

معرفی یک روش انتخاب ویژگی چند-برچسبه مبتنی بر کمینه کردن افزونگی

حکیمه حسینی^۱، بهزاد ابراهیمی^۲، فرید صابری موحد^۳، مهدی افتخاری^{۴*}

^۱ کارشناس ارشد گروه ریاضی کاربردی، دانشکده علوم و فناوری‌های نوین، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته، کرمان،

ایران

^۲ کارشناس ارشد بخش مهندسی کامپیوتر، دانشگاه شهید باهنر کرمان، ایران

^۳ استادیار گروه ریاضی کاربردی، دانشکده علوم و فناوری‌های نوین، دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته، کرمان، ایران

^۴ دانشیار بخش مهندسی کامپیوتر، دانشگاه شهید باهنر کرمان، ایران

چکیده

مقاله پژوهشی

روش‌های انتخاب ویژگی ابزاری کارا در بهبود فرآیند یادگیری شناخته می‌شوند. هدف از یک روش انتخاب ویژگی، شناسایی ویژگی‌های مرتبط و حذف ویژگی‌های غیرمرتبط به منظور به دست آوردن یک زیرمجموعه مناسب از ویژگی‌ها است، به طوری که افزونگی بین ویژگی‌های انتخاب شده کمینه گردد. در داده‌های چند-برچسبه، این امکان وجود دارد که در صورت وجود همبستگی بین ویژگی‌ها، مقدار افزونگی در مجموعه ویژگی‌ها افزایش یابد. وجود افزونگی بین ویژگی‌ها به همراه چالش ابعاد بالای داده‌های چند-برچسبه، می‌تواند باعث افزایش حجم محاسبات، کاهش دقت و در نهایت افزایش احتمال رخ دادن خطا در پیش‌بینی و طبقه‌بندی داده‌های چند-برچسبه شود. در این مقاله، باهدف کمینه کردن افزونگی ویژگی‌های انتخابی، یک الگوریتم انتخاب ویژگی چند-برچسبه با در نظر گرفتن مدل رگرسیون کمترین مربعات خطا و تنظیم تنکی پیشنهاد شده است. در انتها، با استفاده از تعدادی مجموعه داده چند-برچسبه مشهور، کارایی روش پیشنهادی بررسی می‌گردد و نتایج به دست آمده با چند روش انتخاب ویژگی چند-برچسبه متداول مقایسه می‌شود.

تاریخ دریافت:

۱۴۰۱/۶/۲۹

تاریخ پذیرش:

۱۴۰۲/۳/۲۳

کلیدواژه‌ها:

انتخاب ویژگی چند-برچسبه، کمینه کردن افزونگی، رگرسیون، کمترین مربعات خطا، تنظیم تنکی

نویسنده مسئول:

m.eftekhari@uk.ac.ir

 : 10.22034/ABMIR.2023.18967.1016

۱- مقدمه

در روش‌های یادگیری با نظارت سنتی، هر نمونه تنها با یک برچسب نشان داده می‌شد تا وابستگی مفهومی کلاس را نشان دهد. با این حال، در بسیاری از مسائل کاربردی در دنیای واقعی، یک نمونه ممکن است توسط مجموعه‌ای از برچسب‌ها نمایش داده شود. به عنوان مثال، در طبقه‌بندی متون [۱]، یک سند ممکن است به موضوعات مختلفی نظیر دولت و سلامت متعلق باشد. در طبقه‌بندی و حاشیه‌نویسی تصاویر [۲]، یک تصویر ممکن است دارای چندین طبقه معنایی مانند ساحل و مناطق شهری باشد. در ژنومیک عملکردی متون [۳]، هر ژن ممکن است مجموعه‌ای از کلاس‌های اساسی مانند متابولیسم، رونویسی و سنتز پروتئین را به خود اختصاص دهد. بنابراین، در مسائل انتخاب ویژگی، دو نمونه از برچسب‌گذاری مورد توجه قرار می‌گیرد: روش تک-برچسب و روش چند-برچسب [۴]. در روش تک-برچسب، هر نمونه فقط با یک برچسب علامت‌گذاری می‌شود، در حالی که در روش چند-برچسب، یک نمونه معمولاً با بیش از یک برچسب علامت‌گذاری می‌شود، به این معنی که هر نمونه، مجموعه‌ای از برچسب‌های متفاوت را دارا است [۵]. مشابه با داده‌های تک-برچسب، داده‌های چند-برچسب نیز با چالش حجیم بودن داده‌ها سروکار دارند. به ویژه آنکه، داده‌های چند-برچسب با ابعاد بالا، اغلب دارای ویژگی‌های غیر ضروری و زائد می‌باشند که منجر به افزایش خطا در پیش‌بینی می‌شود. برای جلوگیری از این مشکل و کاهش تأثیرات منفی ناشی از آن بر فرآیند طبقه‌بندی، باید از بین مجموعه ویژگی‌های اولیه، یک زیرمجموعه از ویژگی‌ها را به گونه‌ای انتخاب کرد که بیشترین تأثیر را بر روی مسئله دارند [۶]. در این راستا، روش‌های انتخاب ویژگی ابزاری کارا در بهبود فرآیند یادگیری شناخته می‌شوند. به طور کلی، هدف از یک روش انتخاب ویژگی، شناسایی یک زیرمجموعه مناسب از ویژگی‌ها و حذف ویژگی‌های غیر مرتبط است، بطوریکه افزونگی بین ویژگی‌های انتخاب شده کمینه گردد، و همچنین این زیرمجموعه منتخب قادر باشد تا

مجموعه داده اصلی را به خوبی تشریح نماید [۷]. برای حل مسائل یادگیری چند-برچسب با استفاده از روش انتخاب ویژگی، نیاز به تکنیک‌هایی است که قادر به پیدا کردن ویژگی‌های متمایز بین چند برچسب مشترک باشند. در سال‌های اخیر، دو مفهوم مهم و کلیدی تحت عناوین «تنظیم تنکی»^۱ و کمینه کردن «نرخ افزونگی»^۲ نقشی اساسی را در روش‌های انتخاب ویژگی تک-برچسب و چند-برچسب ایفا کرده‌اند [۸،۹]. برای مثال، لین^۳ و همکاران [۱۰] یک روش انتخاب ویژگی چند-برچسب مبتنی بر دو مفهوم کمینه افزونگی و بیشینه ارتباط معرفی کردند. در این روش، مقیاسی جهت محاسبه اهمیت هریک از ویژگی‌ها با استفاده از کشف قابلیت آن‌ها در بهبود عملکرد یادگیری چند-برچسب معرفی شد. تنظیم تنکی به این منظور استفاده می‌گردد تا در مسئله طراحی شده برای انتخاب ویژگی، بتوان نقش ویژگی‌های مؤثر را برجسته‌تر کرد. از طرف دیگر، کمینه کردن نرخ افزونگی از این جهت حائز اهمیت است که کمک می‌کند تا افزونگی بین ویژگی‌های انتخاب شده به میزان کافی کاهش یابد [۷]. علاوه بر این موارد، برخی از مفاهیم مانند اطلاعات مشترک^۴ و آنتروپی شانون^۵ در سال‌های اخیر توجه بسیاری از پژوهشگران را در یادگیری چند-برچسب به خود جلب کرده‌اند. در مسائل انتخاب ویژگی، آنتروپی شانون یک روش اندازه‌گیری متغیرهای تصادفی با عدم قطعیت است و به طور گسترده‌ای در بخش انتخاب ویژگی چند-برچسب، یادگیری قانون^۶ و همچنین کشف دانش‌های مختلف مورد استفاده قرار گرفته است [۱۱]. در ارتباط با مفهوم اطلاعات مشترک، لی و کیم^۷ [۱۲]، یک روش با استفاده از اطلاعات مشترک چندمتغیره برای طبقه‌بندی انتخاب ویژگی چند-برچسب پیشنهاد و ارائه کردند. در این روش، زیرمجموعه‌ای شامل ویژگی‌های مؤثر به وسیله بیشینه کردن وابستگی بین ویژگی‌های منتخب و برچسب‌ها، انتخاب می‌گردد. لی و کیم^۸ [۱۳]، همچنین یک الگوریتم با استفاده از اطلاعات تعاملی برای انتخاب ویژگی چند-برچسب مبتنی بر اطلاعات مشترک معرفی کردند. در ادامه، همان نویسندگان یک روش بهتر برای انتخاب ویژگی چند-برچسب ارائه

⁵ Shannons entropy

⁶ rule learning

⁷ Lee and Kim

⁸ Lee and Kim

¹ sparsity regularization

² redundancy rate

³ Lin

⁴ mutual information

باین‌حال، تحقیقات جزئی درباره بررسی تأثیر افزونگی بین ویژگی‌ها گزارش شده است. در یادگیری چند-برچسبه، افزونگی نه تنها شامل اطلاعات مشترک بین ویژگی موردنظر و ویژگی‌های انتخاب شده است، بلکه باید اطلاعات مشترک بین ویژگی موردنظر و همه برچسب‌ها را در زمانی که ویژگی‌های منتخب داده می‌شوند نیز دربر بگیرد.

هدف از این مقاله، بررسی تأثیر کمینه کردن افزونگی بین ویژگی‌ها بر روند انتخاب ویژگی چند-برچسبه است. در این مقاله، در گام اول، با استفاده از مسئله کمینه‌سازی کمترین مربعات خطا، مسئله انتخاب ویژگی به صورت یک مسئله تجزیه ماتریسی همراه با جمله تنظیم تنکی و با استفاده از نرم فروبنیوس بیان می‌شود. در گام دوم، با پیدا کردن رابطه بین ویژگی‌ها بر اساس نرخ افزونگی، سعی در کمینه کردن نرخ افزونگی و باهدف یافتن ویژگی‌های بااهمیت بیشتر می‌شود. سپس، یک تابع هدف برای مسئله بهینه‌سازی موردنظر طراحی شده، و یک الگوریتم بروز رسانی تکراری نیز برای حل تابع هدف متناظر با مسئله انتخاب ویژگی مطرح شده، مورد بررسی قرار خواهد گرفت. در انتها، نتایج به دست آمده از این روش با چند روش انتخاب ویژگی چند-برچسبه مشهور مقایسه شده و کارایی روش پیشنهادی نسبت به روش‌های متداول پیشین بررسی می‌گردد.

ساختار این مقاله به شرح زیر است. در بخش دوم، نمادهای مورد نیاز این مقاله آورده شده است. در بخش ۳، به تعریف مفهوم

$$F_1 = \{[1\ 0\ 0], [0\ 1\ 0], [1\ 1\ 0]\}$$

$$F^2 = \{[1\ 0\ 0], [0\ 1\ 0], [0\ 0\ 1]\}$$

در مجموعه F_1 بردار $[1\ 1\ 0]$ می‌تواند یک بردار زائد تلقی شود، به این مفهوم که این بردار نسبت به دو بردار دیگر این مجموعه وابسته خطی است. از طرف دیگر، مجموعه F_2 ، یک مجموعه نرخ افزونگی با ذکر مثال، تعریف و قضیه پرداخته شده است. در بخش ۴، مدل‌سازی مسئله انتخاب ویژگی چند-برچسبه و در بخش ۵، الگوریتم بهینه‌سازی متناظر و حل آن آورده شده است. همچنین در بخش ۶ نتایج عددی و تجزیه تحلیل نتایج حاصل شده، ذکر شده

کردند که در آن با بکاربردن یک رویه دارای مزیت، زیرمجموعه‌های ویژگی را در خلال جستجوی ژنتیک دوباره تعریف می‌نماید [۱۴]. داکوئر و ورلیسن^۱ یک الگوریتم انتخاب ویژگی بر پایه اطلاعات مشترک برای مسائل انتخاب ویژگی چند-برچسبه با استفاده از PPT برای تغییر شکل مسئله و سپس استراتژی جستجوی حریمانه^۲ مبتنی بر اطلاعات مشترک هدایت شده به منظور انتخاب ویژگی‌های دارای ارتباط هرچه بیشتر، طراحی کردند [۱۵]. در سالیان گذشته، روش‌های انتخاب ویژگی چند-برچسبه موثری معرفی شده‌اند. برای مثال، جیان^۳ و همکاران [۱۶] یک قالب انتخاب ویژگی آگاهانه چند-برچسبه جدید پیشنهاد کردند که در آن برچسبی را استخراج کند تا از میان چندین برچسب، ویژگی‌های متمایزکننده را برگزیند. آن‌ها اطلاعات مربوط به فضای چند-برچسبه را به یک فضای کم بعد تجزیه کرده و سپس این فضای کم بعد به خدمت گرفته شده را در اختیار یک الگوریتم انتخاب ویژگی گذاشتند. کای و ژو^۴ [۹] یک روش جدید برای انتخاب ویژگی چند-برچسبه با استفاده از مدل «رگرسیون کمترین مربعات»^۵ و تلفیقی از «یادگیری منیفولد ویژگی»^۶ و «تنظیم تنکی» را مورد مطالعه قرار دادند. در این راستا، از مفهوم گراف تنظیم برای پیدا کردن ساختار هندسی ویژگی‌ها به منظور رسیدن به یک ماتریس ضریب رگرسیون بهتر استفاده شده است تا اهمیت هر کدام از ویژگی‌های مختلف منعکس شود. هوانگ^۷ و همکاران [۱۷] یک روش انتخاب ویژگی جدید تحت عنوان امتیاز لاپلاسیان مقید مبتنی بر منیفولد ارائه کردند. در این روش، از یادگیری منیفولد برای تبدیل فضای برچسب اصلی به فضای برچسب اقلیدسی و تشابه بین نمونه‌هایی که محدود به تناظر عددی برچسب‌ها شده‌اند، استفاده شده است. هو^۸ و همکاران [۱۸] یک روش بر پایه منظم‌سازی گراف دوگانه، یعنی تنظیم گراف ویژگی و تنظیم گراف برچسب طراحی کردند. منظم‌سازی گراف ویژگی، در حفظ همبستگی ساختار هندسی ویژگی‌ها و منظم‌سازی گراف برچسب، برای کشف همبستگی بین برچسب‌ها مورد استفاده قرار گرفته است.

⁵ least square regression model

⁶ feature manifold learning

⁷ Huang

⁸ Hu

¹ Doquire and Verleysen

² greedy search

³ Jian

⁴ Cai and Zhu

که $I = \{I_1, \dots, I_k\}$ و $\rho(f_i, f_j)$ ضریب همبستگی پیرسون بین دو ویژگی f_i و f_j است و عبارت است از:

$$\rho(f_i, f_j) = \frac{cov(f_i, f_j)}{\sqrt{D(f_i)D(f_j)}} \quad (2)$$

که در آن $cov(f_i, f_j)$ کواریانس ویژگی‌های f_i و f_j است و به صورت زیر تعریف می‌شود:

$$cov(f_i, f_j) = \langle f_i, f_j \rangle = f_i^T f_j \quad (3)$$

به علاوه، $D(f_i)$ و $D(f_j)$ به ترتیب انحراف معیار^۱ مربوط به f_i و f_j می‌باشند.

اگر داده‌ها نرمال‌سازی شوند و فرض شود که همه ویژگی‌ها دارای توزیع نرمال هستند، آنگاه ضریب همبستگی پیرسون به صورت زیر ساده می‌شود:

$$\rho(f_i, f_j) = cov(f_i, f_j) \quad (4)$$

مثال ۳-۳. فرض کنید که مجموعه داده عبارت است از:

$$X = \{[1 \ 0 \ 0], [0 \ 1 \ 0], [1 \ 1 \ 0], [0 \ 0 \ 1]\}$$

در این مثال، هدف محاسبه نرخ افزونگی دو مجموعه ویژگی F_1 و F_2 است که در مثال ۳-۱ معرفی شدند. برای این منظور، داریم:

$$RED(I_1) = 0.89, RED(I_2) = 0.33$$

که $I_2 = \{1, 2, 4\}$ و $I_1 = \{1, 2, 3\}$. بنابراین، میزان افزونگی مجموعه ویژگی F_2 از میزان افزونگی مجموعه F_1 کمتر است. در ادامه، یک فرم ماتریسی برای نرخ افزونگی برای یک مجموعه از ویژگی‌ها بیان می‌شود.

قضیه ۳-۴. فرض کنید که ماتریس داده عبارت است از

$$X = [f_1, f_2, \dots, f_d] \in \mathbb{R}^{n \times d}$$

همچنین، فرض کنید F_I یک مجموعه از ویژگی‌ها باشد که $|I| = k$ در این صورت یک ماتریس $W \in \mathbb{R}^{d \times k}$ وجود دارد که

$$RED(I) = \frac{1}{k^2} Tr(W^T X^T X W) \quad (5)$$

که 1 ماتریسی $k \times k$ است که تمام درایه‌های آن 1 است.

اثبات: فرض کنید $F_I = \{F_{I_1}, F_{I_2}, \dots, F_{I_k}\}$ یک زیرمجموعه از ویژگی‌ها باشد. از آنجا که

$$F_I \subseteq span\{f_1, f_2, \dots, f_d\}$$

بنابراین، یک ماتریس $W \in \mathbb{R}^{d \times k}$ وجود دارد به طوری که

است. در نهایت، در بخش ۷ نتیجه حاصل از این مقاله را خواهیم داشت.

۲- نمادهای موردنیاز

در ابتدا نمادهای مورد استفاده در مقاله ذکر خواهد شد. در سراسر این مقاله، فرض می‌شود که مجموعه داده‌های چند-برچسبه، شامل n نمونه x_1, x_2, \dots, x_n است. به عبارت دیگر، ماتریس نمونه‌ها عبارت است از:

$$X = [x_1; x_2; \dots; x_n] \in \mathbb{R}^{n \times d}$$

همچنین، ماتریس برچسب‌ها به صورت زیر نمایش داده می‌شود:

$$Y = [y_1; y_2; \dots; y_n] \in \{0, 1\}^{n \times l}$$

که هر

$$y_i = [y_i^1, y_i^2, \dots, y_i^l] \in \{0, 1\}^l$$

$$i = 1, \dots, n.$$

بردار برچسب‌های متناظر با نمونه x_i است. همچنین، 1_k ماتریسی $k \times k$ است که تمام درایه‌های آن 1 است.

۳- نرخ افزونگی

نرخ افزونگی یک مجموعه از ویژگی‌ها یکی از مفاهیم اساسی در بحث انتخاب ویژگی محسوب می‌شود که در حقیقت بیانگر میزان تشابه بین ویژگی‌ها است. برای توضیح بیشتر ابتدا با یک مثال شروع می‌کنیم.

مثال ۳-۱. دو مجموعه زیر را در نظر بگیرید:

مستقل خطی است و اعضای آن برخلاف مجموعه F_1 از «تشابه

کمتری» نسبت به یکدیگر برخوردار هستند. بنابراین، مجموعه F_2

در مقایسه با مجموعه F_1 از افزونگی کمتری برخوردار است.

یکی از راه‌های تعریف نرخ افزونگی، استفاده از مفهوم آماری «ضریب همبستگی پیرسون» است که در ادامه به آن می‌پردازیم.

تعریف ۳-۲. فرض کنید

$$F_I = \{F_{I_1}, F_{I_2}, \dots, F_{I_k}\}$$

یک زیرمجموعه از ویژگی‌ها باشد. نرخ افزونگی F_I به صورت زیر تعریف می‌شود:

$$RED(I) = \frac{1}{k^2} \sum_{i, j \in I} \rho(f_i, f_j) \quad (1)$$

¹ Standard Deviation

صفر باشند. در نتیجه، این نیاز احساس می‌شود که ماتریس وزن W دارای خاصیت تنک بودن باشد. به همین دلیل، بحث تنک‌سازی ماتریس W در مدل انتخاب ویژگی از اهمیت زیادی برخوردار است و به صورت کمینه کردن یک نرم مناسب از W انجام می‌گیرد. در بسیاری از روش‌های موجود، از نرم $l_{2,1}$ به منظور تنک‌سازی ماتریس وزن W استفاده شد. به علاوه اینکه اگر $D \in \mathbb{R}^{d \times d}$ یک ماتریس قطری باشد که i امین درایه روی قطر اصلی آن به صورت زیر باشد:

$$D_{ii} = \frac{1}{2\|w_i\|_2}$$

در این صورت:

$$\|W\|_{2,1} = Tr(W^T D W) \quad (8)$$

نکته قابل توجه این است که ممکن است حالتی رخ دهد که در آن برخی از درایه‌های قطری ماتریس D صفر گردند و یا اینکه حتی اعدادی کوچک باشند. در این حالت، در عمل به منظور جلوگیری از خطاهای عددی، مقایسه با یک مقدار اختلال کوچک به میزان ϵ در درایه‌های قطری ماتریس D به صورت زیر اعمال می‌شود:

$$D_{ii} = \frac{1}{2 \times \max(\|w_i\|_2, \epsilon)}$$

بنابراین، همان‌طور که به‌وضوح دیده می‌شود، پارامتر ϵ می‌تواند نقشی اساسی در ساختار $\|W\|_{2,1}$ ایفا کند. از طرف دیگر، بیاید نرم فروبنیوس ماتریس W را در نظر بگیریم، یعنی $\|W\|_F$ از یک طرف داریم:

$$\|W\|_F \leq \|W\|_{2,1}$$

و از طرف دیگر، برتری بزرگی که $\|W\|_F$ به $\|W\|_{2,1}$ دارد این است که ساختار $\|W\|_F$ به هیچ پارامتری وابسته نیست. همین موضوع، انگیزه‌ای برای ما است و تنک‌سازی ماتریس وزن W در بحث انتخاب ویژگی را به صورت کمینه کردن تابع هدف $\|W\|_F$ در نظر بگیریم، یعنی،

$$\min_{W \in \mathbb{R}^{d \times l}} \|W\|_F \quad (9)$$

اکنون، با توجه به عبارات (۷)، (۸) و (۹)، مسئله انتخاب ویژگی چند-برچسبه بر اساس مسئله رگرسیون کمترین مربعات و با استفاده از مفاهیم کمینه کردن نرخ افزونگی و تنک‌سازی ماتریس وزن W با استفاده از نرم فروبنیوس، به صورت مساله بهینه‌سازی زیر بیان می‌شود:

$$XW = \{f_{I_1}, f_{I_2}, \dots, f_{I_k}\}$$

در نتیجه، خواهیم داشت:

$$\frac{1}{k^2} Tr(W^T X^T X W 1) = \sum_{i,j \in I} \langle f_i, f_j \rangle$$

که اثبات قضیه را کامل می‌سازد.

۴- مدل‌سازی مسئله انتخاب ویژگی چند-

برچسبه

در این بخش، به منظور ارائه یک روش انتخاب ویژگی چند-برچسبه، مدلی پیشنهاد می‌شود که از سه مفهوم زیر در ساختار آن استفاده شده است

(۱) مسئله رگرسیون کمترین مربعات. هدف از یک مسئله رگرسیون کمترین مربعات، کمینه‌سازی تابع هدف زیر است:

$$\min_{W \in \mathbb{R}^{d \times l}} \|XW - Y\|_F^2 \quad (6)$$

که در آن $W \in \mathbb{R}^{d \times l}$ ماتریس ضریب (یا ماتریس وزن) رگرسیون است.

(۲) کمینه کردن نرخ افزونگی

منظور از مفهوم «کمینه کردن افزونگی» در فرآیند انتخاب ویژگی، دستیابی به یک زیرمجموعه از ویژگی‌ها است که کمترین وابستگی ممکن بین ویژگی‌های آن وجود داشته باشد. به عبارت دیگر، هرچه قدر مقدار نرخ افزونگی کمتر باشد، آنگاه انتظار داریم مجموعه ویژگی‌های منتخب دارای وابستگی کمتری نسبت به یکدیگر باشند. بنابراین، با توجه فرم ماتریسی نرخ افزونگی، که در رابطه (۵) بیان شد، هدف از کمینه کردن نرخ افزونگی در بحث انتخاب ویژگی عبارت است از:

$$\min_{W \in \mathbb{R}^{d \times l}} Tr(W^T X^T X W 1) \quad (7)$$

(۳) تنک‌سازی ماتریس وزن W .

مقدار $\|w_i\|_2$ نشان‌دهنده اهمیت ویژگی i ام است و هرچه مقدار $\|w_i\|_2$ بزرگ‌تر باشد، ویژگی i ام از اهمیت بیشتری نسبت به سایر ویژگی‌ها برخوردار است. بنابراین، در بحث انتخاب ویژگی، انتظار می‌رود که فقط تعداد کمی از $\|w_i\|_2$ های محاسبه‌شده غیر

ورودی: ماتریس داده، $X \in \mathbb{R}^{n \times d}$ ماتریس برچسب $Y \in \mathbb{R}^{n \times d}$:

پارامترهای α و β و تعداد ویژگی‌ها با تعداد k .

خروجی: زیرمجموعه I منتخب از ویژگی‌های با تعداد k .

$t=0$:1

2: مقداردهی اولیه برای $W \in \mathbb{R}^{n \times d}$ به صورت تصادفی.

3: تکرار مراحل ۴ و ۵ تا زمان برقراری معیار همگرایی.

4: محاسبه $\|W^{t+1}\|$ با استفاده از رابطه تکراری زیر:

$$(X^T X + \alpha I)W^{t+1} = X^T Y - \beta X^T X W^t 1_k$$

$t=t+1$: ۵

۶: مرتب‌سازی مقادیر $\|W_i^t\|$ که $i \in \{1, \dots, d\}$. به صورت

نزولی و انتخاب مجموعه I به عنوان k عضو اول.

۶- نتایج عددی

به منظور بررسی کیفیت روش FSRS عملکرد آن با برخی از روش‌های مشهور با استفاده از چهار مجموعه داده مشهور چند-برچسبه و در دسترس مقایسه خواهد شد. همچنین معیارهای ارزیابی، روش‌های استفاده شده برای مقایسه و نتایج حاصل به شرح زیر می‌باشند.

۶-۱ مجموعه داده‌ها

به منظور انجام آزمایش‌های عددی، چهار مجموعه داده رایانه^۳، مرجع^۴، چشم‌انداز^۳ و مخمر^۴ که دارای کاربردهای متفاوت هستند، بررسی خواهند شد. داده‌های رایانه و مرجع به طور گسترده‌ای برای دسته‌بندی اتوماتیک صفحات وب بکار برده می‌شوند. داده چشم‌انداز، برای حل مسئله «به وجود آمدن تقاضا» در دسته‌بندی تصاویر معنایی، ایجاد شده است. داده بیولوژیکی مخمر متعلق به مجموعه داده‌های میکرو-آرایه است که در آن هر ژن با استفاده از داده‌های بیان ریزآرایه الحاقی و پروفایل فیلوژنتیک توصیف شده است. لازم به ذکر است مجموعه داده‌های انتخاب شده فوق از

$$\min_{W \in \mathbb{R}^{d \times l}} \frac{1}{2} \|W^T X - Y\|_F^2 + \frac{\alpha}{2} \|W\|_F^2 + \frac{\beta}{2} \text{Tr}(W^T X^T X W 1)$$

که در آن، α پارامتر منظم‌ساز متناظر با تنک‌سازی ماتریس وزن W و β پارامتر منظم‌ساز متناظر با نرخ افزونگی است.

۵- الگوریتم بهینه‌سازی و حل آن

به منظور حل مسئله کمینه‌سازی (۵) تابع $f(W)$ به صورت زیر تعریف می‌شود:

$$f(W) = \frac{1}{2} \|XW - Y\|_F^2 + \frac{\alpha}{2} \|W\|_F^2 + \frac{\beta}{2} \text{Tr}(W^T X^T X W 1_k)$$

که مقدار^۱ قبل از عبارات تابع هدف به منظور ساده شدن با ضریب ۲ ایجاد شده پس از مشتق‌گیری در نظر گرفته شده است. با مشتق گرفتن از عبارت (۱۱) نسبت به W و مساوی صفر قرار دادن آن خواهیم داشت:

$$\frac{\partial f}{\partial W} = X^T X W - X^T Y + \alpha W + \beta X^T X W 1_k = 0$$

با استفاده از رابطه فوق، مقدار W به صورت زیر به دست خواهد آمد:

$$(X^T X + \alpha)W = X^T Y - \beta X^T X W 1_k$$

که در آن با استفاده از ماتریس W در مرحله t ام، ماتریس W در مرحله $t+1$ ام محاسبه خواهد شد. لذا بر اساس عبارت (۱۲) رابطه تکراری زیر را خواهیم داشت:

$$(X^T X + \alpha I)W^{t+1} = X^T Y - \beta X^T X W^t 1_k$$

در ادامه، با توجه به روابط به دست آمده، الگوریتم انتخاب ویژگی چند-برچسبه بر اساس مسئله رگرسیون کمترین مربعات، کمینه کردن نرخ افزونگی و تنک‌سازی تنک به صورت الگوریتم (۱) ارائه می‌شود.

الگوریتم ۱: انتخاب ویژگی چند-برچسبه بر اساس مسئله رگرسیون کمترین مربعات، کمینه کردن نرخ افزونگی و تنک‌سازی (FSRS).

³ Scene
⁴ Yeast

¹ Computer
² Reference

۲-۲-۶ پوشش

ارزیابی تعداد گام‌هایی که به‌طور متوسط نیاز است تا لیست برچسب‌ها در برگرفته شوند تا همه برچسب‌های واقعی در نمونه را پوشش دهند.

$$CV(\tau) = \frac{1}{p} \sum_{i=1}^p \max_{y \in Y_i} \text{rank}(x_i, y) - 1$$

که مقدار $CV(\tau)$ ، هرچه قدر کوچک‌تر باشد، کارایی بهتر خواهد بود.

۳-۲-۶ افت همینگ

مقدار جفت برچسب‌های نامناسب طبقه‌بندی‌شده را محاسبه می‌کند. به‌عبارت‌دیگر، یک برچسب یا متعلق به نمونه‌های پیش‌بینی‌نشده است یا برچسبی است که متعلق به نمونه پیش‌بینی‌شده، نیست.

$$HL(\tau) = \frac{1}{p} \sum_{i=1}^p \frac{1}{q} |h(x_i) \Delta y_i|$$

که در آن Δ نشان‌دهنده تفاضل مقارن بین دو مجموعه است. اینجا، مقدار $HL(\tau)$ هرچه قدر کوچک‌تر باشد، کارایی بهتر خواهد بود.

۴-۲-۶ یک - خطا

ارزیابی چندین‌باره برای بالاترین برچسبی که در مجموعه برچسب‌های مربوط به نمونه نیست.

$$OE(\tau) = \frac{1}{p} \sum_{i=1}^p \left\{ \left[\arg \max_{y \in Y} f(x_i, y) \right] \notin y_i \right\}$$

که مقدار OE هرچه قدر کوچک‌تر باشد، کارایی بهتر خواهد بود.

۵-۲-۶ افت رتبه

میانگین جفت برچسب‌هایی که برچسب نامناسب را بالاتر از برچسب مربوطه ارزیابی می‌کنند.

کتابخانه مولان^۱ قابل دریافت هستند و اطلاعات آن‌ها در جدول زیر جمع‌آوری شده است.

جدول (۱): مجموعه داده‌های استفاده‌شده

مجموعه داده	تعداد نمونه	تعداد ویژگی	تعداد برچسب
مرجع (Reference)	۵۰۰۰	۷۹۳	۳۳
رایانه (Computer)	۵۰۰۰	۶۸۱	۳۳
چشم‌انداز (Scene)	۲۴۰۷	۲۹۴	۶
خمیر (Yeast)	۲۴۱۷	۱۰۳	۱۴

۲-۶ معیارهای ارزیابی

ارزیابی عملکرد سیستم‌های چند-برچسب‌یادگیری، متفاوت از سیستم‌های تک-برچسب هستند. سیستم‌های یادگیری چند-برچسب نیازمند معیارهای ارزیابی پیچیده‌تری هستند. فرض کنید یک مجموعه داده آزمون به‌صورت زیر باشد:

$$\tau = \{(x_i, y_i) | 1 \leq i \leq p\}$$

که در آن p تعداد نمونه‌های آزمون است. با توجه به نمونه x_i بردار برچسب باینری که توسط طبقه‌بندی چند-برچسب پیش‌بینی شده است به‌عنوان مشخص $h(x_i)$ می‌شود، درحالی‌که رتبه پیش‌بینی شده برای k امین برچسب به‌عنوان $\text{rank}(x_i, k)$ تعریف شده است. معیارهای ارزیابی چندمنظوره به‌صورت زیر استفاده می‌شود:

۱-۲-۶ متوسط دقت

میانگین کسری از رتبه برچسب‌های بالاتر از یک برچسب خاص را در مجموعه برچسب‌های اساسی ارزیابی می‌کند.

$$AP(\tau) = \frac{1}{p} \sum_{i=1}^p \frac{1}{|y_i|} \sum_{y \in y_i} \left\{ \frac{\text{rank}(x_i, y')}{\text{rank}(x_i, y)} \mid \text{rank}(x_i, y') \leq \text{rank}(x_i, y), y' \in y_i \right\}$$

که مقدار $AP(\tau)$ هرچه قدر بیشتر باشد، کارایی بهتر خواهد بود.

¹ Mulan Library: <http://mulan.sourceforge.net/datasets-mlc.html>.

۵-۶ نتایج تجربی

در این بخش، روش انتخاب ویژگی چند-برجسه پیشنهادی FRSR، بر روی چهار مجموعه داده وسیع و در دسترس، با آزمون‌های گسترده مورد آزمایش قرار گرفته می‌شود، و نتایج حاصل با چندین الگوریتم انتخاب ویژگی کارا، که در بخش ۶-۴ معرفی شدند، مقایسه و عملکرد روش پیشنهادی از نظر طبقه‌بندی مورد بررسی قرار خواهد گرفت. برای این منظور، کارایی روش‌های انتخاب ویژگی چند-برجسه با در نظر گرفتن معیارهای «متوسط دقت»، «پوشش»، «افت همینگ»، «یک-خطا» و «افت رتبه» ارزیابی می‌شوند و نتایج این بررسی‌ها در جدول‌های زیر به صورت کامل آورده شده است. در این جدول‌ها، در هر ردیف، بهترین نتیجه به صورت بولد و دومین بهترین نتیجه به صورت آندرلاین نشان داده می‌شوند.

جدول (۲): کارایی الگوریتم‌های مختلف برای معیار «متوسط دقت»

روش \ داده	FSRS	MDMR	PMU	FIMF
رایانه	<u>۰/۶۳۴۵</u>	<u>۰/۶۳۰۵</u>	۰/۶۰۹۲	۰/۶۲۰۳
مرجع	<u>۰/۷۲۳۹</u>	<u>۰/۷۲۵۷</u>	۰/۶۵۹۴	۰/۷۰۸۹
چشم‌انداز	<u>۰/۸۳۷۴</u>	<u>۰/۷۶۳۳</u>	<u>۰/۸۰۳۴</u>	۰/۶۹۰۶
مخمر	<u>۰/۷۵۹۰</u>	<u>۰/۷۵۸۰</u>	۰/۷۵۶۳	۰/۷۵۵۲

جدول (۳): کارایی الگوریتم‌های مختلف برای معیار «پوشش»

روش \ داده	FSRS	MDMR	PMU	FIMF
رایانه	<u>۴/۳۸۱۳</u>	<u>۴/۳۴۸۰</u>	۴/۶۵۲۳	۴/۵۵۸۰
مرجع	<u>۳/۰۹۱۳</u>	<u>۳/۱۶۴۷</u>	۳/۵۶۸۷	۳/۱۷۳
چشم‌انداز	<u>۰/۵۳۲۶</u>	<u>۰/۸۲۵۳</u>	<u>۰/۷۴۹۲</u>	۱/۰۹۵۳
مخمر	<u>۶/۲۹۶۶</u>	<u>۶/۳۶۴۲</u>	۶/۳۷۰۸	۶/۳۷۴۰

$$RL(\tau) = \frac{1}{p} \sum_{i=1}^p \frac{1}{|y_i| |\bar{y}_i|} \left\| \left\{ \left(y', y'' \right) \middle| f \left(x_i, y' \right) \leq f \left(x_i, y'' \right), \left(y', y'' \right) \in y_i \times \bar{y}_i \right\} \right\|$$

که \bar{y}_i نشان‌دهنده متمم y_i است. همچنین، مقدار $RL(\tau)$ هر چه قدر کوچک‌تر باشد، کارایی بهتر خواهد بود.

۳-۶ تنظیم پارامترها

تعدادی پارامتر در روش پیشنهادی FRSR وجود دارند که نیاز است این پارامترها تنظیم شوند. برای مثال، مقادیر پارامترهای α و β ، به ترتیب، در مجموعه $\{10^1, \dots, 10^6\}$ و $\{10^{-1}, \dots, 10^{-6}\}$ جستجو می‌شوند. در تمام روش‌ها، تعداد ویژگی‌های انتخاب شده k در مجموعه $\{10, 20, \dots, 100\}$ جستجو می‌شود. برای روش FRSR، بیشینه تعداد تکرار برابر با ۳۰ در نظر گرفته می‌شود. همچنین، روش k -fold به ازاء $k=5$ ، برای تنظیم کردن پارامترها در نظر گرفته شده است. به این معنی که داده را به ۵ قسمت تقسیم کرده و هر بار یک پنجم داده به عنوان داده تست و مابقی به عنوان داده آموزش در نظر گرفته شده است.

۴-۶ آزمون‌های مقایسه

به منظور بررسی کیفیت روش پیشنهادی FRSR، عملکرد این روش با چند روش انتخاب ویژگی مؤثر چند-برجسه مقایسه می‌شود. این روش‌ها عبارت هستند از:

روش PMU [۱۲]: یک روش انتخاب ویژگی چند-برجسه مبتنی بر استفاده از اطلاعات مشترک و به حداکثر رساندن وابستگی بین ویژگی‌ها و برجسب‌ها.

روش MDMR [۱۰]: یک روش انتخاب ویژگی مبتنی بر ترکیب کردن «حداکثر وابستگی» و «کمترین افزونگی».

روش FIMF [۱۹]: یک روش انتخاب ویژگی چند-برجسه سریع بر اساس رتبه‌بندی ویژگی‌های علمی اطلاعات.

¹ Tune

(۲) در ارتباط با داده «مرجع» که روش پیشنهادی FSRS در رتبه بهترین دوم برحسب معیارهای ارزیابی «افت همینگ» و «یک-خطا» قرار دارد، روش پیشنهادی قادر است در تمام معیارهای ارزیابی دیگر نسبت به سایر روش‌ها بهتر عمل کند.

(۳) در ارتباط با داده «رایانه» که روش پیشنهادی FSRS در رتبه بهترین دوم برحسب معیارهای ارزیابی «پوشش» و «افت همینگ» قرار دارد، روش پیشنهادی قادر است در تمام معیارهای ارزیابی دیگر نسبت به سایر روش‌ها بهتر عمل کند.

۶-۶ آزمون‌های آماری غیر پارامتری

در این بخش، به منظور دستیابی به یک توجیه منصفانه آماری در بررسی تفاوت‌ها و برتری روش پیشنهادی در مقایسه با دیگر روش‌های اشاره شده، از یک آزمون آماری مانند آزمون فریدمن، استفاده می‌شود. آزمون فریدمن یک آزمون آماری ناپارامتری است که از آن برای مقایسه میانگین رتبه‌ها در بین k متغیر (گروه) استفاده می‌شود. برای این منظور، یک آزمون فرض به صورت مقدار احتمال (p -مقدار) برابر با کمترین مقدار از سطح معنی‌دار، که موجب رد فرض صفر خواهد شد، در نظر گرفته می‌شود. جدول ۷ نتایج حاصل از آزمون فریدمن را برای هر روش و برحسب هر یک از معیارهای ارزیابی نشان می‌دهد. در اینجا، هرچه رتبه روش پایین‌تر باشد، آنگاه کارایی آن روش بهتر است. مطابق جدول ۷، مشاهده می‌شود که روش FSRS پایین‌ترین رتبه را برحسب هر یک از معیارهای ارزیابی دارد، و بنابراین می‌توان نتیجه گرفت که روش FSRS در مقایسه با سایر روش‌ها از کارایی بالاتری برخوردار است.

جدول (۷): میانگین رتبه روش‌ها حاصل از آزمون آماری فریدمن

و بر اساس معیارهای مختلف

(آ) میانگین دقت

رتبه	روش
۱/۲۵	FSRS
۲	MDMR
۳/۲۵	PMU

جدول (۴): کارایی الگوریتم‌های مختلف برای معیار «افت همینگ»

روش \ داده	FSRS	MDMR	PMU	FIMF
رایانه	۰/۰۳۹۹	۰/۰۳۹۸	۰/۰۴۱۶	۰/۰۴۰۹
مرج	۰/۰۳۹۵	۰/۰۳۹۱	۰/۰۴۵۷	۰/۰۴۰۷
چشم‌انداز	۰/۱۰۱۴	۰/۱۳۴۸	۰/۱۱۳۷	۰/۱۵۸۷
مخمر	۰/۱۹۵۹	۰/۱۹۹۹	۰/۲۰۰۶	۰/۲۰۲۱

جدول (۵): کارایی الگوریتم‌های مختلف برای معیار «یک-خطا»

روش \ داده	FSRS	MDMR	PMU	FIMF
رایانه	۰/۴۴۲۰	۰/۴۵۴۳	۰/۴۷۰۰	۰/۴۶۲۷
مرجع	۰/۳۴۷۷	۰/۳۳۷۳	۰/۳۷۳۰	۰/۳۷۳۰
چشم‌انداز	۰/۲۷۵۹	۰/۳۰۹۴	۰/۳۰۹۴	۰/۴۹۸۳
مخمر	۰/۲۲۳۶	۰/۲۳۶۶	۰/۲۳۷۲	۰/۲۳۷۶

جدول (۶): کارایی الگوریتم‌های مختلف برای معیار «افت رتبه».

روش \ داده	FSRS	MDMR	PMU	FIMF
رایانه	۰/۰۹۰۱	۰/۰۹۰۳	۰/۰۹۸۰	۰/۰۹۵۵
مرجع	۰/۰۵۵۴	۰/۰۵۶۶	۰/۰۶۷۹	۰/۰۵۷۹
چشم‌انداز	۰/۰۹۳۴	۰/۱۴۴۴	۰/۱۲۹۰	۰/۱۹۹۴
مخمر	۰/۱۶۹۲	۰/۱۷۱۰	۰/۱۷۲۳	۰/۱۷۴۷

با توجه به معیارهای ارزیابی، بیشتر شدن عدد حاصل در معیار «متوسط دقت»، و در مابقی معیارها کمتر شدن آن معیارها، بیانگر کارایی بهتر روش خواهد بود. با توجه به آنچه که در جدول‌های ۲ تا ۶ قابل مشاهده است، نتایج زیر حاصل می‌شوند:

(۱) در ارتباط با مجموعه داده‌های «چشم‌انداز» و «مخمر»، روش پیشنهادی FSRS قادر است در تمام معیارهای ارزیابی نسبت به سایر روش‌ها بهتر عمل کند.

به منظور تحقیق بیشتر راجع به کیفیت نتایج آماری، مقایسه اندازه p -مقدار حاصل از آزمون آماری فریدمن بین روش FSRS و سایر روش‌ها در جدول ۸ نمایش داده شده است. در اینجا، سطح معنی دار α به صورت $\alpha = 0/016667$ در نظر گرفته شده است. همچنین، توجه شود که آزمون آماری فریدمن، روش‌هایی با اندازه p -مقدار کوچک‌تر یا مساوی از $0/016667$ را رد می‌کند.

جدول (۸): مقایسه اندازه p -مقدار حاصل از آزمون آماری فریدمن بین روش FSRS و سایر روش‌ها.

(آ) میانگین دقت

رتبه	روش	p - مقدار
۳	FIMF	۰/۰۱۳۷۱۱
۲	PMU	۰/۰۲۸۴۶
۱	MDMR	۰/۴۱۱۳۱۴

(ب) پوشش

رتبه	روش	p - مقدار
۳	FIMF	۰/۰۱۳۷۱۱
۲	PMU	۰/۰۲۸۴۶
۱	MDMR	۰/۴۱۱۳۱۴

(ج) افت همینگ

رتبه	روش	p - مقدار
۳	FIMF	۰/۰۲۸۴۶
۲	PMU	۰/۰۵۵۲۳۴
۱	MDMR	۰/۷۸۴۱۹۱

(د) یک-خطا

رتبه	روش	p - مقدار
۳	FIMF	۰/۰۱۹۹۲۲
۲	PMU	۰/۰۲۸۴۶
۱	MDMR	۰/۳۳۷۸۰۳

رتبه	روش
۳/۵	FIMF

(ب) پوشش

رتبه	روش
۱/۲۵	FSRS
۲	MDMR
۳/۲۵	PMU
۳/۵	FIMF

(ج) افت همینگ

رتبه	روش
۱/۵	FSRS
۱/۷۵	MDMR
۳/۲۵	PMU
۳/۵	FIMF

(د) یک-خطا

رتبه	روش
۱/۲۵	FSRS
۲/۱۲۵	MDMR
۳/۲۵	PMU
۳/۳۷۵	FIMF

(ه) افت رتبه

رتبه	روش
۱	FSRS
۲/۲۵	MDMR
۳/۲۵	PMU
۳/۵	FIMF



- [3] Zhang, M.-L. & Zhou, Z.-H. (2006). Multi-Label Neural Networks with Applications to Functional Genomics and Text Categorization.. IEEE Trans. Knowl. Data Eng., 18, 1338-1351.
- [4] Xu, X., Shan, D., Li, S., Sun, T., Xiao, P., & Fan, J. (2019). Multi-label learning method based on ML-RBF and laplacian ELM. Neurocomputing, 331, 213-219.
- [5] N. Zhang, S. Ding, J. Zhang, Multi layer ELM-RBF for multi-label learning, Applied SoftComputing, 43, 535-545, 2016.
- [6] Wang, S., Pedrycz, W., Zhu, Q. & Zhu, W. (2015). Subspace learning for unsupervised feature selection via matrix factorization.. Pattern Recognit., 48, 10-19.
- [7] Wang, S., Pedrycz, W., Zhu, Q. & Zhu, W. (2015). Unsupervised feature selection via maximum projection and minimum redundancy.. Knowl. Based Syst., 75, 19-29.
- [8] Jian, L., Li, J., Shu, K., & Liu, H. (2016). Multi-label informed feature selection. IJCAI International Joint Conference on Artificial Intelligence, 2016-January, 1627-1633.
- [9] Huang, R., & Wu, Z. (2021). Multi-label feature selection via manifold regularization and dependence maximization. Pattern Recognition, 120, 108149. DOI:10.1016/j.patcog.2021.108149
- [10] Lin, Y., Hu, Q., Liu, J., & Duan, J. (2015). Multi-label feature selection based on max-dependency and min-redundancy. Neurocomputing, 168, 92-103. DOI:10.1016/j.neucom.2015.06.010
- [11] Shannon, C. E. (2001). A Mathematical Theory of Communication. SIGMOBILE Mob. Comput. Commun. Rev., 5(1), 3-55. DOI:10.1145/584091.584093
- [12] Lee, J., & Kim, D.-W. (2013). Feature selection for multi-label classification using multivariate mutual information. Pattern Recognition Letters, 34(3), 349-357. DOI:10.1016/j.patrec.2012.10.005
- [13] Lee, J., & Kim, D.-W. (2015). Mutual Information-based multi-label feature selection using interaction information. Expert Systems with Applications, 42(4), 2013-2025. DOI:10.1016/j.eswa.2014.09.063.
- [14] Lee, J., & Kim, D.-W. (2015). Memetic feature selection algorithm for multi-label classification. Information Sciences, 293, 80-96. DOI:10.1016/j.ins.2014.09.020
- [15] Doquire, G., & Verleysen, M. (2013). Mutual information-based feature selection for

(ه) افت رتبه

رتبه	روش	p - مقدار
۳	FIMF	۰/۰۰۶۱۷
۲	PMU	۰/۰۱۳۷۱۱
۱	MDMR	۰/۱۷۰۹۰۴

توجه شود که در این آزمایش، روش که اندازه p - مقدار آن کوچک‌تر یا مساوی مقدار $۰/۰۱۶۶۶۷$ باشد، رد می‌شود. با توجه به جدول ۸، می‌توان نتیجه گرفت که روش پیشنهادی FSRS روش FIMF را در معیارهای میانگین دقت، پوشش و افت رتبه به‌طور کامل رد می‌کند. همچنین، روش PMU فقط در معیار افت رتبه رد شده است؛ اما مقادیر p -مقدار در سایر روش‌ها نزدیک به مقدار α است که نشان‌دهنده این است که این روش فاصله زیادی تا رد شدن توسط روش پیشنهادی ما ندارد.

۷- نتیجه‌گیری

در این مقاله، یک روش انتخاب ویژگی چند-برچسبه مبتنی بر «رگرسیون کمترین مربعات»، «کمینه کردن افزونگی» و «تنظیم تنکی»، به نام روش FSRS معرفی شد، که در این روش با استفاده از مسئله کمینه‌سازی کمترین مربعات خطا، مسئله انتخاب ویژگی به صورت یک مسئله تجزیه ماتریسی همراه با جمله منظم‌سازی تنک و با استفاده از نرم فروینوس بیان می‌شود. برای این منظور، یک مسئله بهینه‌سازی برای روش FSRS طراحی و یک الگوریتم بروز رسانی تکراری نیز برای حل تابع هدف متناظر با مسئله انتخاب ویژگی مطرح شده، موردبررسی قرار گرفت. مجموعه‌ای از آزمایش‌های عددی جهت بررسی کارایی روش پیشنهادی FSRS و مقایسه عملکرد این روش با عملکرد چند روش انتخاب ویژگی چند-برچسبه کارآمد انجام گرفت. نتایج این آزمایش‌ها نشان دادند که روش پیشنهادی دارای عملکرد مطلوب و رضایت‌بخشی است.

References

- [1] McCallum, A. (1999). Multi-Label Text Classification with a Mixture Model Trained by EM. AAI'99 Workshop on Text Learning.
- [2] Boutell, M. R., Luo, J., Shen, X. & Brown, C. M. (2004). Learning Multi-Label Scene Classification. Pattern Recognition, 37, 1757--1771.

- multilabel classification. *Neurocomputing*, 122, 148–155. [DOI:10.1016/j.neucom.2013.06.035](https://doi.org/10.1016/j.neucom.2013.06.035)
- [16] Jian, L., Li, J., Shu, K., & Liu, H. (2016). Multi-Label Informed Feature Selection. *Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence*, 1627–1633. New York, New York, USA: AAAI Press.
- [17] Huang, R., Jiang, W., & Sun, G. (2018). Manifold-based constraint Laplacian score for multi-label feature selection. *Pattern Recognition Letters*, 112, 346–352. [DOI:10.1016/j.patrec.2018.08.021](https://doi.org/10.1016/j.patrec.2018.08.021)
- [18] Hu, J., Li, Y., Gao, W., & Zhang, P. (2020). Robust multi-label feature selection with dual-graph regularization. *Knowledge-Based Systems*, 203, 106126. [DOI:10.1016/j.knosys.2020.106126](https://doi.org/10.1016/j.knosys.2020.106126)
- [19] Lee, J., & Kim, D.-W. (2015). Fast multi-label feature selection based on information-theoretic feature ranking. *Pattern Recognition*, 48(9), 2761–2771. [DOI:10.1016/j.patcog.2015.04.009](https://doi.org/10.1016/j.patcog.2015.04.009)

Multi-label feature selection method based on redundancy minimization

Hakimeh Hasaniyeh¹, Behzad Ebrahimi², Farid Saberi-Movahed¹, Mahdi Eftekhari^{2*}

¹Department of Applied Mathematics, Faculty of Sciences and Modern Technologies, Graduate University of Advanced Technology, Kerman, Iran

²Department of Computer Engineering, Faculty of Engineering, Shahid Bahonar University of Kerman, Kerman, Iran

Article Information

Original Research Paper

Received:

2022 September 20

Accepted:

2023 June 13

Keywords:

Multi-label feature selection, Redundancy minimization, Regression, Least squared error, Sparsity regularization

Corresponding Author*:

m.eftekhari@uk.ac.ir

Abstract

Feature selection methods are known to be effective in improving the learning process. The purpose of a feature selection method is to identify relevant features and remove irrelevant features in order to obtain a suitable subset of features, so that the redundancy between the selected features is minimized. In multi-label data, if there is a correlation between features, it is possible that the amount of redundancy in the feature set is increased. The existence of redundancy between features along with the challenge of high dimensions of multi-label data can grow the computational calculations, decrease the accuracy and finally increase the probability of errors in the prediction and classification of multi-label data. In this article, with the aim of minimizing the redundancy of features, a multi-label feature selection algorithm is proposed considering the least squares regression model and sparse regularization. Finally, using a number of well-known multi-label data sets, the efficiency of the proposed method is verified and the results are compared with some common multi-label feature selection methods.



: 10.22034/ABMIR.2023.18967.1016

E-ISSN: [2821-2037](https://doi.org/10.22034/ABMIR.2023.18967.1016) /© 2023. Published by Yazd University This is an open access article under the CC BY 4.0 License (<https://creativecommons.org/licenses/by/4.0/>).

