مدل تلقی می‌شود. حال با توجه به گروهی‌بودن روش رده‌بندی، دوباره بر روی مدل‌هایی که داده را درون خوشه تشخیص داده‌اند، رأی بیشینه گرفته‌شده و رده با بیشترین تکرار در مدل‌های موجود، به‌عنوان رده داده جریان در نظر گرفته می‌شود. درصورتی‌که داده برای هیچ یک از مدل‌ها درون خوشه‌ای قرار نگیرد، با استفاده از روشی مبتنی بر آنتروپی تشخیص تغییر برای نمونه بررسی شده و درصورتی‌که تغییر تشخیص داده شد، مدل گروهی به‌روزرسانی می‌شود.

در این مقاله از الگوریتم خوشه‌بندی K-means برای پیاده‌سازی استفاده شده و مقدار k بر اساس حجم داده‌های آموزشی تعیین می‌شود. داده‌های آموزشی به تعداد مدل‌هایی که در رده‌بند گروهی موجود است، تقسیم می‌شود. برای پیاده‌سازی این الگوریتم، داده‌های آموزشی به شش قطعه داده تقسیم شده و روی هر قطعه i با استفاده از الگوریتم K-means خوشه‌بندی انجام می‌شود و مدل m_i به‌دست می‌آید. مقدار k برای هر ۶ قطعه داده یکسان در نظر گرفته شده است. پس از حذف داده‌ها، هر مدل m_i شامل مجموعه‌ای از k خلاصه داده است.

یک داده جریان x با استفاده از مدل m_i به‌صورت زیر رده‌بندی می‌شود. فرض کنید $h \in m_i$ یک خلاصه داده باشد که مرکز آن، نزدیک‌ترین مرکز به نمونه x نسبت به دیگر خلاصه‌های موجود در m_i است. با فرض این‌که مقدار k برای اجرای الگوریتم K-NN یک در نظر گرفته شود، رده‌ای که برای x در نظر گرفته می‌شود، بیشترین تعداد تکرار رده در خلاصه داده h است. رده‌بندی داده x با استفاده از رده‌بند گروهی M و با گرفتن رأی بیشینه از بین همه رده‌بندها انجام می‌شود. درصورتی‌که مقدار k غیر یک باشد، باید از بین k خلاصه داده رأی بیشینه گرفته شود. مرز تصمیم برای هر مدل m_i اجتماعی از فضای ویژگی همه خلاصه داده‌های $h \in m_i$ است. به همین ترتیب مرز تصمیم رده‌بند گروهی M به‌صورت اجتماعی از مرزهای تصمیم همه مدل‌های $m_i \in M$ تعریف می‌شود.

۳-۲- تشخیص تغییر

یک جریان داده توالی از چندتایی‌هایی است که هر نمونه داده x_j شامل بردار ویژگی f_j و یک برچسب l_j است و به شکل کلی (f_j, l_j) نمایش داده می‌شود. در این نمایش f_j برداری از همه ویژگی‌های نمونه j ام بوده و l_j برچسب نمونه j ام است. دو پنجره B_1 و B_2 با طول ثابت N در نظر می‌گیریم. با گذر جریان داده، تعداد N داده ابتدایی به‌صورت متوالی وارد پنجره اول و N داده بعدی وارد پنجره دوم می‌شود. با پرشدن پنجره‌ها، داده‌های بعدی یک‌به‌یک به پنجره B_2 وارد شده و از طرف مقابل قدیمی‌ترین داده از پنجره B_1 خارج می‌شود.

آنتروپی در نظریه اطلاعات معیاری عددی از میزان تصادفی‌بودن یک متغیر تصادفی است که به‌صورت رابطه (۱) تعریف شده است [15]. آنتروپی به‌دلیل ویژگی‌های مطلوب موجود و به ویژه وجود تقارن در آن، به‌عنوان یک معیار مناسب برای بررسی محتوای اطلاعات به کار گرفته می‌شود. برای مقایسه توزیع داده‌ها، آنتروپی نمونه‌های پنجره B_1 و پنجره B_2 را با هم مقایسه می‌کنیم. اگر اختلاف آنتروپی دو پنجره از حد مشخص λ کمتر بود، جریان داده پایدار بوده و هیچ تغییری رخ نداده است؛ ولی

اگر اختلاف توزیع داده‌ها در دو پنجره از λ بیشتر بود، تغییر تشخیص داده می‌شود. برای محاسبه آنتروپی جریان داده از رابطه (۲) استفاده می‌کنیم:

$$H(x) = -\sum_{i=1}^{n} P_i \, log_2 \, P_i \qquad (۱)$$

$$H(x) = -\sum_{i=1}^{c} \sum_{x} P_i^x \, log_2 \, P_i^x \qquad (۲)$$

که در این روابط x متغیر تصادفی گسسته، P_i احتمال رخداد x_i ،$P(x)$ تابع احتمال چگالی x و c تعداد رده‌ها است. برای محاسبه P_i^x باید در هر مدل، خوشه‌ای که داده جریان x در آن واقع شده است و همچنین با توجه به تعداد نمونه کلاس i نسبت به کل نمونه‌های موجود در آن خوشه محاسبه شود؛ سپس از بین مقادیر به‌دست‌آمده برای هر مدل، میانگین گرفته و مقدار P_i^x محاسبه می‌شود.

۳-۳- به‌روزرسانی مدل گروهی رده‌بند

زمانی که یک تغییر مفهوم شناسایی می‌شود، رده‌بند با استفاده از داده‌های دو پنجره به‌روز می‌شود. به این صورت که یک مدل جدید با استفاده از داده‌های دو پنجره ساخته شده و جایگزین قدیمی‌ترین مدل از میان مدل‌های موجود می‌شود. این کار تضمین می‌کند به‌طوردقیق تعداد مشخصی مدل در هر زمان وجود داشته باشد. پس از به‌روزرسانی مدل، داده‌های دو پنجره حذف می‌شود. به این ترتیب روش پیشنهادی از داده‌های جریان نیز برای آموزش رده‌بند استفاده می‌کند و مسأله تغییر مفهوم هم با به‌روزرسانی مدل گروهی با استفاده از مفاهیم اخیر پاسخ داده می‌شود. زمانی که توزیع داده‌های یک رده تغییر کند، تغییر مفهوم رخ می‌دهد؛ بنابراین لازم است با به‌روزرسانی رده‌بند داده‌هایی که درقبل به‌عنوان داده پرت شناخته می‌شده، اکنون به‌عنوان نمونه‌ای از یک رده تلقی کنیم. این شناسایی تغییرات در بهبود عملکرد رده‌بندی مؤثر است. درصورتی‌که تغییری در توزیع داده‌ها اتفاق نیافتد، رده‌بند قادر است با مدل‌های موجود رده‌بندی را انجام دهد. به این دلیل به‌روزرسانی رده‌بند تنها زمانی که یک تغییر مفهوم شناسایی شود، انجام می‌شود.

۳-۴- پیچیدگی محاسباتی

در این بخش به تحلیل زمان اجرای الگوریتم پیشنهادی می‌پردازیم. در مرحله ساخت مدل اولیه، بر روی داده‌های آموزشی برچسب‌دار، الگوریتم خوشه‌بندی K-means اجرا می‌شود که زمان اجرای آن $O(tkn_I)$ است که n_I تعداد داده‌های آموزشی اولیه است و t تعداد تکرار الگوریتم است. باید توجه کرد که مجموعه داده اولیه به چند قسمت تقسیم شده و الگوریتم خوشه‌بندی روی هر قسمت اجرا می‌شود. اما به‌صورت تجمیعی مرتبه زمان اجرا تغییری نمی‌کند و t برابر حداکثر تکرار الگوریتم در قسمت‌های مختلف مجموعه داده خواهد بود.

در هنگام ورود هر داده جدید، لازم است که ابتدا با مدل رده‌بند گروهی مورد ارزیابی قرار گیرد. بنابراین فاصله هر داده با خلاصه‌های نگه‌داری شده در هر مدل m_i مقایسه خواهد شد که تعداد این خلاصه‌ها حداکثر برابر k است. با فرض ثابت بودن تعداد مدل‌ها، این مقایسه برای هر داده از مرتبه $O(k)$ خواهد بود. محاسبات آنتروپی در پنجره‌های B_1 و B_2 به‌صورت افزایشی با مرتبه ثابت انجام می‌شود. در صورت تشخیص تغییر یک مدل جدید با اجرای خوشه‌بندی K-means بر روی داده‌های دو پنجره با مرتبه زمانی $O(tk(|B_1| + |B_2|))$ ایجاد می‌شود که t تعداد تکرار در خوشه‌بندی است. بنابراین در بدترین حالت هر داده جریان در یک اجرای الگوریتم K-means دخیل بوده و به‌ازای هر داده از مرتبه $O(tk)$ کار انجام می‌شود.

۴- پیاده‌سازی و نتایج

در این بخش، به بیان مجموعه داده و مقایسه روش پیشنهادی با برخی از روش‌های موجود در رده‌بندی جریان داده پرداخته می‌شود. پیاده‌سازی این مقاله به زبان جاوا انجام شده است.

۴-۱- مجموعه‌داده

بخشی از مجموعه‌داده‌های استفاده‌شده برای این مقاله از تارنمای UCI به‌دست آمده است. در جدول (۱) مشخصات مجموعه‌داده‌های استفاده‌شده برای ارزیابی روش پیشنهادی با سایر روش‌های رده‌بندی آورده شده است. مجموعه‌داده Gaussian Generator با استفاده از توزیع گوسی با چهار رده و دو ویژگی ساخته شده که مطابق شکل (۳) تعدادی از نمونه‌های دو ردهٔ آبی و قرمز هم‌پوشانی دارند. برای ایجاد تغییر مفهوم، داده‌های سمت چپ ردهٔ آبی و سمت راست ردهٔ قرمز به‌عنوان داده‌های آموزشی و برای داده‌های جریان، داده‌های سمت راست ردهٔ آبی و سمت چپ ردهٔ قرمز به الگوریتم داده شده است. برای دو ردهٔ سبز و زردرنگ هم بخشی از نمونه‌های این دو رده به‌صورت تصادفی به‌عنوان داده آموزشی در نظر گرفته شده و بقیه داده‌های آن‌ها به‌عنوان داده جریان به

الگوریتم داده شده است. هدفِ استفاده از این مجموعه‌داده، بررسی عملکرد الگوریتم با وجود تغییر مفهوم و هم‌پوشانی دو رده به‌صورت هم‌زمان است. مجموعه‌داده Forest Cover شامل ۵۴ ویژگی و هفت رده بوده که ما برای ارزیابی نتایج، پس از نرمال‌سازی از صدهزار نمونه آن استفاده کرده‌ایم.

(جدول-۱): مشخصات مجموعه‌داده‌های استفاده شده برای ارزیابی عملکرد روش پیشنهادی

(Table-1): The characteristics of data sets used to evaluate performance of the proposed method

نام مجموعه‌داده	تعداد نمونه	تعداد کلاس	تعداد ویژگی
Forest Cover	100,000	7	54
Shuttle	40,000	7	9
Skin Segmentation	100,000	2	3
Gaussian Generator	150,000	4	2
Random RBF Generator Drift	100,000	5	17

مجموعه‌داده Shuttle شامل نُه ویژگی و هفت رده است که چهل‌هزار نمونه برای ارزیابی نتایج انتخاب شده است. در مجموعه‌داده Skin Segmentation از صدهزار نمونه به‌عنوان داده آموزشی و داده جریانی استفاده شده است. این سه مجموعه‌داده از تارنمای UCI گرفته شده و مجموعه‌داده آخر با استفاده از Random RBF Generator Drift در MOA با پنج رده و هفده ویژگی ساخته شده است. MOA یک محیط نرم‌افزاری برای اجرای الگوریتم‌ها و اجرای آزمایش‌ها برای یادگیری برخط[1] جریان داده است [16]. مجموعه‌داده Random RBF Generator به این صورت ساخته می‌شود که ابتدا تعدادی مرکز تصادفی تولید می‌شود. به‌طوری‌که هر مرکز دارای موقعیت، انحراف معیار، برچسب رده و وزن است. نمونه‌های جدید با انتخاب تصادفی یک مرکز تولید شده و وزن‌ها برای احتمال انتخاب مراکز، اختصاص می‌یابند. مرکز انتخاب‌شده همچنین برچسب ردهٔ نمونه را تعیین می‌کند. تغییر مفهوم با تغییر در مراکز و با یک سرعت ثابت در مجموعه‌داده ایجاد می‌شود [14]. در مجموعه‌داده Random RBF Generator Drift از MOA برای ساخت داده‌ها استفاده شده و سرعت تغییر مراکز ۰/۰۰۱ واحد در نظر گرفته شده است.

در تمامی مجموعه‌داده‌های معرفی‌شده، تعداد شش‌هزار نمونه به‌عنوان داده آموزشی برای ساخت مدل‌های اولیه در نظر گرفته شده و بقیه نمونه‌ها به‌عنوان داده‌های جریان به الگوریتم داده شده است.

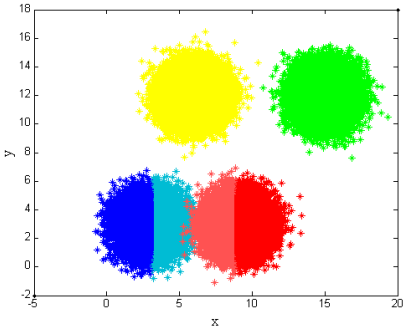

(شکل-۳): نمایش مجموعه‌داده ساختگی با استفاده از توزیع گوسی

(Figur-3): The Gaussian generator artificial data set

۴-۲- معیار ارزیابی

برای نشان‌دادن عملکرد روش پیشنهادی در رده‌بندی جریان داده از معیارهای صحت[2] (Accu)، دقت[3] (PR)، یادآوری[4] (RE) و F1 استفاده شده که در زیر معرفی شده‌اند.

$$Accu(y,\hat{y}) = \frac{1}{n_{samples}} \sum_{i=0}^{n_{samples}-1} 1(\hat{y}_i = y_i) \quad (۳)$$

$$PR = \frac{TP}{TP+FP} \quad (۴)$$

$$RE = \frac{TP}{TP+FN} \quad (۵)$$

$$F1 = \frac{2*PR*RE}{PR+RE} \quad (۶)$$

(جدول-۲): مقایسه روش پیشنهادی و دو روش OBA و HAT بر روی مجموعه‌داده Forest Cover

(Table-2): Comparison of the proposed method OBA and HAT on the Forest Cover data set

معیار	روش	روش پیشنهادی	OBA	HAT
PR	C1	**99.3**	66.4	59.8
	C2	66.04	**68.99**	66
	C3	**100**	79.65	77.98
	C4	**100**	48.36	47.33
	C5	**100**	17.76	17.53
	C6	**100**	30.59	28.94
	C7	**100**	53.98	55.66
RE	C1	53.52	45.91	**57.09**
	C2	**100**	89.94	79.2
	C3	35.19	**56.69**	52.07
	C4	5.46	**42.21**	39.96
	C5	**52.15**	9.05	14.56
	C6	36.23	**80.64**	74.8
	C7	**60.61**	47.53	59.06
F1	C1	**69.55**	54.29	58.41
	C2	**79.55**	78.08	72
	C3	52.06	**66.24**	62.44
	C4	10.35	**45.08**	43.33
	C5	**68.55**	11.99	15.91
	C6	**53.19**	44.35	41.73
	C7	**75.47**	50.55	57.31

[1] Online

[2] Accuracy
[3] Precision
[4] Recall

در رابطه (۳) منظور از $\hat{y}_i$ مقدار پیش‌بینی‌شده نمونه i ام و y_i مقدار واقعی نمونه i و n تعداد نمونه‌های موجود است. در رابطه (۴) و (۵) منظور از TP تعداد نمونه‌هایی است که به‌درستی به‌وسیلهٔ رده‌بند به ردهٔ C_i انتساب یافته و FP یعنی تعداد نمونه‌هایی که متعلق به سایر رده‌ها بوده و به‌اشتباه به‌وسیلهٔ رده‌بند به ردهٔ C_i منسوب شده‌اند. FN تعداد نمونه‌هایی است که متعلق به ردهٔ C_i بوده ولی به‌وسیلهٔ رده‌بند به سایر رده‌ها تعلق گرفته است. معیار TN تعداد نمونه‌هایی است که متعلق به کلاس C_i نبوده‌اند و به‌وسیلهٔ رده‌بند به این رده اختصاص داده نشده‌اند. در رابطه (۶) هم معیار F1 با استفاده از دو معیار دقت و یادآوری به‌دست می‌آید.

۴-۳- نتایج آزمایش‌ها

ابتدا مقایسه‌ای بین دو روش OBA و HAT با روش پیشنهادی انجام شده است. روش HT (Hoeffding Tree) همان الگوریتم درخت تصمیم است که با اعمال تغییراتی برای اجرا بر روی جریان داده سازگار شده است. ایده اصلی این الگوریتم محدودکردن سطح اطمینان بهترین ویژگی برای تقسیم درخت است. روش HAT (Hoeffding Adaptive Tree) با ایجاد تغییر در بیشینه تعداد تقسیم و حذف برخی گره‌های درخت در روش HT، سعی در کوچکترکردن درخت برای سازگاری سریع‌تر الگوریتم با تغییرات موجود در جریان داده کرده است [17]. OBA (OzaBagAdwin) یک روش گروهی برای تشخیص تغییر به همراه تخمین وزن برای بهبود عملکرد است. تشخیص تغییر با مقایسه میانگین مقادیر نمونه‌هایی که قبل و بعد از اضافه‌شدن نمونه i ام به پنجره به‌دست می‌آیند، انجام می‌گیرد. زمانی که تغییر، تشخیص داده می‌شود، رده‌بند جدید جایگزین بدترین رده‌بند در مدل گروهی می‌شود [14].

جدول (۲) نتایج به‌دست‌آمده از رده‌بندی روش پیشنهادی و دو روش OBA و HAT را بر روی مجموعه‌داده Forest Cover نشان می‌دهد. در این جدول میزان دقت، یادآوری و همچنین F1 هر کدام از این سه روش به تفکیک برای هر رده آمده است. همان‌طور که مشاهده می‌شود، روش پیشنهادی برای بیشتر رده‌های موجود در مجموعه‌داده در هر سه معیار ارزیابی بالاتر بوده و در کل عملکرد بهتری داشته است.

در شکل (۴) مقایسه این سه روش بر روی مجموعه‌داده Forest Cover با معیار ارزیابی صحت نشان داده شده که در هر مرحله پنج‌هزار داده به مجموعه‌داده جریان اضافه شده است. همان‌طور که از شکل (۴) مشخص است، روش پیشنهادی در تمام مراحل به‌مراتب از دو روش دیگر صحت بیشتری داشته و عملکرد خوبی را ارائه داده است.

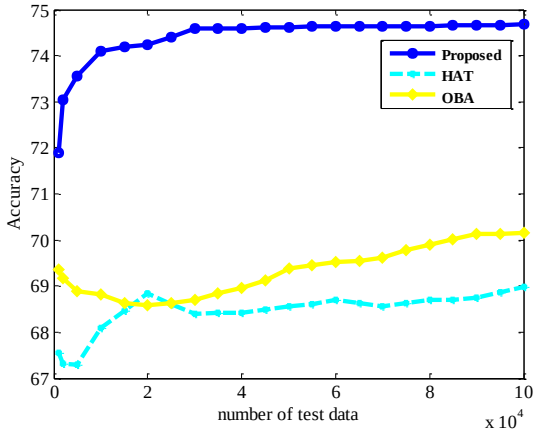

(شکل-۴): مقادیر تغییر صحت به‌ازای اضافه‌شدن پنج‌هزار داده جریان در هر مرحله برای مجموعه‌داده Forest Cover

(Figure-4): Accuracy values while adding 5,000 test data per step for the Forest Cover data set

در شکل (۵) روش پیشنهادی با دو روش OBA و HAT بر روی مجموعه‌داده Shuttle مقایسه شده که در هر مرحله دوهزار داده به مجموعه‌داده جریان اضافه شده است. همان‌طور که مشاهده می‌شود، صحت روش پیشنهادی در ابتدا با تعداد داده جریان کمتر از دوهزار با روش OBA برابر است؛ ولی با زیادشدن داده‌های جریان خیلی سریع صحت روش پیشنهادی بالا رفته و از روش OBA فاصله می‌گیرد. بالارفتن صحت روش پیشنهادی برای هر دو مجموعه‌داده، نشان‌دهنده آن است که بیشتر تغییرات موجود در این دو مجموعه‌داده از نوع تدریجی و ناگهانی بوده و این روش به‌خوبی تغییرات موجود در داده‌ها را تشخیص داده و از آن‌ها برای آموزش الگوریتم و به‌روزرسانی مدل گروهی رده‌بند استفاده می‌کند.

در جدول (۳) صحت روش پیشنهادی در مقایسه با دو روش OBA و HAT و همچنین روش پیشنهادی مرجع [23] بر روی مجموعه‌داده‌های مختلف نشان داده شده است. مرجع [23] از دو ماتریس خلاصه برای تقریب داده‌ها استفاده می‌کند و برای هر ماتریس با استفاده از تجزیه مقادیر منفرد، بهینه‌ترین تقریب را به‌دست می‌آورد. همچنین از میانگین اعداد به‌دست‌آمده از این ماتریس به‌عنوان معیار شباهت استفاده کرده و برای تشخیص ردهٔ جدید بهره می‌برد. پیچیدگی زمانی روش پیشنهادی و روش [23] هر دو از مرتبه خطی نسبت به تعداد داده‌ها است. پیچیدگی زمانی دو روش دیگر در مراجع یاد نشده است. همان‌طور که مشاهده می‌شود، در تمامی مجموعه‌داده‌ها روش پیشنهادی از صحت بالاتری نسبت به

دو روش دیگر برخوردار بوده و عملکرد بهتری دارد. این نشان می‌دهد که بیش‌تر تغییرات موجود در داده‌ها از نوع تدریجی و ناگهانی است و این روش به‌خوبی توانسته تغییرات موجود در مجموعه داده را تشخیص داده و با به‌روزرسانی مدل گروهی رده‌بند، در بهبود دقت و صحت الگوریتم مؤثر باشد.

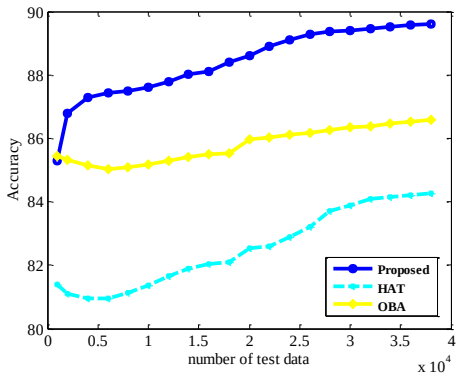

(شکل-۵): مقادیر تغییر صحت به‌ازای اضافه‌شدن دوهزار داده جریان در هر مرحله برای مجموعه‌داده Shuttle

(Figure-5): Accuracy values while adding 2,000 test data per step for the Shuttle data set

(جدول-۳): مقایسه صحت روش‌ها بر روی مجموعه‌داده‌های مختلف

(Table-3): Comparing accuracy of the methods on different data sets

نام مجموعه‌داده	روش پیشنهادی	OBA	HAT	[23]
Forest Cover	**74.67**	70.16	68.98	71.05
Shuttle	**89.61**	86.57	84.26	87.79
Skin Segmentation	**100**	99.4	99.21	100
Gaussian Generator	**98.3**	95.2	95.1	97.04
Random RBF Generator Drift	**81.32**	79.83	78.06	80.07

۵- نتیجه‌گیری

در این مقاله، یک رده‌بند گروهی نیمه‌نظارتی معرفی شده که می‌تواند دو نوع تغییر مفهوم تدریجی و ناگهانی را در جریان داده تشخیص داده و دقت رده‌بندی را بهبود بخشد. این رده‌بند گروهی برای تشخیص تغییر از آنتروپی استفاده می‌کند، به‌طوری‌که با واردشدن هر داده تغییر آنتروپی داده‌ها بررسی و درصورتی‌که تغییر از حد معینی بیشتر بود، تغییر مفهوم تشخیص داده می‌شود. با تشخیص تغییر مفهوم یک مدل جدید از داده‌های اخیر ساخته شده و مدل گروهی به‌روزرسانی می‌شود. این رده‌بند بر روی مجموعه‌داده‌های مختلفی با سه روش موجود مقایسه شده است. نتایج به‌دست‌آمده نشان‌دهنده عملکرد بهتر روش پیشنهادی نسبت به روش‌های دیگر بر روی این مجموعه‌داده‌ها است. به‌عنوان کارهای آینده می‌توان تشخیص مفاهیم جدید را به روش ارائه‌شده اضافه کرد. بخشی از داده‌های پرتی که به‌وسیلهٔ الگوریتم ارائه‌شده کنار گذاشته می‌شوند، در واقع داده‌هایی هستند که نمایان‌گر یک مفهوم جدید هستند. با ارائه روشی می‌توان این مفاهیم جدید را تشخیص داده و دقت رده‌بند را افزایش داد.

سپاس و قدردانی

به این وسیله از بنیاد ملی نخبگان جهت حمایت از پژوهش سپاس‌گزاری و قدردانی به‌عمل می‌آید.

6- References ۶- مراجع

[1] M. Masud, J. Gao, L. Khan, J. Han and B. M. Thuraisingham, "Classification and novel class detection in concept-drifting data streams under time constraints," *IEEE Transactions on knowledge and data engineering*, vol. 23, no. 6, pp. 859-874, 2010.

[2] M. M. Masud, Q. Chen, L. Khan, C. Aggarwal, J. Gao, J. Han and B. Thuraisingham, "Addressing concept-evolution in concept-drifting data streams," in *2010 IEEE International Conference on Data Mining*, IEEE, 2010, pp. 929-934.

[3] B. S. Parker and L. Khan, "Detecting and tracking concept class drift and emergence in non-stationary fast data streams," in *Twenty-ninth AAAI conference on artificial intelligence*, 2015.

[4] R. Klinkenberg, "Learning drifting concepts: Example selection vs. example weighting," *Intelligent data analysis*, vol. 8, no. 3, pp. 281-300, 2004.

[5] A. Bifet and R. Gavalda, "Learning from time-changing data with adaptive windowing," in *Proceedings of the 2007 SIAM international conference on data mining*, SIAM, 2007, pp. 443-448.

[6] A. Haque, L. Khan and M. Baron, "Sand: Semi-supervised adaptive novel class detection and classification over data stream," in *THIRTIETH AAAI Conference on Artificial Intelligence*, 2016.

[7] L. I. Kuncheva and W. J. Faithfull, "PCA feature extraction for change detection in multidimensional unlabeled data," *IEEE transactions on neural networks and learning systems*, vol. 25, no. 1, pp. 69-80, 2013.

[8] P. Sidhu and M. Bhatia, "A novel online ensemble approach to handle concept drifting data streams: diversified dynamic weighted majority," *International Journal of Machine Learning and Cybernetics*, vol. 9, no. 1, pp. 37-61, 2018.

Fuzzy Systems, vol. 28, no. 3, pp. 544-557, 2019.

[22] Y. Li, Y. Wang, Q. Liu, C. Bi, X. Jiang, and S. Sun. "Incremental semi-supervised learning on streaming data." *Pattern Recognition*, vol. 88 pp. 383-396, 2019.

[23] X. Mu, F. Zhu, J. Du, E.P. Lim, & Z.H. Zhou, “Streaming classification with emerging new class by class matrix sketching” In Thirty-First AAAI Conference on Artificial Intelligence, pp. 2373–2379, 2017.

[24] P. Vorburger, A. Bernstein. “Entropy-based concept shift detection” In Sixth IEEE International Conference on Data Mining, ICDM'06, pp. 1113–1118, 2006.

[25] L. Du, Q. Song, and X. Jia. "Detecting concept drift: an information entropy based method using an adaptive sliding window." *Intelligent Data Analysis* vol. 18, no. 3, pp. 337-364, 2014.

[26] J. Haug, G. Kasneci. “Learning Parameter Distributions to Detect Concept Drift in Data Streams”. arXiv preprint arXiv:2010.09388. 2020.

[27] H. Hanqing, M. Kantardzic, T. S. Sethi. "No Free Lunch Theorem for concept drift detection in streaming data classification: A review." Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, Vol. 10, no. 2, e1327, 2020.

[۲۸] م. مسافری، ع. صفائی. ارائه روشی پویا جهت پاسخ به پرس‌وجوهای پیوسته تجمّعی اقتضایی. پردازش علائم و داده‌ها. جلد ۱۴، شماره ۳، ص۲۲-۳، ۱۳۹۶.

[23] M. Mosaferi, A. Safaei, “Providing a Dynamic Technique for Answering Ad-hoc Continuous Aggregate”. *Journal of Signal and Data Processing*. Vol. 14, No. 3, pp. 3-22, 2017.

[9] O. A. Mahdi, E. Pardede and J. Cao, "Combination of information entropy and ensemble classification for detecting concept drift in data stream," in *Proceedings of the Australasian Computer Science Week Multiconference*, ACM, 2018, p. 13.

[10] M. Ester, H.-P. Kriegel, J. Sander and X. Xu, "A density-based algorithm for discovering clusters in large spatial databases with noise," in *Kdd*, 1996, pp. 226-231.

[11] X. Zhu and A. B. Goldberg, "Introduction to semi-supervised learning," *Synthesis lectures on artificial intelligence and machine learning*, vol. 3, no. 1, pp. 1-130, 2009.

[12] A. Tsymbal, "The problem of concept drift: definitions and related work," *Computer Science Department, Trinity College Dublin*, vol. 106, no. 2, p. 58, 2004.

[13] I. Žliobaitė, "Learning under concept drift: an overview," in *arXiv preprint arXiv:1010.4784*, 2010.

[14] A. Bifet, G. Holmes, B. Pfahringer, R. Kirkby and R. Gavaldà, "New ensemble methods for evolving data streams," in *Proceedings of the 15th ACM SIGKDD international conference on Knowledge discovery and data mining*, ACM, 2009, pp. 139-148.

[15] S. J. Morshed, J. Rana and M. Milrad, "Real-time Data analytics: An algorithmic perspective," in *International Conference on Data Mining and Big Data*, Springer, 2016, pp. 311-320.

[16] A. Bifet, G. Holmes, R. Kirkby and B. Pfahringer, "Moa: Massive online analysis," *Journal of Machine Learning Research*, vol. 11, no. May, pp. 1601-1604, 2010.

[17] B. Pfahringer, G. Holmes and R. Kirkby, "Handling numeric attributes in hoeffding trees," in *Pacific-Asia Conference on Knowledge Discovery and Data Mining*, Berlin, Heidelberg, Springer, 2008, pp. 296-307.

[18] D.L. Cabral, D. Rafael, and R.S.M. de Barros. "Concept drift detection based on Fisher’s Exact test." *Information Sciences*, vol. 442, pp. 220-234, 2018.

[19] R.F. de Mello, Y. Vaz, C.H. Grossi, and A. Bifet. "On learning guarantees to unsupervised concept drift detection on data streams." *Expert Systems with Applications*. Vol. 117, pp. 90-102, 2019.

[20] X. Wang, Q. Kang, M. Zhou, L. Pan, and A. Abusorrah. "Multiscale Drift Detection Test to Enable Fast Learning in Nonstationary Environments." *IEEE Transactions on Cybernetics*, pp. 1-13, 2020.

[21] Y. Song, J. Lu, H. Lu, and G. Zhang. "Fuzzy clustering-based adaptive regression for drifting data streams." *IEEE Transactions on*

حسین حسن‌نژاد نامقی مدرک کارشناسی خود را در رشته کامپیوتر گرایش نرم‌افزار از دانشگاه صنعتی شاهرود در سال ۱۳۹۴ دریافت کرد. وی در حال حاضر دانشجوی مقطع کارشناسی ارشد در دانشگاه صنعتی شاهرود در گرایش هوش مصنوعی است. موضوع پایان‌نامه کارشناسی ارشد ایشان، "رده‌بندی نیمه‌نظارتی جریان‌های داده تکاملی" است. زمینه‌های پژوهشی مورد علاقه ایشان داده‌کاوی، یادگیری ماشین و کاوش داده‌های حجیم است.

نشانی رایانامه ایشان عبارت است از:

h_hasannezhad@shahroodut.ac.ir

هدی مشایخی فارغ‌التحصیل مقطع دکترای تخصصی رشته مهندسی کامپیوتر، گرایش نرم‌افزار از دانشگاه صنعتی شریف است. پیش از آن، مقاطع کارشناسی و کارشناسی ارشد را نیز در همان دانشگاه به پایان رسانیده است. وی در حال حاضر استادیار دانشگاه صنعتی شاهرود است. داده‌کاوی و یادگیری در زمینه داده‌های حجیم و پردازش توزیع‌شده از جمله علایق پژوهشی ایشان است.

نشانی رایانامه ایشان عبارت است از:

hmashayekhi@shahroodut.ac.ir

مرتضی زاهدی در حال حاضر عضو هیأت علمی دانشکده مهندسی کامپیوتر دانشگاه صنعتی شاهرود است. وی پروژه‌هایی را در زمینه تعامل انسان و رایانه، شناسایی الگو، پردازش تصویر و ویدئو، و بینایی ماشین در دست اجرا دارد که در آنها به‌طورمعمول از اطلاعات و دانش آماری استفاده می شود. ایشان دارای دکترای تخصصی کامپیوتر از دانشگاه RWTH-Aachen آلمان است. تألیف کتب و مقالات علمی و همچنین سرپرستی پروژه‌های دانشگاهی و صنعتی در ایران و کشورهای اروپایی در کارنامهٔ کاری ایشان دیده می‌شود.

نشانی رایانامه ایشان عبارت است از:

zahedi@suigle.com