



انتخاب برخط ویژگی‌های جریانی با استفاده از سری هندسی ماتریس مجاورت ویژگی‌ها

صادق اسکندری

گروه علوم رایانه، دانشکده علوم ریاضی، دانشگاه گیلان، رشت، ایران

چکیده

انتخاب، ویژگی یکی از گام‌های پیش‌پردازش مهم در یادگیری ماشینی و داده‌کاوی است. تمامی الگوریتم‌های انتخاب ویژگی سنتی فرض می‌کنند که کل فضای ویژگی از ابتدای چرخه انتخاب در دسترس است؛ با این وجود در بسیاری از کاربردهای دنیای واقعی با سناریوی ویژگی‌های جریانی مواجه هستیم. در این سناریو، تعداد ویژگی‌ها به مرور زمان افزایش می‌یابد. در این مقاله، مسئله انتخاب برخط ویژگی‌های جریانی از منظر سری‌های هندسی گراف ارتباط ویژگی‌ها مورد بررسی قرار گرفته و یک الگوریتم جدید به نام GS-OSFS معرفی شده است. این الگوریتم با استفاده از مفهوم سری هندسی گراف مجاورت، ویژگی‌های افزونه را به شکل برخط حذف می‌کند؛ علاوه بر این، الگوریتم پیشنهادی از یک سازوکار نگهداری ویژگی‌های افزونه بهره می‌برد که امکان بررسی مجدد ویژگی‌های بسیار خوبی را که در قبل حذف شده‌اند، فراهم می‌آورد. الگوریتم پیشنهادی بر روی هشت مجموعه داده با ابعاد بزرگ اعمال شده و نتایج نشان‌دهنده دقیق بالای این الگوریتم در نمونه‌های زمانی مختلف است.

وازگان کلیدی: ویژگی‌های جریانی، انتخاب ویژگی، سری هندسی.

Online Streaming Feature Selection Using Geometric Series of the Adjacency Matrix of Features

Sadegh Eskandari

Department of Computer Science, Faculty of Mathematical Sciences,
University of Guilan, Rasht, Iran

Abstract

Feature Selection (FS) is an important pre-processing step in machine learning and data mining. All the traditional feature selection methods assume that the entire feature space is available from the beginning. However, online streaming features (OSF) are an integral part of many real-world applications. In OSF, the number of training examples is fixed while the number of features grows with time as new features stream in. For instance, in the problem of semantic segmentation of images using texture-based features, the number of features can be infinitely growing.

In these dynamically growing scenarios, a rudimentary approach is waiting a long time for all features to become available and then carry out the feature selection methods. However, due to the importance of optimal decisions at every time step, a more rational approach is to design an online streaming feature selection (OSFS) method which selects a best feature subset from so-far-seen information and updates the subset on the fly when new features stream in. Any OSFS method must satisfy three critical conditions; first, it should not require any domain knowledge about feature space, because the full feature space is unknown or inaccessible. Second, it should allow efficient incremental updates in selected features. Third, it should be

* Corresponding author

*نویسنده عهده‌دار مکاتبات

سال ۱۳۹۹ شماره ۴ پیاپی ۴۶

• تاریخ ارسال مقاله: ۱۳۹۷/۱۰/۹ • تاریخ پذیرش: ۱۳۹۸/۰۶/۱۱ • تاریخ انتشار: ۱۳۹۹/۱۲/۰۴ • نوع مطالعه: پژوهشی



as accurate as possible at each time instance to allow having reliable classification and learning tasks at that time instance.

In this paper, OSFS is considered from the geometric series of features adjacency matrix and, a new OSFS algorithm called OSFS-GS is proposed. This algorithm ranks features based on path integrals and the centrality concept on an online feature adjacency graph. The most appealing characteristics of the proposed algorithm are; 1) all possible subsets of features are considered in evaluating the rank of a given feature, 2) it is extremely efficient, as it converts the feature ranking problem to simply calculating the geometric series of an adjacency matrix and 3) beside selected features subset, it uses a redundant features subset that provides the reconsideration of good features at different time instances.

This algorithm is compared with three state-of-the-art OSFS algorithms, namely information-investing, fast-OSFS and OSFSMI. The information-investing algorithm is an embedded online feature selection method that considers the feature selection as a part of learning process. This algorithm selects a new incoming feature if it reduces the model entropy more than the cost of the feature coding. The fast-OSFS algorithm is a filter method that gradually generates a Markov-blanket of feature space using causality-based measures. For any new incoming feature, this algorithm executes two processes: an online relevance analysis and then an online redundancy analysis. OSFSMI is a similar algorithm to fast-OSFS, in which uses information theory for feature analysis.

The algorithms are extensively evaluated on eight high-dimensional datasets in terms of compactness, classification accuracy and run-time. In order to provide OSF scenario, features are considered one by one. Moreover, in order to strengthen the comparison, the results are averaged over 30 random streaming orders. Experimental results demonstrate that OSFS-GS algorithm achieves better accuracies than the three existing OSFS algorithms.

Keywords: Streaming Features, Feature Selection, Geometric Series.

به عنوان مثالی دیگر، در مسأله قطعه‌بندی مبتنی بر متن تصاویر²، تعداد فیلترهای متن می‌تواند بی‌نهایت باشد و درنتیجه ایجاد کل مجموعه‌ویژگی غیر ممکن خواهد بود [8,9,10].

۲. فضای ویژگی مشخص است؛ ولی پردازش آن‌ها به شکل جریانی مزایای بیشتری در مقایسه با پردازش دسته‌ای در اختیار ما قرار می‌دهد. این سناریو اغلب در مجموعه‌داده‌هایی که دارای فضای ویژگی بسیار بزرگی هستند، یک انتخاب مفید خواهد بود. به عنوان مثال، در مسائل رده‌بندی اسناد³ یک مجموعه داده می‌تواند شامل صدها هزار ویژگی باشد [11] و درنتیجه، استفاده از الگوریتم‌های انتخاب ویژگی سنتی نیاز به فضا و زمان بسیار زیادی خواهد داشت.

شاید ابتدائی ترین ایده جهت انتخاب ویژگی در چنین سناریوهایی، منتظر ماندن جهت تکمیل فضای ویژگی و سپس استفاده از الگوریتم‌های سنتی انتخاب ویژگی باشد؛ ولی، همان‌طور که گفته شد، در فضاهای ویژگی بسیار بزرگ و بی‌نهایت، این ایده عملی نخواهد بود. ایده کارآمدتر و منطقی‌تر، طراحی یک الگوریتم انتخاب ویژگی برخط است که بهترین زیرمجموعه را بر اساس ویژگی‌هایی که تابه حال مشاهده شده‌اند، انتخاب کرده و در زمان ورود هر ویژگی جدید، زیرمجموعه انتخابی را بروز کند. هر الگوریتم انتخاب

² Texture-Based Image Segmentation

³ Document Classification

۱- مقدمه

اگرچه یک مجموعه‌ویژگی بزرگ، اطلاعات بیشتری را درباره یک مفهوم در اختیار ما قرار می‌دهد، در رده‌بندی و یادگیری ماشین این مجموعه تا جایی که امکان دارد باید کوچک در نظر گرفته شود. دلیل اصلی این کار، مقابله با پدیده نفرین ابعاد^۱ و افزایش قابلیت تعمیم مدل یادگیری است [1,2,3]. در مسائل کلاسیک انتخاب ویژگی، یک مجموعه‌داده با n بردار ویژگی m بعدی و یک یا چند ویژگی خروجی (رده) داده شده و هدف انتخاب ویژگی، انتخاب یک زیرمجموعه کمینه از مهم‌ترین و تمیزدهنده‌ترین ویژگی‌ها است. در طول سه دهه اخیر، الگوریتم‌های مختلفی جهت انتخاب ویژگی معرفی شده‌اند [2,4,5,6]. تمامی الگوریتم‌های انتخاب ویژگی سنتی فرض می‌کنند که کل فضای ویژگی از همان ابتدای چرخه انتخاب در دسترس است، اما، ویژگی‌های جریانی بخش جدایی‌ناپذیر بسیاری از کاربردهای دنیای واقعی هستند. در این سناریو، تعداد بردارهای ویژگی (n) ثابت بوده و اندازه مجموعه ویژگی (m) با گذشت زمان رشد می‌کند. می‌توان دو دلیل اصلی برای جریانی‌بودن ویژگی‌ها بیان کرد:

۱. فضای ویژگی نامعلوم و یا حتی بی‌نهایت است. به عنوان مثال، در مسائل یادگیری بیوانفورماتیک استخراج تمامی ویژگی‌ها برای تمامی نمونه‌ها گاهی بدليل محدودیت‌های آزمایشگاهی بسیار زمان بر است [7].

¹ Curse of Dimensionality



سه دهه اخیر الگوریتم‌های انتخاب ویژگی فراوانی معروف شده‌اند [6, 2, 4, 5, 6]. این الگوریتم‌ها را می‌توان در سه گروه دسته‌بندی کرد: روش‌های لفافهای، روش‌های فیلتر و روش‌های جاسازی شده [14].

ساختر الگوریتم‌های انتخاب ویژگی سنتی به‌گونه‌ای است که در هر تکرار نیازمند دسترسی به کل فضای ویژگی، جهت انتخاب بهترین زیرمجموعه هستند؛ بنابراین، فرض اساسی ضمیم در این الگوریتم‌ها، مهیا‌بودن تمامی ویژگی‌ها، قبل از شروع رویه انتخاب ویژگی است. استفاده از این الگوریتم‌ها در سناریوی ویژگی‌های جریانی امکان‌پذیر نیست؛ زیرا بزرگ‌ترین چالش در این سناریو، عدم دسترسی به کل فضای ویژگی است؛ بنابراین مطالعاتی درخصوص انتخاب ویژگی در سناریوی ویژگی‌های جریانی صورت گرفته است.

گرافتینگ برخط⁶ [9] را می‌توان نخستین تلاش در حوزه انتخاب ویژگی‌های جریانی دانست. این الگوریتم نوعی روش انتخاب ویژگی جاسازی شده است که از مقاهم الگوریتم سنتی انتخاب ویژگی گرافتینگ [15] استفاده می‌کند. در گرافتینگ برخط، ویژگی ورودی جدید در صورتی به ویژگی‌های انتخابی اضافه می‌شود که آن ویژگی دقت مدل را بیش از یک حد آستانه λ بهبود بخشند. در [10] از الگوریتم گرافتینگ برخط جهت انتخاب ویژگی‌های مناسب برای تشخیص لبه استفاده شده است. اگرچه الگوریتم گرافتینگ برخط قادر به مدیریت ویژگی‌های جریانی است، ولی استفاده از آن در سناریوهای واقعی با دو چالش اساسی مواجه است: ۱) انتخاب λ مناسب نیازمند دانش کافی درباره فضای ویژگی است و ۲) این الگوریتم از مسئله تأثیر لانه‌ای⁷ [16] رنج می‌برد. بدین معنی که اگر یک ویژگی در زمان t به مجموعه ویژگی اضافه شود، این ویژگی هیچ زمان دیگری بعد از t از مجموعه حذف نخواهد شد، حتی اگر ویژگی مورد نظر افزونه شده باشد.

در [17]، یک الگوریتم جاسازی شده مبتنی بر رگرسیون خطی به نام سرمایه‌گذاری اطلاعات معرفی شده است. در این الگوریتم، ویژگی جدید در صورتی به مدل اضافه می‌شود که کاهش آنتروپی مدل بیش از هزینه کدگذاری ویژگی باشد. از نظر ساختاری این الگوریتم بسیار شبیه به گرافتینگ برخط است با این تفاوت که مقدار حد آستانه در طول اجرای الگوریتم به شکلی پویا تغییر می‌کند. در [18] نیز یک الگوریتم بسیار مشابه با سرمایه‌گذاری

ویژگی برخط برای ویژگی‌های جریانی باید سه شرط اساسی را برآورده کند [1]: نخست، چنین الگوریتمی نباید نیاز به هیچ دانش اضافی درباره فضای ویژگی داشته باشد؛ زیرا فضای ویژگی نامشخص و دسترسی ناپذیر است. دوم‌این‌که، تا حد امکان سریع بوده و به روزرسانی‌های کارآمدی را در ویژگی‌های انتخابی ممکن سازد، زیرا به طور معمول در این سناریو، زمان‌های میان ورود ویژگی‌ها بسیار محدود است. سوم‌این‌که، تا جایی که ممکن است، در هر نمونه زمانی دقیق باشد.

اگرچه چندین مطالعه در حوزه انتخاب برخط ویژگی‌های جریانی صورت گرفته است [13, 1, 3, 9, 8, 11, 12, 13]، هیچ یک از آن‌ها تمامی نیازمندی‌های سه گانه بالا را برآورده نمی‌کند. در این مقاله، مسئله انتخاب برخط ویژگی‌های جریانی از منظر سری‌های هندسی گراف ارتباط ویژگی‌ها مورد بررسی قرار گرفته است. انگیزه اصلی نگارنده برای چنین بررسی، امکان بیان وابستگی‌های بسیار پیچیده میان ویژگی‌ها با استفاده از مسیرهای با طول بینهایت در گراف مجاورت است. در این مقاله، یک الگوریتم جدید به نام OSFS-GS پیشنهاد شده است. این الگوریتم با استفاده از مفهوم سری هندسی گراف مجاورت، ویژگی‌های افزونه را به‌شکل برخط حذف می‌کند. علاوه براین، الگوریتم پیشنهادی از یک سازوکار نگهداری ویژگی‌های افزونه بهره می‌برد که امکان بررسی مجدد ویژگی‌های بسیار خوبی را که در قبل حذف شده‌اند، فراهم می‌آورد. کارآیی و دقت الگوریتم پیشنهادی به‌وسیله نتایج تجربی متعدد به اثبات رسیده است.

ساختر مقاله بدین شکل است که در بخش دو کارهای مرتبط و سپس در بخش سه پیش‌نیازهای روش پیشنهادی بیان می‌شود. چهارچوب روش پیشنهادی در بخش چهار و نتایج تجربی در بخش پنج و در انتهای نیز جمع‌بندی بیان می‌شود.

۲- پیشینهٔ پژوهش

هدف از انتخاب ویژگی، حذف ویژگی‌های نامرتبه⁴ و افزونه⁵ است. ویژگی‌های نامرتبه هیچ اطلاعات مفیدی درخصوص مسئله مورد نظر در اختیار ما قرار نمی‌دهند. ویژگی‌های افزونه حاوی اطلاعات مفیدی هستند؛ ولی این اطلاعات به‌وسیله ویژگی‌های بهتر دیگری نیز بیان شده‌اند. در طول

⁴ Irrelevant

⁵ Redundant

⁶ Online Grafting

⁷ Nesting Effect



اطلاعات، تحت عنوان سرمایه‌گذاری آلفا معرفی شده است. این الگوریتم به جای آنتروپی از مقدار μ آماری به عنوان معیار انتخاب ویژگی استفاده می‌کند. در [11] نشان داده شده است که دو الگوریتم سرمایه‌گذاری اطلاعات و سرمایه‌گذاری آلفا معادل هستند. اگرچه این الگوریتم‌ها قادر به مدیریت فضای ویژگی نامعلوم هستند، دو مشکل اساسی دارند: ۱) فرض اولیه در این الگوریتم‌ها آن است که تمامی ویژگی‌ها به وسیله منبعی با توزیع یکسان (مانند گوسین) تولید می‌شوند. این فرض ضمنی با ماهیت سناریوی ویژگی‌های جریانی در تناقض است. ۲) این الگوریتم‌ها همانند گرافتینگ برخط از مشکل تأثیر لانه‌ای رنج می‌برند. در [19] توسعه‌ای از الگوریتم‌های سرمایه‌گذاری جهت مرتفع ساختن مشکل نخست معرفی شده است.

در [8]، مسأله انتخاب ویژگی‌های جریانی با استفاده از تئوری ارتباط فرموله‌سازی و یک الگوریتم انتخاب برخط به نام الگوریتم سریع معرفی شده است. این الگوریتم از دو گام اساسی تشکیل می‌شود: ۱) آنالیز ارتباط برخط جهت حذف ویژگی‌های نامرتب و ۲) آنالیز افزونگی برخط جهت حذف ویژگی‌های افزونه. الگوریتم سریع یک الگوریتم انتخاب ویژگی فیلتر است و درنتیجه بسیار سریع‌تر از الگوریتم‌های گرافتینگ برخط و سرمایه‌گذاری عمل می‌کند؛ علاوه بر این، برخلاف الگوریتم‌های پیشین، این الگوریتم مشکل تأثیر لانه‌ای ندارد. مشکل اصلی این الگوریتم، آزمون‌های (وابستگی و استقلال) شرطی هستند. جهت تولید نتایج قابل اعتماد به وسیله این آزمون‌ها، نیاز به داده‌های بسیار زیادی است. بنابراین، این الگوریتم از تعداد ویژگی‌های محدودی (حداکثر ۳) جهت انجام این آزمون‌ها استفاده می‌کند. درنتیجه، افزونگی‌های پیچیده‌تر نادیده گرفته می‌شوند.

در [1,3,12]، مسأله انتخاب ویژگی‌های جریانی از منظر مجموعه‌های ناهموار مورد بررسی قرار گرفته است. مزیت اصلی مجموعه‌های ناهموار عدم نیاز عملگرهای آن به دانش اضافی درباره داده است. این ویژگی، مجموعه‌های ناهموار را به یک ابزار ایده‌آل برای سناریوی ویژگی‌های جریانی تبدیل می‌کند. مشکل اصلی استفاده از مجموعه‌های ناهموار، پیچیدگی محاسباتی بالای عملگرهای آن است؛ بنابراین، در تمامی الگوریتم‌های ارائه شده در [1,3,12]، فرض بر این است که تعداد ویژگی‌های انتخابی بسیار کوچک است. درصورتی که تعداد ویژگی‌های غیرافزونه و مرتبط زیاد باشد، استفاده از مجموعه‌های ناهموار بسیار ناکارآمد خواهد بود.

در [13]، یک الگوریتم فیلتر مبتنی بر تئوری اطلاعات معرفی شده است. ساختار کلی این الگوریتم بسیار شبیه به الگوریتم سریع [8] است. مشکل اصلی این الگوریتم نیز نبود درنظرگرفتن تمامی زیرمجموعه‌های مجموعه انتخابی در گام حذف ویژگی‌های افزونه است.

۳- تحلیل ویژگی به وسیله سری هندسی

در این مقاله، از ایده تحلیل ویژگی‌ها در [20] و [14] استفاده شده است. بنابراین، در این بخش به بررسی و معرفی این ایده می‌پردازم. فرض کنید یک مجموعه داده با m ویژگی $\{f_1, \dots, f_m\}$ داده شده است. می‌توان گراف غیرجهت‌دار، کامل و وزن‌دار $G = (V, E, e)$ را برای این مجموعه داده ایجاد کرد؛ به‌گونه‌ای که $V = \{f_i | f_i \in F\}$ و $E = \{(f_i, f_j) | f_i, f_j \in F \wedge i \neq j\}$ بهترین نشان‌دهنده رئوس و یال‌ها بوده و $e: E \rightarrow \mathbb{R}^+$ تابعی است که انرژی دوبعدی ویژگی‌ها را محاسبه می‌کند. گراف G را می‌توان با استفاده از ماتریس مجاورت A نشان داد؛ به‌گونه‌ای که $(e(f_i, f_j)) = a_{ij}$. حال فرض کنید r_i^l نشان‌دهنده مجموعه تمامی مسیرهای با طول l میان رئوس i و j باشد. وقتی داشته باشید که این مجموعه می‌تواند شامل مسیرهایی که حاوی دور هستند نیز باشد.

یک معیار اولیه جهت رتبه بندی ویژگی‌ها آن است که یک l مناسب را انتخاب کرده و مقدار $(i) s_e(i)$ را برای هر ویژگی f_i محاسبه کنیم:

$$s_e(i) = \sum_{j \in V} \sum_{p \in P_{i,j}} \prod_{k=0}^{l-1} a_{v_k, v_{k+1}} = \sum_{j \in V} A^l(i, j) \quad (1)$$

این معیار دارای دو مشکل کلی است: نخست، دورها می‌توانند تأثیر معتبرداری در مقادیر نهایی داشته باشند. دوم، محاسبه A^l از مرتبه $O(n^4)$ است که برای تعداد زیاد ویژگی‌های پیشنهاد شده در [20] پیشنهاد شده است تا به جای استفاده از یک طول مسیر خاص، مجموع معیارها با مقادیر متفاوت l (حتی مقادیر بی‌نهایت) مورد استفاده قرار گیرد. این کار موجب یک‌نواختشدن احتمال عضویت ویژگی‌ها در دورها شده و تأثیر دورها را از بین می‌برد؛ بنابراین، معیار رتبه بندی جدید برای هر ویژگی f_i به صورت زیر قابل بیان است:

$$s(i) = \left[\left(\left(\sum_{l=0}^{\infty} A^l \right) - I \right) \bar{1} \right]_i \quad (2)$$

الگوریتم یک، رویه پیشنهادی جهت انتخاب برش خودگردنی ویژگی های جریانی را نشان می دهد. این الگوریتم سعی در انتخاب بهترین ویژگی ها با استفاده از سری هندسی گراف ارتباط ویژگی ها دارد. این الگوریتم با یک مجموعه انتخابی خالی S کار خود را آغاز می کند؛ سپس منتظر یک ویژگی f_t ورودی جدید می شود (خط ۴). زمانی که ویژگی جدید f_t مهیا می شود، این ویژگی به همراه تعداد K ویژگی خوبی که در زمان های قبلی حذف شده اند (این ویژگی ها در مجموعه R نگهداری می شوند) به مجموعه انتخابی فعلی (S) اضافه می شوند (خط ۵). در گام بعد، ماتریس مجاورت ویژگی های موجود در S بر اساس فرمول (۴) ایجاد شده (خط ۶) و سری هندسی منظم شده آن بر اساس فرمول (۳) محاسبه می شود (خطوط ۷ و ۸). درنهایت تمامی ویژگی هایی که معیار منظم شده آنها کمتر از ویژگی f_t باشد از S حذف شده و به ویژگی های افزونه (R) منتقل می شوند. گام های بالا تا زمان برآورده شدن برخی معیارهای توقف تکرار می شوند. بسته به نوع مسئله، از معیارهای توقف مختلفی می توان بهره جست. به عنوان مثال، اگر فضای ویژگی نامعلوم و یا بی نهایت باشد، معیار توقف می تواند رسیدن به یک حد مناسب از دقت رده بندی باشد. از طرفی دیگر، اگر فضای ویژگی معلوم باشد، می توان معیار توقف را مشاهده آخرین ویژگی در نظر گرفت.

OSFS - GS(C, K)

C: The class attribute

K: Number of relevant features for reconsideration

```

1:    $S \leftarrow \{\}$  //the selected feature subset
2:    $R \leftarrow \{\}$  //the redundant feature subset
3:   do
4:      $f_t \leftarrow \text{Get\_New\_Feature}()$  //wait for a new feature
5:      $S \leftarrow S \cup f_t \cup R[1:K]$ 
6:      $A[i, j] \leftarrow \alpha \left( \max(I(f_i, Y), I(f_j, Y)) \right)$ 
       $+ (1 - \alpha)(1 - |SPR(f_i, f_j)|), \forall f_i, f_j \in S$ 
7:      $G \leftarrow (I - rA)^{-1} - I$ 
8:      $\gamma_{f_i} \leftarrow [G\bar{1}]_i, \forall f_i \in S$ 
9:      $S \leftarrow S - \{f_i\}, Add(\{R, f_i, \beta_{f_i}\}), \forall f_i \in S \text{ and } \gamma_{f_i} < \gamma_f$ 
10:    until (stopping criterion is met)
11:

```

(الگوریتم ۱): رویه پیشنهادی جهت انتخاب برش خودگردانی ویژگی های جریانی

(Algorithm-1): Proposed online streaming feature selection method

۱-۴- فهرست ویژگی های افزونه

در الگوریتم (۱) از یک فهرست مرتب R جهت نگهداری ویژگی های افزونه (ویژگی هایی که تابه حال از ویژگی های انتخابی حذف شده اند) استفاده شده است. دلیل نگهداری

که در آن I یک ماتریس همانی و $\bar{1}$ بردار ستونی از یک ها می باشند.

در جبر ماتریس ها، $\sum_{l=0}^{\infty} X^l$ را سری هندسی ماتریس X می نامند. این سری به $(I - X)^{-1}$ همگرا است اگر و تنها اگر $1 < (X)$ که در آن (X) بزرگترین مقدار ویژه r است. می توان نشان داد که برای هر ماتریس X ، $1 < r(X)$. اگر و تنها اگر $\frac{1}{r(X)} < r < 0$. با استفاده از این ویژگی، معیار منظم شده برای هر ویژگی به صورت زیر قابل تعریف است:

$$\begin{aligned} s'(i) &= \left[\left(\left(\sum_{l=0}^{\infty} r^l A^l \right) - I \right) \bar{1} \right]_i \\ &= [(I - rA)^{-1} - I] \bar{1}_i \end{aligned} \quad (3)$$

پیچیدگی محاسبه $I - rA)^{-1} - I$ برابر $O(n^{2.37})$ است که در مقایسه با $O(n^4)$ برای فرمول (۱)، بسیار کارآمدتر است. یکی از مسائل مهم در راهبرد بالا، تعیینتابع e است.

در [۱۴] نشان داده شده است که برای سناریوهای ناظارت شده، تابع زیر بهترین دقت را نتیجه می دهد:

$$e(\{f_i f_j\}) = \alpha \left(\max(I(f_i, Y), I(f_j, Y)) \right) + (1 - \alpha)(1 - |SPR(f_i, f_j)|) \quad (4)$$

که در آن (\dots, I, \dots) $SPR(\dots, \dots)$ به ترتیب نشان دهنده اطلاعات متقابل و ضریب همبستگی رتبه ای اسپیرمن هستند. علاوه بر این در [۱۴] نشان داده شده است که $\alpha \in [0.8, 1]$ بازه مناسبی برای تعیین ضرایب تأثیر هر یک از معیارهای بالا است.

۴- روش پیشنهادی

فرض کنید $D_t = (X_t, F_t, C)$ مجموعه داده در زمان t باشد که در آن $X_t = \{X_{1,t}, X_{2,t}, \dots, X_{N_t,t}\}$ مجموعه بردارهای ویژگی، $F_t = \{f_{1,t}, f_{2,t}, \dots, f_{M_t,t}\}$ مجموعه ویژگی و C نیز صفت رده باشد. در سناریوی ویژگی های جریانی، ویژگی های جدید به مرور زمان اضافه می شوند؛ در حالی که تعداد بردارهای ویژگی ثابت است. به عبارت دیگر، در این سناریو برای هر $t' > t$ و $M_{t'} \geq M_t$ ، $N_t = N_{t'}$ علاوه بر این، فرض کنید $\{S_{t-1} \cup f_t\} \subseteq \{S_t \cup f_t\}$ زیرمجموعه انتخاب شده تا زمان t و f_t ویژگی ورودی در زمان t باشند. هدف از انتخاب برش خودگردانی ویژگی های جریانی، انتخاب یک زیرمجموعه کمینه $S_t \subseteq \{S_{t-1} \cup f_t\}$ است؛ به گونه ای که برخی معیارهای وابستگی به S_t را بیشینه کند.



در این مقاله از هشت مجموعه‌داده با ابعاد بزرگ استفاده شده است. این مجموعه‌داده‌ها به همراه منبع، اندازه و نوع آنها در جدول (۱) فهرست شده است. رده‌بندی داده‌ها با استفاده از SVM خطی انجام گرفته و جهت مقداردهی پارامتر C در این رده‌بند، از اعتبارسنجی پنج‌تایی استفاده شده است.

با توجه به عدم دسترسی به فضای کلی ویژگی‌ها، ترتیب ورود ویژگی‌ها در نتایج نهایی تأثیرگذار هستند. بنابراین، جهت افزایش دقت مقایسه‌ها، تعداد ۳۰ ترتیب ورود تصادفی برای هر مجموعه‌داده ایجاد و از یک آزمون فرض t جهت مقایسه نتایج بر روی این ترتیب‌ها استفاده شده است. فرض کنید d_A و d_B به ترتیب نمونه‌هایی از جوامع A و B باشند. آزمون‌های فرض t را به صورت زیر تعریف می‌کنیم:

$$t_1: \begin{cases} H_0: \mu_{d_A} = \mu_{d_B} \\ H_1: \mu_{d_A} > \mu_{d_B} \end{cases} \quad (7)$$

$$t_1: \begin{cases} H_0: \mu_{d_A} = \mu_{d_B} \\ H_1: \mu_{d_B} > \mu_{d_A} \end{cases} \quad (8)$$

که در آن μ_D میانگین جمعیت D است. حال بر اساس نتایج این دو آزمون، متغیر t را به صورت زیر تعریف می‌کنیم:

$$t = \begin{cases} \uparrow & \text{if } H_0 \text{ in } t_1 \text{ is rejected} \\ \downarrow & \text{if } H_0 \text{ in } t_2 \text{ is rejected} \\ = & \text{otherwise} \end{cases} \quad (9)$$

(جدول-۱): فهرست مجموعه‌داده‌ای مورد استفاده

در نتایج تجربی

(Table-1): The benchmark datasets used in experimental results

حوزه	تعداد نمونه‌ها	تعداد ویژگی‌ها	مجموعه‌داده
زنیتیک	1600	10000][21 dorothaea
تشخیص سرطان	800	10000][21 arcene
رده بندی متن	2300	20000][21 dexter
نامعلوم	3800	500][21 madelon
صنویعی	1000	100][15 tm1
صنویعی	1000	100][15 tm2
رده بندی تصویر	9963	6096][22 VOC 2007
رده بندی تصویر	22531	6096][23 VOC 2012

۱-۵-۱- تأثیر پارامتر K بر کارآیی الگوریتم پیشنهادی

مهم‌ترین پارامتر در الگوریتم یک، تعداد ویژگی‌هایی است که از مجموعه R به مجموعه S اضافه می‌شوند. این انتقال به ویژگی‌های خوبی که حذف شده‌اند، شناس بررسی مجدد را می‌دهد. جداول (۲) و (۳) نتیجه تأثیر این پارامتر بر دقت

چنین فهرستی آن است که ممکن است، ویژگی‌ای که در زمان t به دلیل حضور ویژگی f_t افزونه شده باشد، در یک زمان $t' > t$ به دلیل حذف ویژگی f_t افزونه نباشد. یک مشکل عمده در نگهداری چنین فهرستی، افزایش اندازه آن با گذشت زمان است. این افزایش باعث کاهش سرعت جستجو در یافتن بهترین ویژگی‌ها (خط ۵ در الگوریتم ۱) می‌شود. جهت حل این مشکل، فهرست R همواره بر اساس معیار زیر مرتب نگهداری می‌شود:

$$\beta(f) = I(f, C) - \frac{T_f}{\sum_{j \in R} T_{f_j}} \quad (5)$$

که در آن T_f نشان‌دهنده تعداد دفعاتی است که ویژگی f از فهرست R به فهرست S منتقل شده ولی دوباره حذف شده است؛ بنابراین، اگر یک ویژگی چندین بار به فهرست S منتقل شده و دوباره حذف شود، دچار جریمه شده و از ابتدای فهرست R فاصله می‌گیرد.

۴-۲- پیچیدگی زمانی روش پیشنهادی

فرض کنید در زمان t ویژگی جدید f_t وارد شود و نیز فرض کنید S_t و R_t به ترتیب نشان‌دهنده مجموعه ویژگی‌های انتخابی و افزونه در زمان t باشند. نخستین گام محاسباتی پس از مشاهده f_t ، محاسبه ماتریس مجاورت برای مجموعه $S_t \cup f_t \cup R[1..K]$ است. پیچیدگی زمانی این گام برابر $O((|S_t| + K + 1)^2)$ است. در گام بعد، محاسبه معیار منظم شده اتفاق می‌افتد. پیچیدگی زمانی این گام برابر $O((|S_t| + K + 1)^{2.37})$ است؛ درنهایت عمل Add می‌شود که دارای پیچیدگی زمانی $O(\log_2 |R_t|)$ است؛ بنابراین، پیچیدگی زمانی الگوریتم پیشنهادی جهت پردازش هر ویژگی جدید ورودی به صورت زیر خواهد بود:

$$O((|S_t| + K + 1)^2 + (|S_t| + K + 1)^{2.37} + \log_2 |R_t|) \quad (6)$$

۵- نتایج تجربی

نتایج تجربی را می‌توان به دو دسته تقسیم‌بندی کرد. دسته نخست شامل آزمایش‌های اولیه جهت بررسی تأثیر مقادیر مختلف پارامتر K بر کارآیی روش پیشنهادی است. دسته دوم شامل آزمایش‌هایی جهت مقایسه الگوریتم پیشنهادی با سه الگوریتم مطرح در حوزه انتخاب برخط ویژگی‌های جریانی، شامل الگوریتم‌های سرمایه‌گذاری آلفا [18]، سریع [8] و مبتنی بر تئوری اطلاعات [13]، است.



استفاده شده است. برای هر یک از این آزمون‌ها، سطح معناداری آماری (α) برابر 0.05 انتخاب شده است. در الگوریتم OSFSMI نیز مقدار مقدار پارامتر β برابر 0.1 قرار داده شده است.

۵-۲-۱- مقایسه از نظر تعداد ویژگی‌های انتخابی
 جدول (۴)، تعداد ویژگی‌های انتخابی بهوسیله الگوریتم‌های مورد مقایسه را فهرست کرده است. از نتایج این جدول مشخص است که الگوریتم سرمایه‌گذاری آلفا کوچک‌ترین زیرمجموعه‌ها را انتخاب می‌کند (به جزء مجموعه داده‌های $tm1$ و $tm2$). نکته قابل ملاحظه در این جدول، تفاوت معنادار اندازه‌های زیرمجموعه‌های انتخابی توسط الگوریتم OSFS-GS برای دو مجموعه‌داده VOC2007 و VOC2012 است. این دو مجموعه‌داده از طریق ترکیب لایه‌های پایانی سه شبکه عمیق GoogleNet (هزار ویژگی)، ResNet (هزار ویژگی) و VGG-VD (۴۰۹۶ ویژگی) بدست آمده‌اند؛ در نتیجه، تعداد ویژگی‌های افزونه و نامرتبط در آنها بهنسبه کم است؛ بنابراین، یک الگوریتم ایده‌آل باید بخش زیادی از این ویژگی‌ها را داشته باشد. اگرچه الگوریتم زیرمجموعه‌هایی را انتخاب کرده که اندازه آنها پسیار کوچک‌تر از مجموعه اصلی است، ولی در مقایسه با سه الگوریتم دیگر، بسیار بهتر عمل کرده است. این رفتار را می‌توان با بررسی مجدد ویژگی‌های افزونه بهوسیله الگوریتم OSFS-GS (۹) را نشان می‌دهد و در آن A نتایج روش OSFS-GS و B نتایج یکی از سایر الگوریتم‌ها است.

(جدول-۴): میانگین زیرمجموعه انتخابی در سی ترتیب ورود مختلف توسط الگوریتم‌های سرمایه‌گذاری آلفا، fast-OSFS و OSFS-GS و OSFSMI. در این جدول، t نتیجه آزمون فرض رابطه (۹) را نشان می‌دهد و در آن A نتایج روش OSFS-GS و B نتایج یکی از سایر الگوریتم‌ها است.

(Table-4): Average sizes of the selected subsets for 30 different streaming orders using alpha-investing, fast-OSFS, OSFSMI and OSFS-GS. In this table, t indicates the result of the hypothesis test defined in eq (9). In the tests, A is OSFS-GS and B is one of the other algorithms.

OSFS-GS	OSFSMI	Fast-OSFS	سرمایه‌گذاری آلفا	مجموعه داده
میانگین	t	میانگین	t	میانگین
9.3	\downarrow	15.7	=	8.5
10.9	=	10.5	\uparrow	8.6
10.7	\uparrow	8.9	\downarrow	12.8
12.9	\downarrow	15.2	\uparrow	5.1
9.6	\downarrow	14.8	\downarrow	23.4
7.8	\downarrow	17.3	\downarrow	34.6
81.7	\uparrow	19.5	\uparrow	12.0
91.8	\uparrow	21.8	\uparrow	11.2

ردبند SVM خطی برای نمونه‌های زمانی (نسبت ویژگی‌های مشاهده شده) مختلف را نشان می‌دهد. همان‌طور که از این دو جدول قابل مشاهده است، بررسی مجدد ویژگی‌های افزونه ($K > 0$) باعث بهبود چشم‌گیر دقت ردبند نسبت به حالتی که ویژگی‌های افزونه به‌طور کامل حذف می‌شوند ($K = 0$)، شده است. از میان مقادیر مختلف این پارامتر، $K = 1$ بیشترین افزایش دقت را نتیجه داده است. به نظر می‌رسد با افزایش بیشتر مقدار K مجموعه انتخابی حاوی تعداد بیشتری ویژگی افزونه می‌شود که خود باعث افزایش اندازه مجموعه ویژگی انتخابی و درنتیجه کاهش دقت ردبندی می‌شود.

(جدول-۲): تأثیر پارامتر K بر دقت ردبند SVM در نمونه‌های زمانی مختلف برای مجموعه‌داده Arcene

(Table-2): The effect(s) of parameter K on the classification accuracy of SVM at different time instances on arcene dataset

Arcene					
% ویژگی‌های مشاهده شده					
100	75	50	25	10	K
62.1	65.7	59.7	61.4	59.8	0
71.2	68.8	71.4	71.9	64.2	1
67.2	67.3	67.1	72.0	63.1	2
67.1	66.9	65.3	65.5	58.9	3
59.8	59.0	60.7	60.6	58.4	4
60.2	57.1	57.4	60.3	57.4	5

(جدول-۳): تأثیر پارامتر K بر دقت ردبند SVM در نمونه‌های زمانی مختلف برای مجموعه‌داده Madelon

(Table-3): The effect(s) of parameter K on the classification accuracy of SVM at different time instances on madelon dataset

Madelon					
% ویژگی‌های مشاهده شده					
100	75	50	25	10	K
51.0	53.2	54.2	49.5	49.3	0
72.4	67.6	67.8	66.9	58.7	1
62.7	57.4	67.1	59.0	53.1	2
58.7	57.9	59.7	60.3	54.7	3
53.7	50.0	54.6	54.2	49.4	4
42.7	41.7	47.5	42.8	48.1	5

۵-۵- مقایسه با روش‌های پیشین

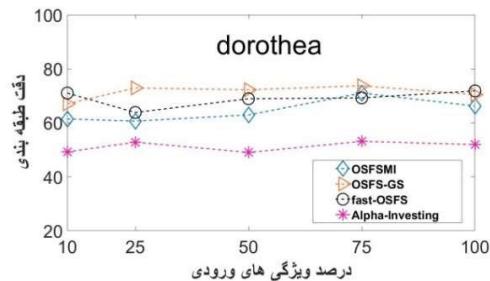
در این بخش، الگوریتم OSFS-GS را با الگوریتم‌های سرمایه‌گذاری آلفا [18] و fast-OSFS [8] و OSFSMI مقایسه می‌کیم. در الگوریتم آلفا [18]، $K = 1$ استفاده شده است. برای الگوریتم سرمایه‌گذاری آلفا، مقادیر پارامترها برابر با مقادیر پیش فرض آنها قرار داده شده است. در الگوریتم fast_OSFS، از آزمون‌های استقلال G^2 برای مجموعه داده‌های کاملاً گستته (حاوی هیچ ویژگی پیوسته‌ای نباشد) و آزمون‌های χ^2 فیشر برای مجموعه‌داده‌هایی که حاوی ویژگی‌های پیوسته هستند،



طول زمان برای این دو مجموعه داده بسیار بزرگ است. درنتیجه محاسبه سری های هندسی برای این زیرمجموعه ها نیز بسیار زمان بر است. البته این مورد نشان دهنده ضعف الگوریتم های دیگر در تشخیص ویژگی های مناسب است.

۵-۲-۳- مقایسه از نظر دقت رده بندی

شکل های (۱ تا ۸)، دقت رده بند SVM خطی برای نمونه های زمانی مختلف را نشان می دهند. همان طور که از این شکل ها قابل ملاحظه است، الگوریتم پیشنهادی از نظر دقت رده بندی بسیار کارآمد عمل کرده است. این کارآمدی به ویژه در مجموعه داده های VOC2007 و VOC2012 محسوس است. برای مجموعه داده های arcene، dorothea، dexter، tm1 و tm2 نیز الگوریتم پیشنهادی بیشتر نمونه های زمانی بهتر از الگوریتم های دیگر عمل کرده است؛ علاوه بر این، برای سایر مجموعه داده ها، این الگوریتم در زمرة الگوریتم های با دقت بالا قرار گرفته است. در مجموع برای نمونه های زمانی ثبت شده در هشت مجموعه داده، روش پیشنهادی در ۲۶ نمونه زمانی از ۴۰ نمونه ۶۵ درصد نمونه های زمانی) بهتر از الگوریتم های دیگر عمل کرده است. علاوه بر این، این الگوریتم تنها در هفت مورد (۱۷,۵ درصد نمونه های زمانی) قادر به تولید بهترین نتیجه نبوده است. در میان الگوریتم های مورد مقایسه، الگوریتم سرمایه گذاری آلفا دقت پایین تری دارد. دلیل چنین عملکردی را می توان به تفاوت مدل یادگیری آن با مدل SVM خطی مرتبط دانست (سرمایه گذاری آلفا یک روش انتخاب ویژگی جاسازی شده است).



شکل-۱: میانگین دقت های رده بندی در نمونه های زمانی متفاوت توسط الگوریتم های سرمایه گذاری آلفا، fast-OSFS، OSFS-GS و OSFSMI برای مجموعه داده dorothea

(Figure-1): The average classification accuracy at different time instances using alpha-investing, fast-OSFS, OSFSMI and OSFS-GS on dorothea

(جدول-۵): میانگین زمان های اجرا در سی ترتیب ورود مختلف توسط الگوریتم های سرمایه گذاری آلفا، fast-OSFS، OSFS-GS

(Table-5): Average running times for 30 different streaming orders alpha-investing, fast-OSFS, OSFSMI and OSFS-GS.

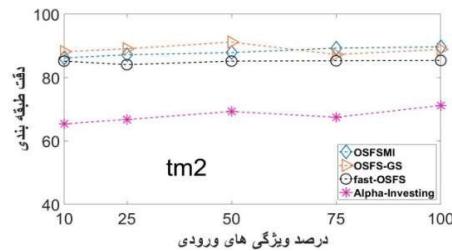
OSFS-GS	OSFSMI	Fast-OSFS	سرمایه گذاری آلفا	مجموعه داده
میانگین	میانگین	میانگین	میانگین	
۳۳.۸	↑ 22.9	↑ 8.6	1 6.5	dorothea
25.9	↑ 12.8	↑ 1.7	↑ 1.8	arcene
32.1	↑ 20.8	↑ 5.9	↑ 7.8	dexter
5.4	↑ 3.8	↑ 0.9	↑ 0.8	madelon
7.5	↑ 4.8	↑ 0.8	↑ 4.2	tm1
7.3	↑ 4.9	↑ 0.8	↑ 3.7	tm2
53.9	↑ 11.8	↑ 1.9	↑ 2.0	VOC 2007
61.3	↑ 13.5	↑ 1.9	1 2.3	VOC 2012

۵-۲-۵- مقایسه از نظر زمان های اجرا

جدول (۵) میانگین زمان های اجرای چهار الگوریتم مورد مقایسه را نشان می دهد. چنان که قابل ملاحظه است، الگوریتم پیشنهادی بیشترین زمان اجرا را در میان این الگوریتم ها دارد. جهت توصیف این رخداد، می توان دو دلیل زیر را بیان کرد:

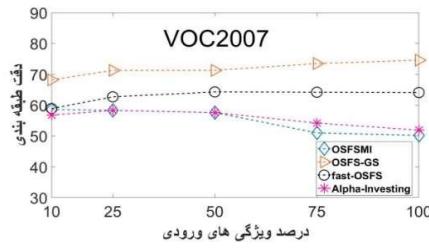
۱- الگوریتم پیشنهادی تنها الگوریتمی است که ویژگی های افزونه را نگهداری و مدیریت می کند. این عمل بار زمانی قابل توجهی را به حلقه های الگوریتم تحمیل می کند؛ به ویژه این که با گذشت زمان اندازه مجموعه ویژگی های افزونه بزرگ تر شده و نگهداری، به روزرسانی و جستجو در آن نیاز به زمان بیشتری دارد. چنان که در قبل گفته شد، این هزینه بابت بررسی مجدد ویژگی های مفیدی که حذف شده اند، اجتناب ناپذیر است؛ با این وجود، می توان با تعریف محدودیت بر روی بیشینه تعداد ویژگی های قابل نگهداری، بخش قابل توجهی از این بار زمانی را تقلیل داد؛ علاوه بر این، می توان با ثابت کردن پارامتر K در این الگوریتم، نیاز به مرتب سازی فهرست ویژگی های افزونه را مرتفع ساخت.

۲- برای دو مجموعه داده VOC2007 و VOC2012، علاوه بر مدیریت ویژگی های افزونه، اندازه بزرگ مجموعه های انتخابی در طول حربیان ویژگی ها، تأثیر بیشتری بر روی زمان اجرای الگوریتم پیشنهادی داشته است. به عبارت دیگر، با توجه به این که این دو مجموعه داده از وزن های شبکه عصبی عمیق استخراج شده اند، بخش بزرگی از ویژگی ها، مرتبط و غیر افزونه هستند؛ به همین دلیل، مجموعه ویژگی های انتخابی در



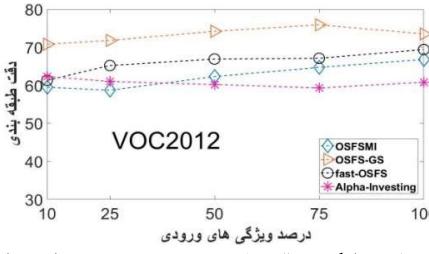
(شکل-۶): میانگین دقت‌های رده‌بندی در نمونه‌های زمانی متفاوت توسط الگوریتم‌های سرمایه‌گذاری آلفا، fast-OSFS، OSFS-GS و OSFSMI برای مجموعه‌داده tm2

(Figure-6): The average classification accuracy at different time instances using alpha-investing, fast-OSFS, OSFSMI and OSFS-GS on tm2



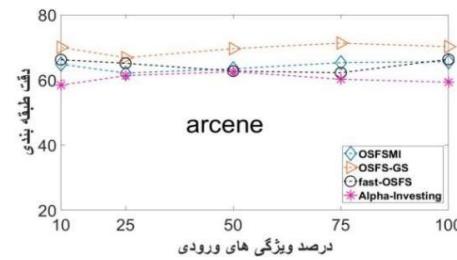
(شکل-۷): میانگین دقت‌های رده‌بندی در نمونه‌های زمانی متفاوت توسط الگوریتم‌های سرمایه‌گذاری آلفا، fast-OSFS، OSFS-GS و OSFSMI برای مجموعه‌داده VOC2007

(Figure-7): The average classification accuracy at different time instances using alpha-investing, fast-OSFS, OSFSMI and OSFS-GS on VOC2007



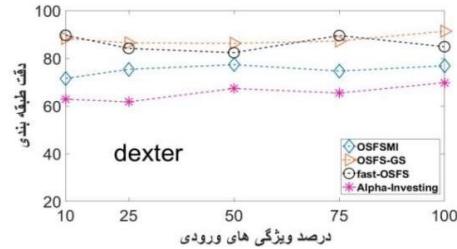
(شکل-۸): میانگین دقت‌های رده‌بندی در نمونه‌های زمانی متفاوت توسط الگوریتم‌های سرمایه‌گذاری آلفا، fast-OSFS، OSFS-GS و OSFSMI برای مجموعه‌داده VOC2012

(Figure-8): The average classification accuracy at different time instances using alpha-investing, fast-OSFS, OSFSMI and OSFS-GS on VOC2012



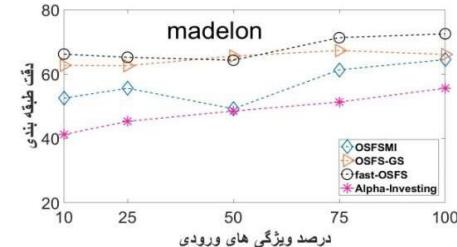
(شکل-۲): میانگین دقت‌های رده‌بندی در نمونه‌های زمانی متفاوت توسط الگوریتم‌های سرمایه‌گذاری آلفا، fast-OSFS، OSFS-GS و OSFSMI برای مجموعه‌داده arcene

(Figure-2): The average classification accuracy at different time instances using alpha-investing, fast-OSFS, OSFSMI and OSFS-GS on arcene



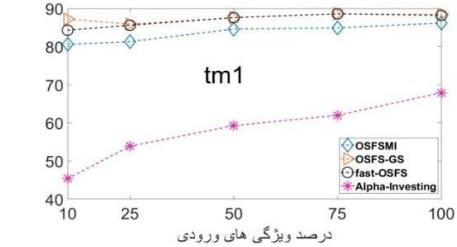
(شکل-۳): میانگین دقت‌های رده‌بندی در نمونه‌های زمانی متفاوت توسط الگوریتم‌های سرمایه‌گذاری آلفا، fast-OSFS، OSFS-GS و OSFSMI برای مجموعه‌داده dexter

(Figure-3): The average classification accuracy at different time instances using alpha-investing, fast-OSFS, OSFSMI and OSFS-GS on dexter



(شکل-۴): میانگین دقت‌های رده‌بندی در نمونه‌های زمانی متفاوت توسط الگوریتم‌های سرمایه‌گذاری آلفا، fast-OSFS، OSFS-GS و OSFSMI برای مجموعه‌داده madelon

(Figure-4): The average classification accuracy at different time instances using alpha-investing, fast-OSFS, OSFSMI and OSFS-GS on madelon



(شکل-۵): میانگین دقت‌های رده‌بندی در نمونه‌های زمانی متفاوت توسط الگوریتم‌های سرمایه‌گذاری آلفا، fast-OSFS، OSFS-GS و OSFSMI برای مجموعه‌داده tm1

(Figure-5): The average classification accuracy at different time instances using alpha-investing, fast-OSFS, OSFSMI and OSFS-GS on tm1

- Online stream feature selection method based on mutual information," *Applied Soft Computing*, vol. 68, pp. 733-746, 2018.
- [14] S. Eskandari and E. Akbas, "Supervised Infinite Feature Selection," CoRR arXiv, 2017.
- [15] S. Perkins, K. Lacker, and J. Theiler, "Grafting: Fast, incremental feature selection by gradient descent in function space," *Journal of machine learning research*, vol. 3, pp. 1333-1356, 2003.
- [16] P. Pudil, J. Novovičová, and J. Kittler, "Floating search methods in feature selection," *Pattern recognition letters*, vol. 15, no. 11, pp. 1119-1125, 1994.
- [17] L. H. Ungar, J. Zhou, D. P. Foster, and B. A. Stine, "Streaming Feature Selection using IIC," in Proceedings of the Tenth International Workshop on Artificial Intelligence and Statistics, 2005.
- [18] J. Zhou, D. Foster, R. Stine, and L. Ungar, "Streaming feature selection using alpha-investing," in Proceedings of the eleventh ACM SIGKDD international conference on Knowledge discovery in data mining, 2005, pp. 384-393.
- [19] P. S. Dhillon, D. Foster, and L. Ungar, "Feature selection using multiple streams," in Proceedings of International Workshop on Artificial Intelligence and Statistics, 2010.
- [20] G. Rosso, S. Melzi, and M. Cristani, "Infinite feature selection," in Proceedings of the IEEE International Conference on Computer Vision, 2015, pp. 4202-4210.
- [21] Isabelle Guyon. (2003) <http://clopinet.com/isabelle/Projects/NIPS2003/>.
- [22] M. Everingham, L. Van Gool, Ch. Williams, J. Winn, and A. Zisserman, The pascal visual object classes (voc) challenge, 2007.
- [23] M. Everingham, L. Van Gool, Ch. K. Williams, J. Winn, and A. Zisserman, The pascal visual object classes (voc) challenge, 2012.
- [24] S. Maldonado and R. Weber, "A wrapper method for feature selection using support vector machines," *Information Sciences*, vol. 179, no. 13, pp. 2208-2217, 2009.
- [25] R. Battiti, "Using mutual information for selecting features in supervised neural net learning," *IEEE Transactions on neural networks*, vol. 5, no. 4, pp. 537-550, 1994.
- [26] G. Brown, A. Pocock, M. Zhao, and M. Luján, "Conditional Likelihood Maximisation: A Unifying Framework for Information Theoretic Feature Selection," *The Journal of Machine Learning Research*, vol. 13, pp. 27-66, 2012.
- [27] M. Dash and H. Liu, "Consistency-based search in feature selection," *Artificial intelligence*, vol. 151, no. 1-2, pp. 155-176, 2003.
- [28] P. Zhao and B. Yu, "On model selection consistency of Lasso," *Journal of Machine learning research*, no. 7, pp. 2541-2563, 2006.

می‌آورد. الگوریتم پیشنهادی بر روی هشت مجموعه داده با ابعاد بزرگ اعمال شد و نتایج آن با الگوریتم‌های سرمایه‌گذاری آلفا، OSFSMI و fast-OSFS مورد مقایسه قرار گرفت. نتایج نشان‌دهنده دقیق بالای الگوریتم پیشنهادی در نمونه‌های زمانی مختلف بود.

7- References

مراجع

- [1] S. Eskandari and M. Javidi, "Online streaming feature selection using rough sets," *International Journal of Approximate Reasoning*, vol. 69, pp. 35-57, 2016.
- [2] I. Guyon and A. Elisseeff, "An introduction to variable and feature selection," *Journal of machine learning research*, vol. 3, pp. 1157-1182, 2003.
- [3] S. Eskandari and M. Javidi, "Streamwise feature selection: a rough set method," *International Journal of Machine Learning and Cybernetics*, vol. 9, no. 4, pp. 667-676, 2016.
- [4] R. Kohavi and G. H. John, "Wrappers for feature subset selection," *Artificial intelligence*, vol. 97, no. 1-2, pp. 273-324, 1997.
- [5] Y. Saeys, I. Inaki , and P. Larrañaga, "A review of feature selection techniques in bioinformatics," *bioinformatics*, vol. 23, no. 19, pp. 2507-2517, 2007.
- [6] V. Bolón-Canedo, S. Noelia , and A. Amparo, "A review of feature selection methods on synthetic data," *Knowledge and information systems*, vol. 34, no. 3, pp. 483-519, 2013.
- [7] J. Wang, Zh. Peilin , H. CH Steven , and J. Rong , "Online feature selection and its applications," *IEEE Transactions on Knowledge and Data Engineering* , vol. 29, no. 3, pp. 698-710, 2014.
- [8] X. Wu, K. Yu, W. Ding, H. Wang, and X. Zhu, "Online feature selection with streaming features," *IEEE transactions on pattern analysis and machine intelligence*, vol. 35, no. 3, pp. 1178-1192, 2013.
- [9] S. Perkins and J. Theiler, "Online feature selection using grafting," in Proceedings of the 20th International Conference on Machine Learning, 2003, pp. 592-599.
- [10] K. Glocer, D. Eads, and J. Theiler, "Online feature selection for pixel classification," in Proceedings of the 22nd international conference on Machine learning, pp. 249-256.
- [11] J. Zhou, D. P. Foster, R. A Stine, and L. H Ungar, "Streamwise feature selection," *Journal of Machine Learning Research*, vol. 7, pp. 1861-1885, 2006.
- [12] M. Javidi and S. Eskandari, "Online streaming feature selection: a minimum redundancy, maximum significance approach," *Pattern Analysis and Applications*, pp. 1-15, 2018.
- [13] M. Rahmani and P. Moradi, "OSFSMI:





صادق اسکندری مدرک دکترای خود را در رشته ریاضی کاربردی و مدرک کارشناسی ارشد در رشته علوم رایانه از دانشگاه شهید باهنر کرمان دریافت کرده و ایشان هم‌اکنون استادیار گروه علوم رایانه دانشگاه گیلان است. زمینه‌های پژوهشی ایشان شامل یادگیری ماشین، یادگیری عمیق و انتخاب ویژگی هستند.

نشانی رایانامه ایشان عبارت است از:
eskandari@guilan.ac.ir



