

دیریت فاوری اطلاعات

دانشکده مدیریت دانشگاه تهران

دوره ۷، شماره ۲

تایستان ۱۳۹۴

ص. ۲۵۹ - ۲۸۲

تعیین خودکار حداقل دامنه پشتیبانی از قاعده در محیط فازی برای بهبود استخراج قواعد همباش با استفاده از الگوریتم اپریوری

حیدر جعفرزاده^۱، چمران عسگری^۲، امیر امیری^۳

چکیده: قواعد همباش (انجمنی) یکی از محبوب‌ترین مدل‌های حوزه داده‌کاوی به‌شمار می‌رود. در الگوریتم‌های کلاسیک حوزه قواعد همباش کاوی، مانند اپریوری، از حداقل دامنه پشتیبانی قاعدة واحد استفاده می‌شود؛ در حالی که در رویکردهای جدیدی که تلاش کرده‌اند الگوریتم‌های کلاسیک را بهبود بخشدند، مانند ام. اس. اپریوری، از حداقل دامنه پشتیبانی قاعدة چندگانه استفاده می‌شود که در هر دو حالت، کاربر موظف است حداقل دامنه پشتیبانی از قاعده را تعیین کند. در نظر بگیرید کاربر قصد اعمال الگوریتم اپریوری را بر پایگاه داده‌ای با میلیون‌ها تراکنش داشته باشد؛ به طور قطعی کاربر نمی‌تواند دانش لازم را درباره تمام تراکنش‌های موجود در پایگاه داده داشته باشد، بنابراین نمی‌تواند حد آستانه مناسبی را تعیین کند. در این پژوهش، برای اولین بار با استفاده از داده‌های فازی سازی شده و تکنیک میانگین‌گیری، روشی ارائه شده است که در آن، الگوریتم اپریوری به صورت کاملاً خودکار حداقل دامنه پشتیبانی از قاعده را تعیین می‌کند. نتایج شبیه‌سازی شده روی نمونه‌ای واقعی نشان داد این رویکرد عملکرد مطلوب‌تری نسبت به الگوریتم اپریوری کلاسیک دارد.

واژه‌های کلیدی: الگوریتم اپریوری، الگوهای پرتکرار، خوشه‌بندی فازی، دامنه پشتیبانی از قاعده، قواعد همباش.

۱. کارشناس ارشد مهندسی کامپیوتر، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات ایلام، ایلام، ایران

۲. کارشناس ارشد مهندسی کامپیوتر، گروه مهندسی کامپیوتر، دانشگاه پیام نور، ایران

۳. کارشناس ارشد مهندسی کامپیوتر، دانشگاه آزاد اسلامی ملایر، ملایر، ایران

تاریخ دریافت مقاله: ۱۳۹۳/۰۶/۲۸

تاریخ پذیرش نهایی مقاله: ۱۳۹۴/۰۳/۰۶

نویسنده مسئول مقاله: حیدر جعفرزاده

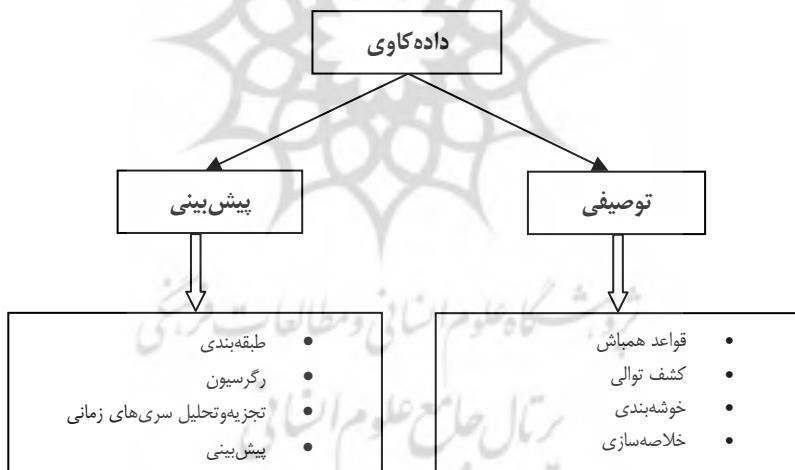
E-mail: heydar.jafarzadeh@gmail.com

مقدمه

داده‌کاوی فرایند منطقی‌ای است که برای جست‌وجوی داده‌ها از حجم زیادی از اطلاعات، به کار برد می‌شود (دونهام، ۲۰۰۲: ۵۰-۵۱). داده‌کاوی به فرایند شناخت الگوها و کشف روابط معنادار بین داده‌های انبوه اشاره دارد (عزیزی، حسین‌آبادی و بلاگی اینانلو، ۱۳۹۳). با توجه به اینکه همیشه می‌توان رابطه‌های جالبی بین داده‌ها پیدا کرد، ابزارهای خودکار و کارآمدی برای یافتن و نظمدهی به این رابطه‌ها لازم است. از این رو ابزارهای داده‌کاوی بسیاری با روش‌های تجزیه و تحلیل مختلف ارائه شده است.

داده‌کاوی به مدل‌های پیش‌بینی‌کننده و توصیفی تقسیم می‌شود (دونهام، ۲۰۰۲: ۷۳-۷۴) و همان‌طور که در شکل ۱ آمده است در حوزه‌های گوناگون به کار می‌رود.

- مدل پیش‌بینی؛ به‌منظور پیش‌بینی مقادیر آینده از نتایج به‌دست‌آمده از داده‌های مختلف، به کار می‌رود؛
- مدل توصیفی؛ به‌منظور ارائه الگوهای کشفشده به شکلی فهم‌پذیر برای انسان به کار می‌رود.



شکل ۱. وظایف داده‌کاوی

قواعد همباش^۱ یکی از وظایف بسیار مهم در حوزه داده‌کاوی است که می‌تواند در دامنه‌های مختلف استفاده شود. قواعد همباش کاوی، روش داده‌کاوی عمومی است و برای استخراج

1. Association Rules

الگوهای مفید از پایگاه داده‌های عظیم استفاده می‌شود (کاکر و آراس، ۲۰۱۲). قوانین انجمنی، یکی از روش‌های توصیفی و غیرنظری داده کاوی است که برای یافتن ارتباط بین ویژگی‌ها، در مجموعه داده‌ها به جستجو می‌پردازد. در واقع این روش به مطالعه ویژگی‌هایی می‌پردازد که همراه یکدیگرند، ضمن آنکه ارتباط بین این ویژگی‌ها را کمی می‌کند (آخوندزاده نوqابی، البدوی و اقدسی، ۱۳۹۳).

یکی از مشکلات الگوریتم اپریوری^۱ و سایر الگوریتم‌هایی که در حوزه استخراج قواعد همباش‌اند، اینکه کاربر مجبور است حداقل دستانه را برای دامنه پشتیبانی از قاعده^۲ مشخص کند. در نظر بگیرید کاربر می‌خواهد الگوریتم اپریوری را بر پایگاه داده‌ای با میلیون‌ها تراکنش اعمال کند؛ به طور قطعی کاربر نمی‌تواند دانش مد نظر برای تراکنش‌های موجود در پایگاه داده را داشته باشد و نمی‌تواند حداقل دامنه پشتیبانی از قاعده مناسبی تعیین کند.

هدف از این پژوهش بهبود الگوریتم اپریوری است. برای این کار ابتدا تراکنش‌هایی که در پایگاه داده به صورت قطعی ذخیره شده‌اند، به کمک یکی از الگوریتم‌های خوشبندی فازی، وارد محیط فازی (طفیزاده، ۱۹۶۵) خواهند شد و قبل از اعمال الگوریتم اپریوری، داده‌ها در محدوده‌های مختلفی قرار خواهند گرفت. در این فرایند تلاش شده است مناسب‌ترین حد آستانه به صورت خودکار به کمک یکی از روش‌های حوزه آمار، پس از تعیین، به کاربر پیشنهاد شود. امیدواریم این کار موجب شود هیچ قاعده جالبی به دلیل حد آستانه نامناسبی که کاربر مشخص کرده است، از دست نرود و هیچ قاعده‌بی استفاده‌ای استخراج نشود.

این مقاله ابتدا پیشینه استخراج قواعد همباش را معرف می‌کند و پس از آن روش پیشنهادی را معرفی می‌کند. برای درک بهتر مسئله، این رویکرد در قالب جدول‌ها و شکل‌های متعددی ارائه شده است. بخش پایانی مقاله به نتیجه‌گیری و پیشنهادها اختصاص دارد.

پیشینه پژوهش

همان‌طور که بسیاری از پایگاه داده‌ها انبوهی از نمونه‌ها و صفت‌ها را در برگرفته‌اند، باید ابزارهای کارآمدی پیاده‌سازی شود تا بتوان اطلاعات مفید پنهان شده در این پایگاه‌ها را استخراج کرد؛ بر این اساس ابزارهای داده کاوی بسیاری که از روش‌های تجزیه و تحلیل گوناگونی استفاده می‌کنند و به طور عمده برگرفته از آمار کلاسیک‌اند، توسعه داده شده است. در این بین، روش‌های قواعد همباش کاوی علاقه‌مندی‌های بسیاری را ایجاد کرده‌اند (لی و زنهو، ۲۰۰۷)؛ زیرا محققان

1. Apriori
2. Minsup

بسیاری موضوع پژوهش در این زمینه انتخاب کرده‌اند و الگوریتم‌های متنوعی را در این حوزه توسعه داده‌اند.

پیشنهاد نظری

استخراج قواعد همباش از پایگاه داده‌ها، اصول و مراحلی دارد و تمام محققانی که در این حوزه کار کرده‌اند با توجه به این اصول، تلاش در بهبود روش‌ها و الگوریتم‌ها داشته‌اند.

اصول قواعد همباش

همباش یعنی با همبودن دو یا چند قلم داده که مدام با هم تکرار می‌شوند و جلو می‌روند. کشف قواعد همباش یکی از وظایف بسیار مهم در حوزه داده‌کاوی است. قاعدة همباش ساده به این صورت بیان شود: Bread → Cheese [support = ۰/۱, confidence = ۰/۸]، به گفته ساده‌تر این قاعده بیان می‌کند رابطه‌ای بین خرید نان و پنیر وجود دارد، ماثور دامنه پشتیبانی از قاعده، بیان کننده ثبت نان و پنیر با هم در ۱۰ درصد تراکنش‌ها است و ماثور میزان اعتماد به قاعده بیان می‌کند پنیر در تراکنش‌های اتفاق افتاده است که نان هم در آن تراکنش‌ها وجود دارد. در این مورد ۸۰ درصد تراکنش‌ها شامل پنیر است که نان هم در همان تراکنش‌ها حضور دارد. به کمک این قاعده می‌توان فرض کرد، در آینده افرادی که نان خریداری می‌کنند به احتمال زیاد در همان تراکنش‌ها پنیر نیز خواهند خرید. این گونه اطلاعات می‌تواند به فروشنده‌گان برای کشف فرصت‌های متقابل خرید کمک کند (گوتوالد، ۲۰۰۶).

در این مطالعه مسئله قواعد همباش به این صورت بیان می‌شود: $I = \{i_1, i_2, \dots, i_m\}$ مجموعه‌ای از اقلام داده است و $T = \{t_1, t_2, \dots, t_n\}$ مجموعه‌ای از تراکنش‌های است که هریک شامل اقلام داده‌ای از مجموعه اقلام داده I است. بنابراین هر تراکنش i از مجموعه‌ای از اقلام داده تشکیل شده است؛ به گونه‌ای که $i \subseteq t_i$. اگر X و Y اقلام داده فرض شود، قاعدة همباش مفهومی به شکل $X \rightarrow Y$ است که در آن $X \subseteq I$, $Y \subseteq I$ و $Y \cap X = \emptyset$ (لیو، ۲۰۰۷: ۵۷-۶۰).

در قاعدة همباشی که به شکل $Y \rightarrow X$ باشد؛ X را «مقدم» و Y را «نتیجه (تالی)» می‌نامند. واضح است که مقدار مقدم، مقدار نتیجه را دربرمی‌گیرد. دامنه پشتیبانی از قاعده و میزان اعتماد به قاعده، مهم‌ترین معیارهای کیفی برای ارزیابی جالب‌بودن قاعده در نظر گرفته شده‌اند.

- دامنه پشتیبانی از قاعده (Support)
- نحوه محاسبه دامنه پشتیبانی از قاعده به صورت زیر است.

$$\text{sup}(A \Rightarrow B) = \frac{A \cap B}{X} \quad (\text{رابطه ۱})$$

که در آن، A و B دو قلم داده متفاوت در پایگاه داده و X کل اقلام‌هایی است که در پایگاه داده وجود دارد. این قاعده تمام تراکنش‌هایی را که در آنها دو قلم داده A و B وجود دارد، استخراج می‌کند و با مقدار حداقل دامنه پشتیبانی از قاعده که توسط کاربر مشخص می‌شود، مقایسه می‌کند و پس از آن فقط تراکنش‌هایی را انتخاب می‌کند که دامنه پشتیبانی از قاعده‌شان بزرگ‌تر یا مساوی حداقل دامنه پشتیبانی از قاعده باشد و باقی تراکنش‌ها قواعد به دردناخوری (غیر جالبی) هستند که حذف می‌شوند.

- میزان اعتماد به قاعده (Confidence) معیار میزان اعتماد به قاعده در فهرست جدید به صورت رابطه ۲ اعمال می‌شود.

$$\text{conf}(A \Rightarrow B) = P(B|A) = \frac{\text{sup}(A \Rightarrow B)}{\text{sup}(A)}; \quad \text{sup}(A) = \frac{A}{X} \quad (\text{رابطه ۲})$$

ابتدا تراکنش‌های حاوی قلم داده A محاسبه می‌شود و از بین آنها، تراکنش‌های حاوی قلم داده B استخراج می‌شود، سپس به مقایسه خروجی این رابطه با حداقل میزان اعتماد به قاعده پرداخته خواهد شد. قواعدی که از این فیلتر عبور کنند، قواعد همباش نامیده می‌شوند (آگراوال و شافر، ۱۹۹۶).

پیشینهٔ تجربی

الگوریتم اپریوری کلاسیک‌ترین و محبوب‌ترین الگوریتم برای استخراج قواعد همباش از پایگاه داده است که آگراوال و سریکانت آن را در سال ۱۹۹۴ برای استخراج قواعد همباش از مجموعه اقلام داده پر تکرار در پایگاه داده‌های تراکنشی با استفاده از دو معیار حد آستانه از قبیل تعریف شده به نام‌های دامنه پشتیبانی از قاعده و میزان اعتماد به قاعده، توسعه دادند.

از زمانی که ایده تولید قواعد همباش مطرح شده است تا کنون، محققان الگوریتم‌های متعددی برای انجام این مهم معرفی کردند که همه آنها در تلاش برای تولید قواعد همباش مفیدتر بودند (هان، چنگ، شین و یان، ۲۰۰۷). الگوریتم‌های قواعد همباش کاوی در زمینه‌های گوناگونی در کانون توجه قرار گرفته است. در ادامه به برخی از این مطالعات پرداخته می‌شود. هیو، وو و لایو (۲۰۱۳) ابتدا یک ساختار داده‌ای فشرده با عنوان PLMS-Tree برای ذخیره و فشرده‌سازی پایگاه داده رابطه‌ای، در قالب درختی معرفی کردند و پس از آن، الگوریتم

MSCP-Growth را بر اساس آن طراحی و ارائه کردند که به کاربران اجازه می‌دهد حداقل دامنه‌پشتیبانی از قاعده‌های متفاوت را برای اقلام داده بر اساس فرکانس طبیعی‌شان تعیین کند. در یک ساختار مشابه، هیو و چن FP-Tree را با عنوان MIS-Tree به منظور ذخیره اطلاعات پیچیده برای الگوهای پرتکرار طراحی کردند و بر اساس این درخت، الگوریتم CFP-Growth را به منظور کشف مجموعه اقلام داده پرتکرار ارائه دادند. سپس با بیان اینکه به کارگیری حداقل دامنه‌پشتیبانی از قاعده یکسان برای اقلام داده‌ای که هریک فرکانس خاصی دارند، مشکل خواهد بود، راهکاری جدید برای تنظیم دامنه‌پشتیبانی از قاعده اقلام داده معرفی کردند و با اجرای مکرر الگوریتم به پایانی رضایت‌بخش دست یافتند (هیو و چن، ۲۰۰۶).

لی و همکارانش نوعی الگوریتم کاوش چندسطحی فازی، برای استخراج دانش از پایگاه داده‌های تراکنشی به کمک حداقل دامنه‌پشتیبانی از قاعده چندگانه معرفی کردند. در این الگوریتم از یک بستار بالا به پایین برای دستیابی به اقلام داده پرتکرار بهره برند. پیاده‌سازی این الگوریتم در مطالعه مورדי، به استخراج قواعد همباش در سطوح مختلف تحت دامنه‌پشتیبانی از قاعده چندگانه انجامید (لی، هونگ و وانگ، ۲۰۰۸).

در مطالعه تسنگ و لین (۲۰۰۷) بیان شده است تعیین حداقل دامنه‌پشتیبانی از قاعده یکسان برای تمام اقلام داده‌ای که در سطح مشابهی طبقه‌بندی شده‌اند، به از دست‌رفتن برخی اطلاعات جالب در بین اقلام داده منجر خواهد شد. آنها با مطرح کردن مشکلات استفاده از الگوریتم اپریوری برای کشف الگوهای پرتکرار، الگوریتم‌های MMS-Cumulate و MMS-Stratify را ارائه کردند. این الگوریتم‌ها با استفاده از حداقل دامنه‌پشتیبانی از قاعده‌های متعدد، الگوهای پرتکرار را از مجموعه داده استخراج می‌کنند.

در مطالعه هوانگ (۲۰۱۳) تلاش شد الگوریتم FQSP، بهبود داده شود. محقق معتقد است اولاً از آنجاکه FQSP از حداقل دامنه‌پشتیبانی از قاعده واحد برای کشف الگوهای پرتکرار استفاده می‌کند؛ اگر حداقل دامنه‌پشتیبانی از قاعده، عددی بزرگ در نظر گرفته شود، اقلام داده غیرجالب بسیاری تولید خواهد شد و اگر عددی پایین در نظر گرفته شود، به از دست‌رفتن اقلام داده‌ای می‌انجامد که می‌تواند جالب باشد. از این رو در رویکرد جدید، روش حداقل دامنه‌پشتیبانی از قاعده چندگانه را به کار برد. دوم، با توجه به اینکه FQSP، فقط از تابع عضویت واحد استفاده می‌کند و عملکردی آشفته‌ای دارد، در رویکرد جدید برای پوشش این مشکل، ایده تابع عضویت قابل تنظیم را ارائه کرد.

در پژوهشی تلاش شده است الگوهای جزئی دوره‌ای با استفاده از حداقل دامنه‌پشتیبانی از قاعده چندگانه استخراج شود. در این پژوهش ابتدا به مشکل کارهای قبلی برای استخراج الگوهای جزئی دوره‌ای مبنی بر مشکل ناکارآمدی ناشی از به کارگیری حداقل دامنه‌پشتیبانی از

قاعده واحد، اشاره شده است. سپس برای غلبه بر این مشکل، الگوریتمی ارائه شد که نیاز به تولید الگوهای جزئی دوره‌ای کاندید را برطرف می‌کند و تعداد بازدیدهای متوالی از پایگاه داده را کاهش می‌دهد. سپس برای هر رویداد بر اساس فرکانس رخ دادنش، حداقل دامنه پشتیبانی از قاعده، تعیین شده است (پی، کولیت و تیل، ۲۰۰۷).

چن، هونگ و تسنگ (۲۰۰۹) تلاش کردند کار قبلی خود را مبنی بر الگوریتم داده‌کاوی ژنتیک فازی برای استخراج حداقل دامنه پشتیبانی از قاعده و توابع عضویت برای اقلام داده در پایگاه داده کمی، بهبود بخشنده. آنها الگوریتم بهبودیافته را که بر اساس تقسیم و حل کار می‌کند، DGFMMMS نامیدند. در این روش، از الگوریتم ژنتیک فازی برای استخراج قواعد همباش فازی استفاده شده است.

با توجه به اینکه بررسی کامل الگوریتم‌ها و رویکردهای حوزه استخراج قواعد همباش خارج از حوصله این پژوهش است، به همین مقدار بسنده می‌شود. با این حال در مقاله هان، چنگ، شیین و یان (۲۰۰۷)، نگاه ویژه و مفصلی به رویکردهای ارائه شده در حوزه استخراج قواعد همباش و کشف الگوهای پرتکرار تا سال ۱۳۸۶ شده است.

نکته حائز اهمیتی که انگیزه ارائه مقاله حاضر بوده است، اینکه در هر دو حالت به کارگیری حداقل دامنه پشتیبانی از قاعده واحد و چندگانه، بدون استثنای از کاربر درخواست می‌شود حداقل دامنه پشتیبانی از قاعده را تعیین کند. فرض کنید کاربر قصد اعمال الگوریتم اپریوری را بر پایگاه داده‌ای با میلیون‌ها تراکنش داشته باشد؛ به طور مسلم کاربر نمی‌تواند دانش لازم را درباره تمام تراکنش‌های موجود در پایگاه داده داشته باشد و بنابراین نمی‌تواند حداقل دامنه پشتیبانی از قاعده مناسبی را تعیین کند. در این مطالعه با استفاده از روش میانگین‌گیری، روشی معرفی شده است که در آن الگوریتم اپریوری به صورت کاملاً خودکار این حد آستانه را تعیین می‌کند.

فازی‌سازی

لطفی‌زاده، اولین فردی بود که نظریه مجموعه‌های فازی را مطرح کرد. این نظریه چارچوب ریاضی محکمی برای مطالعه پدیده‌ها و مفاهیم مبهم، مهیا می‌کند؛ زبان مدل‌سازی محسوب می‌شود و هنگامی که روابط و محدودیتها فازی می‌شوند، بسیار مناسب است (آذر، سنگی، ایزدخواه و انوری، ۱۳۹۴). در این پژوهش از روش خوش‌بندی فازی استفاده می‌شود. با بهره‌مندی از این روش می‌توان داده‌های قطعی را وارد مجموعه‌های فازی کرد. از میان الگوریتم‌هایی که برای خوش‌بندی فازی وجود دارد، در این مطالعه از الگوریتم محبوب خوش‌بندی فازی C-means (بزدک، ۱۹۸۱؛ ۱۵۰-۱۶۲ و شیهاب و بورگر، ۱۹۸۸) بهره برده شده است.

قواعد همباش فازی

پس از انتقال داده‌ها به محیط فازی، به استخراج قواعد همباش فازی از بین این داده‌ها اقدام خواهد شد. این کار به کمک رویکرد اپریبوری صورت خواهد گرفت؛ همان‌طور که پیش از این بیان شد، دو معیار اندازه‌گیری به نام‌های «دامنه پشتیبانی از قاعده» و «میزان اعتماد به قاعده» در استخراج قواعد همباش استفاده می‌شود که در محیط فازی این معیارها به صورت زیر مطرح می‌شوند:

- دامنه پشتیبانی از قاعده فازی

در اولین گام برای تعیین تعداد تکرار هر قلم داده در پایگاه داده فازی‌سازی شده، مجموع درجهٔ عضویت‌ها برای هر داده محاسبه می‌شود که این رقم میزان تکرار هر داده در نظر گرفته خواهد شد. رابطهٔ ۳ گویای مطلب فوق است.

$$\text{fuzzysum} = \sum_{(x) \in D} \mu(x) \quad \text{رابطهٔ ۳}$$

سپس برای تولید مجموعهٔ اقلام دو – داده‌ای، باید پس از مقایسه تمام درجهٔ عضویت‌های هر دو قلم داده با هم، حداقل^۱ را از بین آنها انتخاب کرد. در پایان، مجموع حداقل‌ها میزان تکرار دو قلم داده مذکور معرفی می‌شود. برای تولید مجموعهٔ اقلام سه – داده‌ای باید پس از مقایسه تمام درجهٔ عضویت‌های هر سه داده با هم، از بین آنها حداقل را انتخاب کرد که مجموع حداقل‌ها، میزان تکرار سه قلم داده مذکور معرفی می‌شود. این کار تا زمانی ادامه پیدا خواهد کرد که داده پر تکرار جدیدی تولید نشود. معمول ترین انتخاب برای عملگر t-norm (جانگ، سون و میزوئانی، ۱۹۷۷: ۱۱۷-۱۲۱)، یافتن حداقل در بین مجموعه‌ها است که در پژوهش پیش رو از این عملگر استفاده شده است. رابطهٔ ۴ گویای مطلب فوق است.

$$\text{fuzzysup}(A \rightarrow B) = \sum_{(x) \in D} T[A(x), B(y)] \quad \text{رابطهٔ ۴}$$

یانگر t-norm است و حداقل مقدار $T[A(x), B(y)]$ و $A(x)$ را محاسبه می‌کند.

- میزان اعتماد به قاعده فازی

پس از استخراج الگوهای پر تکرار فازی، برای تولید قواعد همباش تلاش خواهد شد که این کار مستلزم استفاده از میزان اعتماد به قاعده فازی است. قواعدی که از این فیلتر عبور کنند، قواعد

همباش فازی معرفی خواهند شد. در این مطالعه از عملگر t-norm برای محاسبه میزان اعتماد به قاعده فازی استفاده شده است. رابطه ۵ مطلب فوق را به صورت رسمی بیان می‌کند.

$$\text{fuzzyconf}(A \Rightarrow B) = \frac{\sum_{(x,y) \in D} T[A(x), B(y)]}{\sum_{(x) \in D} \min[A(x)]} \quad \text{رابطه ۵}$$

نحوه محاسبه حداقل دامنه پشتیبانی از قاعده با روش پیشنهادی

این پژوهش تلاش می‌کند الگوریتم، به صورت خودکار حداقل آستانه مناسبی را برای معیار اندازه‌گیری حداقل دامنه پشتیبانی از قاعده به کاربر معرفی کند. هنگامی که متخصصان بخواهند مجموعه‌ای از داده‌ها را با شاخصی مقایسه کنند و چنین شاخصی وجود نداشته باشد که داده‌ها نسبت به آن سنجیده شود و داده‌ایی که از این شاخص بزرگ‌تر (بهتر، قوی‌تر و ...) یا کوچک‌ترند (بدتر، ضعیفتر و ...) را دسته‌بندی کند، از روش‌های آماری کمک می‌گیرند و با توجه به معادله‌هایی مانند میانگین‌گیری، انحراف معیار، میانه، مد، واریانس و... شاخصی را به منظور مقایسه داده‌ها تعریف می‌کنند و با این کار اطلاعات را به دست می‌آورند.

از آنجاکه هیچ شاخص مناسبی وجود ندارد که بتوان حداقل آستانه مناسبی را برای معیار اندازه‌گیری دامنه پشتیبانی از قاعده با توجه به آن تعریف کرد، در این مطالعه نیز از روش‌های آماری استفاده شده است. از بین روش‌هایی که در این حوزه وجود دارد، روش میانگین‌گیری انتخاب شده است تا حداقل آستانه مناسب برای استخراج الگوهای پرتکرار تعریف شود؛ به طوری که این حداقل آستانه، نه خیلی پایین باشد که به تولید حجم زیادی از الگوهای به دردناکور منجر شود و نه خیلی بالا در نظر گرفته شود که به از دستدادن الگوهای جالب بینجامد. به کارگیری این ایده می‌تواند سبب بهبود روند کشف الگوهای پرتکرار و استخراج قواعد همباش شود. پس از انتقال داده‌ها به محیط فازی توسط الگوریتم خوشبندی FCM، از طریق رابطه ۶ مجموع تمام درجه‌های عضویت برای هر فیلد محاسبه می‌شود و این رقم بر تعداد کل اقلام داده (T) تقسیم خواهد شد. عدد به دست آمده حداقل دامنه پشتیبانی از قاعده معرفی می‌شود.

$$\text{fuzzy min sup}(A, B) = \frac{\sum_{(x,y) \in D} [\text{sum}(f_A(x), f_B(y))] }{|T|} \quad \text{رابطه ۶}$$

در واقع، در این پژوهش دخالت کاربر در روند اجرای الگوریتم اپریوری حذف شده است و ادعا می‌شود که با ارائه این روش، الگوریتم اپریوری به الگوریتمی خودکار تبدیل شده است.

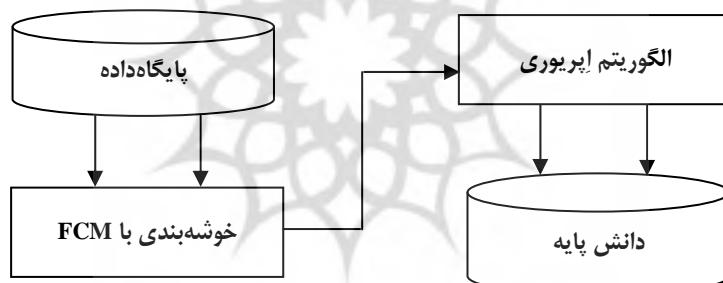
روش‌شناسی پژوهش

به طور کلی رویکرد پیشنهادی به منظور بهبود الگوریتم اپریوری در دو مرحله اجرا می‌شود:

- تبدیل داده‌های قطعی به فازی که از الگوریتم خوشبندی FCM استفاده خواهد شد؛
- رویکرد اپریوری با بهبود در نحوه تعیین حداقل دامنه پشتیبانی از قاعدة خودکار که از مجموعه داده‌های فازی برای کشف الگوهای پرتکرار و استخراج قواعد همباش، استفاده خواهد شد.

شکل ۲ مراحل اجرای کار را در قالب مدل نشان می‌دهد.

۱. دریافت مجموعه داده مدنظر از پایگاه داده که به منظور هماهنگی و حذف داده‌های پرت بر اساس قوانین پیش‌پردازش، تجزیه و تحلیل شده است؛
۲. انتقال مجموعه داده‌های قطعی به محیط فازی با استفاده از الگوریتم FCM؛
۳. استفاده از الگوریتم اپریوری با تکیه بر روش پیشنهادی برای تعیین حداقل دامنه پشتیبانی از قاعدة به منظور کشف الگوهای پرتکرار و استخراج قواعد همباش و درنهایت، ذخیره قواعد با نام KB.



شکل ۲. مدل رویکرد پیشنهادی

در ادامه به تعریف مفاهیمی که در رویکرد پیشنهادی به کار می‌رود، پرداخته شده است:

- فیلد: عبارت است از صفت، قلم داده یا ستون جدول؛
- رکورد: عبارت است از سطر با همه فیلدها؛
- $\mu(X)$: مقدار مجموعه فازی که عددی خواهد بود در بازه $[0, 1]$ ؛
- C_k : معرف مجموعه اقلام داده کاندید است که $1 \leq k \leq n$ ؛
- L_k : معرف مجموعه اقلام داده پرتکرار است که $1 \leq k \leq n$ ؛
- Fuzzy minsup: معیار اندازه‌گیری حداقل دامنه پشتیبانی از قاعدة فازی؛
- Fuzzy minconf: معیار اندازه‌گیری حداقل میزان اعتماد به قاعدة فازی.

مراحل ۱ تا ۱۲ شبه کد رویکرد پیشنهادی ارائه شده در شکل ۳ را با جزئیات توضیح می‌دهند:

۱. FCM پس از خوشبندی داده‌های قطعی، مرکز هر مجموعه فازی را تعیین می‌کند و مقادیر حداکثر و حداقل را برای هر فیلد از مجموعه داده ورودی پیدا می‌کند؛
۲. با استفاده از trimf اقلام داده میان خوشها توزیع می‌شود؛
۳. حداقل دامنه پشتیبانی از قاعده با استفاده از رابطه ۶ به صورت خودکار محاسبه می‌شود؛
۴. دامنه پشتیبانی از قاعده هر مجموعه قلم داده برای هر رکورد با استفاده از رابطه ۳ به دست می‌آید، سپس در فهرست مجموعه اقلام داده کاندید C_1 مرتب و ذخیره می‌شود؛
۵. از بین مجموعه اقلام داده کاندید C_1 ، آنهای که بتوانند شرط حداقل دامنه پشتیبانی از قاعده را برآورده کنند، مجموعه اقلام داده پر تکرارند که در L_1 مرتب و ذخیره می‌شوند؛
۶. اقلام داده موجود در L_1 به صورت زیر با هم الحق می‌شوند:

$$(L, \text{Join } L_i) = \{ \{C[1], C[i], \{C[1], C[i+1]\}, \dots, \{C[1], C[n]\} \} \}$$

که $C[1]$ اولین مجموعه فازی، $C[i]$ دومین مجموعه فازی و $C[n]$ آخرین مجموعه فازی است و $C[1] \cap C[i] = \emptyset$, $C[1] \cap C[i+1] = \emptyset$, ..., $C[1] \cap C[n] = \emptyset$. نتیجه در فهرست مجموعه اقلام داده کاندید C_2 ذخیره می‌شود. دامنه پشتیبانی از قاعده برای هر مجموعه قلم داده کاندید با استفاده از رابطه ۴ محاسبه می‌شود؛

۷. از بین مجموعه اقلام داده کاندید C_2 ، آنهای که بتوانند شرط حداقل دامنه پشتیبانی از قاعده را برآورده کنند، مجموعه اقلام داده پر تکرارند که در L_2 مرتب و ذخیره می‌شوند؛

۸. اقلام داده‌ای که در L_2 هستند با هم الحق می‌شوند. باید تمام زیرمجموعه‌های C_2 به مثابه مجموعه اقلام داده پر تکرار در L_1 حضور داشته باشند، یعنی تمام

زیرمجموعه‌های C_K به مثابه مجموعه اقلام داده پر تکرار در L_{K-1} حضور داشته باشند؛

۹. نتیجه عملیات الحق مرحله قبل در فهرست مجموعه اقلام داده کاندید C_3 ذخیره می‌شود. دامنه پشتیبانی از قاعده برای هر مجموعه قلم داده کاندید محاسبه می‌شود؛

۱۰. اقلام داده کاندید C_3 که شرط حداقل دامنه پشتیبانی از قاعده را برآورده کنند به L_3 منتقال داده می‌شوند؛

۱۱. این فرایند تا زمانی که L_K خالی شود، تکرار می‌شود؛

۱۲. الگوهای پر تکرار کشف شده در قالب (IF-Then) مرتب می‌شوند و میزان اعتماد به قاعده با استفاده از رابطه ۵ به دست می‌آید و نتیجه در KB ذخیره می‌شود.

Begin

Find the fuzzy set of the quantitative data set, based on FCM.

Calculate the *fuzzy minsup* value using equation 6.

Calculate the summation of the membership value for each fuzzy set with all records using Equation 3.

IF $fuzzysum \geq fuzzy minsup$ Then

Insert the fuzzy set into L_1 , $L_1 = \{\text{frequent itemset}\}$

For ($k = 2$; $L_{k-1} \neq \emptyset$; $k++$) **do**

C_k = generate candidate from L_{k-1} (join L_{k-1} call (p) with L_{k-1} call (q));

{

Insert into C_k

Select itemset; p. *item*₁, p. *item*₂ ... p. *item* _{$k-1$} , q. *item* _{$k-1$} From p, q

Where p. *item*₁ = q. *item*₁, p. *item*₂ = q. *item*₂ ... p. *item* _{$k-1$} = q. *item* _{$k-1$}

}

For each $c \in C_k$ **do**

Check all subsets of all itemsets in C_k , should be frequent itemsets in L_{k-1}

For each ($k-1$) subset s of c **do**

IF $s \notin L_{k-1}$ Then Delete c from C_k

EndIF

EndFor

EndFor

For each itemset candidate in C_k **do**

Calculate the fuzzy support value using Equation 4.

Insert the fuzzy set into L_k , $L_k = \{\text{frequent itemset}\}$

EndFor

EndFor

Select the frequent itemsets that exist in L_2 to L_k under form "IF-Then".

For each frequent itemset

Calculate the fuzzy confidence for frequent itemset using Equation 5.

Endfor

EndBegin

شکل ۳. شبکه کد رویکرد پیشنهادی

یافته‌های پژوهش

برای تجزیه و تحلیل و اعتبارسنجی اهداف، رویکردی که در بخش قبل مطرح شد، بر مجموعه داده انتخاب شده از یک کتابخانه الکترونیک، اعمال شده است.

پیاده‌سازی چگونگی کارکرد رویکرد پیشنهادی

با توجه به سطح اهمیت کتابخانه‌های الکترونیک میان مؤسسه‌های تحقیقاتی و دانشگاهی، در این پژوهش چگونگی استخراج قواعد همباش فازی با استفاده از رویکرد پیشنهادی و با کمک گرفتن از داده‌های یکی از کتابخانه‌های الکترونیک توصیف می‌شود. در این مطالعه اطلاعات با توجه به اطلاعات مقاله جلیل‌منش و همکارش با عنوان «نگاشت دانش‌سازمانی بر اساس سیستم اطلاعاتی کتابخانه» به دست آمده است (جلیل‌منش و همایون‌والا، ۱۳۹۰).

در کل هدف از ارائه این مثال، یافتن ارتباطات جالب بین کتاب‌های یکی از کتابخانه‌های الکترونیک با استفاده از رویکرد پیشنهادی بوده است. با تجزیه و تحلیل کتاب‌هایی که محتمل است با هم به امانت برده شوند، اطلاعات مفیدی برای محققان و کاربران به دست می‌آید و می‌توانند در کمترین زمان جست‌وجو، بهترین نتایج را استخراج کنند و این امکان در اختیار آنها قرار خواهد گرفت که بدانند موضوع مد نظرشان با چه موضوعات دیگری در ارتباط است. در این مطالعه برای تشکیل انبار داده، اطلاعات از این پایگاه داده دریافت شده است. جدول ۱ نمونه‌های از این انبار داده را نشان می‌دهد.

جدول ۱. نمونه‌ای از انبار داده کتابخانه الکترونیک

ردیف	نام	ژانریه	اقلام داده	...
۱	ناصری	۱	تکنولوژی نانو، زیست‌شناسی، فیزیک،
۲	شفیعی	۲	کامپیوتر، مکانیک،
۳	علوی	۳	فیزیک، بیولوژی، الکترونیک، کامپیوتر،
۴	اصغری	۴	الکترونیک، مکانیک، تکنولوژی نانو،
۵	کبیری	۵	فیزیک، شیمی، تکنولوژی نانو،
۶	اکبری	۶	الکترونیک،
۷	حدیری	۷	فیزیک، بیولوژی، کامپیوتر، شیمی،
۸	محسنی	۸	شیمی، معماری،
۹	ناصری	۹	فیزیک، زیست‌شناسی، تکنولوژی نانو،
۱۰	شفیعی	۱۰	فیزیک، زیست‌شناسی، کامپیوتر، مکانیک	...
...

وظایف آماده‌سازی داده‌ها در چند دوره انجام می‌گیرد و هیچ تعریف از پیش تعیین شده‌ای ندارد. این وظایف شامل انتخاب جدول، رکوردها، خصیصه‌ها و همچنین انتقال و پاکسازی داده برای مدل‌سازی است (رادفر، نظافتی و یوسفی اصلی، ۱۳۹۳). در مرحله پیش‌پردازش، فقط اطلاعات لازم برای استخراج قواعد همباش فازی، از این انبار داده استخراج خواهد شد؛ به این صورت که در هر تراکنش چه کتابهایی حضور داشته‌اند. جدول ۲ اطلاعات قطعی پیش‌پردازش شده‌ای را که آماده فازی‌سازی‌اند، نشان می‌دهد. سپس قسمتی از این مجموعه داده برای استخراج قواعد همباش انتخاب می‌شود. جدول ۳ یکسری اطلاعات آماری از مقادیر حداقل، حداکثر و مراکز داده‌های ورودی را نشان می‌دهد.

جدول ۲. نمونه‌ای از مجموعه داده قطعی کتابخانه الکترونیک

ردیف	ماه	فیزیک	زیست‌شناسی	الکترونیک	کامپیوتر	شیمی	...
۱	ژانویه	۱	۱۲	۲۰	۵	·	...
۲	فوریه	۵	۲	۱۲	۱۳	۱۶	...
۳	مارس	۱۱	۴	۱۱	۱۸	۱۸	...
۴	آوریل	۲	۰	۱	۱	۵	...
۵	مه	۳	۱	۸	۶	۱۲	...
۶	ژوئن	۰	۶	۳	۷	۱۸	...
۷	جولای	۱	۱۵	۷	۱۹	۱۴	...
۸	آگوست	۸	۰	۶	۲۱	·	...
۹	سپتامبر	۴	۸	۴	۱	۱۸	...
۱۰	اکتبر	۷	۷	۲	۱۶	۱۴	...
...

جدول ۳. اطلاعات آماری از مجموعه داده قطعی کتابخانه الکترونیک

	کامپیوتر	الکترونیک	زیست‌شناسی	فیزیک	...
حداقل	·	·	·	·	·
حداکثر	۲۱	۲۰	۱۵	۱۱	۱۱
مرکز ۱	۰/۹۸۸۲	۱/۷۲۷۵	۰/۲۵۴۵	۰/۷۱۱۵	۰/۷۱۱۵
مرکز ۲	۶/۰۱۶۵	۷/۱۵۷۴	۳/۱۷۴۶	۳/۵۹۱۷	۳/۵۹۱۷
مرکز ۳	۱۴/۲۲۹۴	۱۱/۴۶۸۲	۷/۰۷۸۷	۷/۰۴۶۹	۷/۰۴۶۹
مرکز ۴	۱۹/۲۹۱۱	۱۹/۹۹۴۹	۱۳/۶۵۵۳	۱۰/۴۶۲۲	۱۰/۴۶۲۲

حال مجموعه داده‌های قطعی به محیط فازی منتقل می‌شود که برای این کار از الگوریتم خوشبندی FCM استفاده شده است. در این مطالعه موردی، برای هر فیلد چهار خوشه با عنوان‌های «ضعیف»^۱، «متوسط»^۲، «خوب»^۳ و «عالی»^۴ تعریف شده است و تمام اقلام داده در این چهار خوشه توزیع شده‌اند. برای خلاصه کردن نام خوشه‌ها از کلمه اول نام هر خوشه استفاده شده است که به ترتیب عبارت‌اند از: (T, G, M, W). جدول ۴، هر فیلد را با خوشه‌های متناظر و تابع عضویتش نشان می‌دهد.

جدول ۴. فیلدها و مجموعه‌های فازی متناظر با آن‌ها

هزوزه دانشی	مجموعه فازی	تابع عضویت
فیزیک	ضعیف (W۱)، متوسط (M۲)، خوب (G۳)، عالی (T۴)	Trimf
زیست‌شناسی	ضعیف (W۵)، متوسط (M۶)، خوب (G۷)، عالی (T۸)	Trimf
الکترونیک	ضعیف (W۹)، متوسط (M۱۰)، خوب (G۱۱)، عالی (T۱۲)	Trimf
کامپیوتر	ضعیف (W۱۳)، متوسط (M۱۴)، خوب (G۱۵)، عالی (T۱۶)	Trimf

درجه عضویت برای تمام قسمت‌هایی که مجموعه‌ها با هم تداخلی نداشته باشند، برابر با ۱ است، اما در مناطقی که مجموعه‌ها با هم تداخل دارند، تعیین درجه عضویت به این بستگی دارد که در مرز بالای مجموعه قرار دارد یا مرز پایین. به طور مثال برای بیان درجه عضویت فازی فیلد فیزیک (فرض کنید p) از رابطه‌های ۷ تا ۱۰ استفاده شده است.

$$\mu_{\text{Physics.Middle}}(p) = \begin{cases} 1 & p \leq 0/7 \\ \frac{3/6 - p}{2/9} & 0/7 \leq p \leq 3/6 \end{cases} \quad \text{رابطه ۷}$$

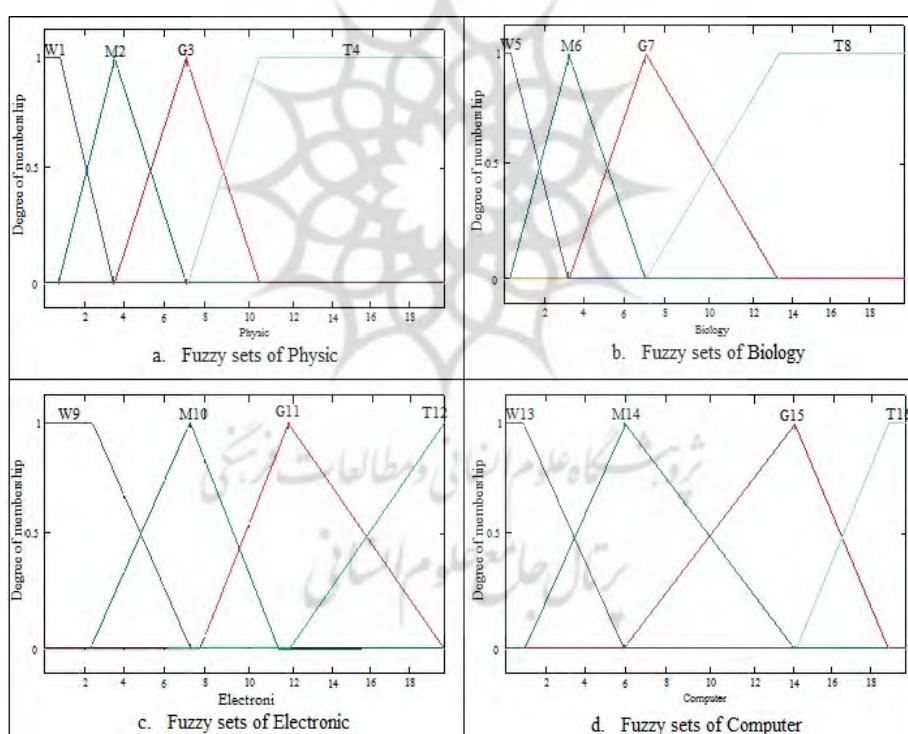
$$\mu_{\text{Physics.Middle}}(p) = \begin{cases} \frac{p - 0/7}{2/9} & 0/7 \leq p \leq 3/6 \\ \frac{7/1 - p}{3/5} & 3/6 \leq p \leq 7/1 \end{cases} \quad \text{رابطه ۸}$$

-
1. Weak
 2. Middle
 3. Good
 4. Top

$$\mu_{\text{Physics.Good}}(p) = \begin{cases} \frac{p - 3/6}{3/6} & 3/6 \leq p \leq 7/1 \\ \frac{3/5}{10/5 - p} & 7/1 \leq p \leq 10/5 \\ \frac{3/4}{3/4} & p \geq 10/5 \end{cases} \quad \text{رابطه ۹}$$

$$\mu_{\text{Physics.Top}}(p) = \begin{cases} \frac{p - 7/1}{3/4} & 7/1 \leq p \leq 10/5 \\ 1 & p \geq 10/5 \end{cases} \quad \text{رابطه ۱۰}$$

شکل ۴ خوشبندی فازی با استفاده از الگوریتم FCM و محدوده‌های خوشبدها را نشان می‌دهد. همچنین جدول ۵ توزیع برخی داده‌ها را میان خوشبدها نشان می‌دهد.



شکل ۴. خوشبندی فازی کتابخانه الکترونیک. (الف) مجموعه‌های فازی فیلد فیزیک؛ (ب) مجموعه‌های فازی فیلد زیست‌شناسی؛ (ج) مجموعه‌های فازی فیلد الکترونیک؛ (د) مجموعه‌های فازی فیلد کامپیوتر

جدول ۵. توزیع برخی داده‌ها میان خوشه‌ها (کتابخانه الکترونیک)

الکترونیک	ژیستشناسی				فیزیک			
...	W{۹}	T{۸}	G{۷}	M{۶}	W{۵}	T{۴}	G{۳}	M{۲}
...	.	.۰/۸۵۶	.۰/۰۹۷	.۰/۰۳	.۰/۰۱۷	.۰/۰۰۱	.۰/۰۰۳	.۰/۰۱۲
...	.۰/۰۰۳	.۰/۰۰۷	.۰/۰۳۵	.۰/۶۵۹	.۰/۲۹۹	.۰/۰۴	.۰/۲۸۷	.۰/۶۰۷
...	.۰/۰۰۳	.۰/۰۰۷	.۰/۰۶۳	.۰/۸۸۷	.۰/۰۴۳	.۰/۹۷۴	.۰/۰۱۸	.۰/۰۰۵
...	.۰/۹۸	.	.۰/۰۰۱	.۰/۰۰۷	.۰/۹۹۲	.۰/۰۱۳	.۰/۰۳۷	.۰/۳۷۶
...	.۰/۰۱۷	.۰/۰۰۴	.۰/۰۱۳	.۰/۰۱۳	.۰/۸۸	.۰/۰۰۵	.۰/۰۲	.۰/۹۱۴
...	.۰/۸۹۱	.۰/۰۱۷	.۰/۸۳۳	.۰/۱۲۱	.۰/۰۲۹	.۰/۰۰۴	.۰/۰۱	.۰/۰۳۷
...	.۰/۰۰۱	.۰/۹۵۲	.۰/۰۲۷	.۰/۰۱۳	.۰/۰۰۸	.۰/۰۰۱	.۰/۰۰۲	.۰/۰۱۲
...	.۰/۰۶۵	.	.۰/۰۰۱	.۰/۰۰۷	.۰/۹۹۲	.۰/۱۲۴	.۰/۸۲۴	.۰/۰۳۸
...	.۰/۶۱۳	.۰/۰۲۵	.۰/۹۲۸	.۰/۰۳۴	.۰/۰۱۳	.۰/۰۰۴	.۰/۰۱۷	.۰/۹۶۴
...	.۰/۹۱۹	.	۱	.	.	.	۱	.
...	.۰/۰۱۷	.	.۰/۰۰۲	.۰/۹۹۴	.۰/۰۰۴	.	.	.۰/۰۱
...	.۰/۹۹۶	.	.۰/۰۰۱	.۰/۰۰۷	.۰/۹۹۲	.۰/۰۰۳	.۰/۰۰۱	.۰/۰۳۷
...

از این مرحله به بعد است که از الگوریتم اپریوری برای استخراج الگوهای پر تکرار و تولید قواعد همباش استفاده می‌شود. با توجه به رابطه μ معیار اندازه‌گیری حداقل دامنه پشتیبانی از قاعده در این مطالعه موردی برابر با $\text{Fuzzyminsup} = ۰/۲۶۳$ به دست آمده است. جدول‌های ۶ تا ۱۲ کشف اقلام داده پر تکرار را با استفاده از رویکرد پیشنهادی به تصویر می‌کشند.

جدول ۶. قسمتی از L_1 ، قسمتی از C_1

مجموعه داده	قلم داده	دامنه پشتیبانی از قاعده
W{۱}	W{۱}	۳/۶۵۲
M{۲}	M{۲}	۲/۹۶۵
G{۳}	G{۳}	۲/۲۱۸
T{۴}	T{۴}	۱/۱۶۶
W{۵}	W{۵}	۲/۲۸۱
...

جدول ۸. نحوه محاسبه دامنه پشتیبانی از قاعده برای دو قلمداده

دامنه پشتیبانی از قاعده	T{۸}	W{۱}
.۰/۸۵۶	.۰/۸۵۶	.۰/۹۸۵
.۰/۰۰۷	.۰/۰۰۷	.۰/۰۶۶
.۰/۰۰۳	.۰/۰۰۷	.۰/۰۰۳
.	.	.۰/۵۷۴
.۰/۰۰۴	.۰/۰۰۴	.۰/۰۶۱
...
$\sum = ۱ / ۸۵۴$

جدول ۹. قسمتی از L۲

مجموعه داده
W{۱} , M{۲}
W{۱} , M{۵}
W{۱} , G{۷}
W{۱} , T{۸}
W{۱} , W{۹}
W{۱} , M{۱۰}
W{۱} , G{۱۱}
M{۷} , G{۳}
...

جدول ۹. قسمتی از C۲

دامنه پشتیبانی از قاعده	مجموعه داده
W{۱} , M{۲}	.۰/۵۹۶
W{۱} , G{۳}	.۰/۱۷
W{۱} , T{۴}	.۰/۰۸۵
W{۱} , W{۵}	.۰/۲۱۱
W{۱} , M{۶}	.۰/۳۳۳
W{۱} , G{۷}	.۱/۰۲۵
W{۱} , T{۸}	.۱/۸۵۴
W{۱} , W{۹}	.۱/۵۱۸
...	...

جدول ۱۰. قسمتی از L۳

مجموعه داده
W{۱} , M{۲} , W{۹}
M{۲} , G{۳} , W{۵}
M{۲} , G{۳} , M{۶}
M{۲} , G{۳} , M{۱۰}
M{۲} , W{۵} , M{۶}
M{۷} , W{۵} , M{۱۰}
M{۲} , W{۵} , G{۱۱}
W{۱} , M{۶} , M{۱۰}
...

جدول ۱۱. قسمتی از C۳

دامنه پشتیبانی از قاعده	مجموعه داده
W{۱} , M{۲} , M{۶}	.۰/۲۲
W{۱} , M{۲} , G{۷}	.۰/۱۲۹
W{۱} , M{۲} , W{۹}	.۰/۴۶۶
W{۱} , M{۲} , M{۱۰}	.۰/۱۹۵
M{۲} , G{۳} , W{۵}	.۰/۳۷۸
M{۲} , G{۳} , M{۶}	.۰/۳۵۸
M{۱} , G{۳} , G{۷}	.۰/۰۸۳
M{۲} , G{۳} , W{۹}	.۰/۱
...	...

تعیین خودکار حداقل دامنه پشتیبانی از قاعده در محیط فازی ... ۲۷۷

تا این مرحله الگوهای پر تکرار با دامنه پشتیبانی از قاعده شان کشف شده اند. از این مرحله به بعد استخراج قواعد هم باش آغاز خواهد شد. ابتدا تمام مجموعه اقلام داده پر تکرار موجود در L_2 تا L_n در قالب های IF-Then قرار می گیرند. سپس برای هر یک میزان اعتماد به قاعده بر اساس رابطه ۵ محاسبه می شود. جدول ۱۳ محاسبه این معیار را نشان می دهد.

جدول ۱۳. محاسبه معیار اندازه گیری میزان اعتماد به قاعده

الگوهای پر تکرار	Form ($x \rightarrow y$)	Support (x,y)	Support (x)	Conf = Support (x,y)/Support (x)
{1, 8}	(1 → 8)	1/854	3/652	.1508
{10, 4}	(10 → 4)	1/073	2/338	.0459
{1, 2, 9}	(1 → 2, 9)	.0466	3/652	.0128
{3, 9, 7}	(3, 9 → 7)	.0968	1/072	.0903
{6, 10, 3, 5}	(6, 10 → 3, 5)	.0356	1/768	.0201
{1, 9, 11, 7}	(1, 9, 11 → 7)	.087	0/907	.0959
{5, 2, 3, 6, 10}	(5 → 2, 3, 6, 10)	.0343	2/281	.015
{5, 6, 10, 2, 3}	(5, 6, 10 → 2, 3)	.0343	0/446	.0769

در نهایت جدول ۱۴ برخی از قواعد هم باش تولید شده با استفاده از روش پیشنهادی را نشان می دهد که در آن $Fuzzyminsup = 0.263$ و $Fuzzyminconf = 0.7$ در نظر گرفته شده اند.

جدول ۱۴. برخی از قواعد هم باش تولید شده با استفاده از رویکرد پیشنهادی

قواعد هم باش	Support (x,y)	Support (x)	Confidence ($x \rightarrow y$)
(7 → 9)	2/387	2/998	.796
(7, 11 → 9)	1/226	1/272	.964
(7, 10 → 9, 11)	.03	.0392	.765
(10, 11 → 9)	.0347	.0404	.859
(2, 3 → 10)	.0383	.0419	.914
(1, 7, 9 → 11)	.087	.087	1
(9, 10 → 11)	.0347	.0347	1
(7, 9, 10 → 11)	.03	.03	1

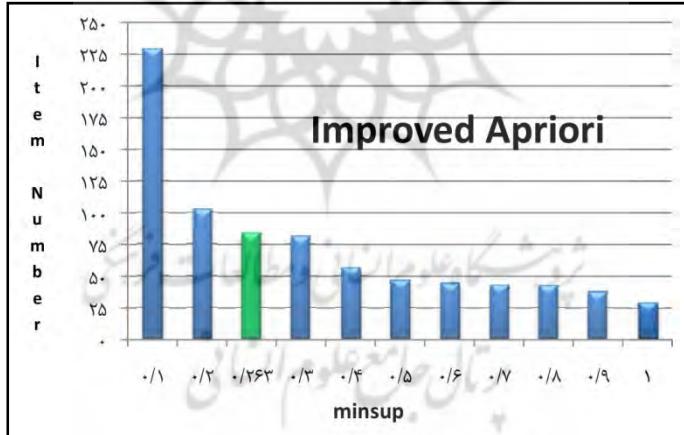
حال می‌توان به جای اعداد به کاررفته در این پژوهش، اقلام داده متضاظر با آنها را قرار داد. این کار درک بهتری از خروجی‌ها را به همراه می‌آورد. شکل ۵ برخی از قواعد همباش را در قالب IF-Then نشان می‌دهد که در آنها از عنوان خود اقلام داده استفاده شده است.

IF Biology = Good Then Electronic = Weak, Confidence=0/796
IF Physics=Top and Electronic= Middle Then Biology= Middle, Confidence= 0/8
IF Physics= Good and Electronic= Middle Then Physics= Middle and Biology= Middle
Confidence= 0/9

شکل ۵. برخی از قواعد همباش استخراج شده در قالب IF-Then

تجزیه و تحلیل یافته‌ها

از آنجا که در این پژوهش حداقل آستانه برای حداقل دامنه پشتیبانی از قاعده به صورت خودکار تعریف شد، می‌توان ادعا کرد که تمام الگوهای پرتکرار استخراج خواهند شد. شکل ۶ مقایسه‌ای از تعداد اقلام داده پرتکرار تولیدشده روش پیشنهادی و حداقل آستانه‌های مختلف را نشان می‌دهد.

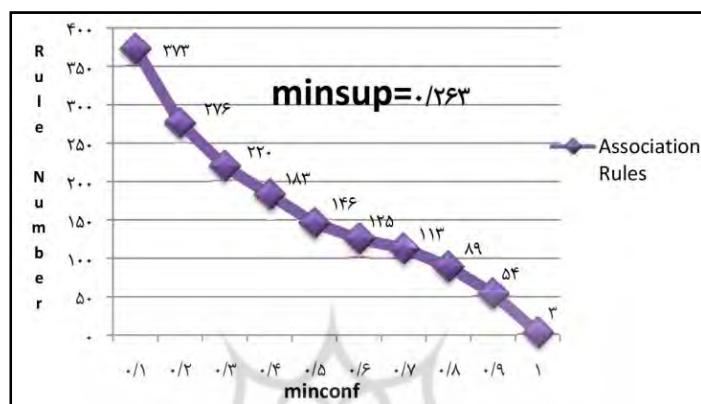


شکل ۶. تعداد الگوهای پرتکرار تولیدشده با استفاده از روش پیشنهادی و حداقل دامنه پشتیبانی از قاعده‌های مختلف

حداقل دامنه پشتیبانی از قاعده به دست آمده برای مطالعه موردی این پژوهش با استفاده از رویکرد پیشنهادی برابر با $0/263$ است و بر اساس آن، قواعد همباش با توجه به معیار

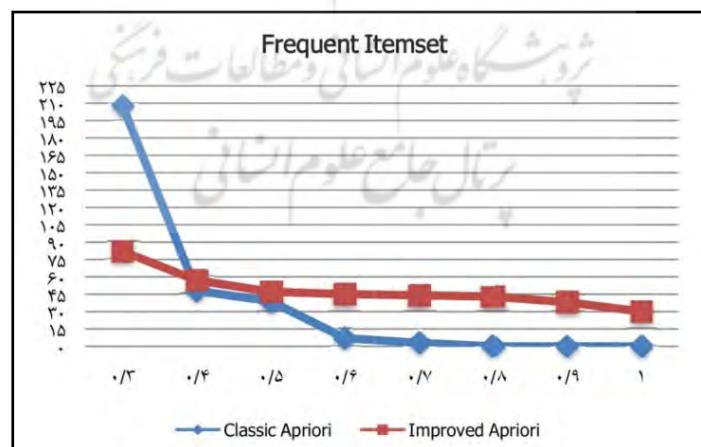
تعیین خودکار حداقل دامنه پشتیبانی از قاعده در محیط فازی ... ۲۷۹

اندازه‌گیری میزان اعتماد به قاعده‌شان استخراج شده‌اند. شکل ۷ تعداد قواعد همباش تولید شده با حداقل دامنه پشتیبانی از قاعده $= 0.263$ و حداقل میزان اعتماد به قاعده‌های مختلف را نشان می‌دهد.



شکل ۷. تعداد قواعد همباش تولید شده با استفاده از حداقل میزان اعتماد به قاعده‌های مختلف

در این مطالعه، الگوریتم اپریوری کلاسیک با استفاده از نرم‌افزار و داده‌های پژوهش، اعمال شد. مقایسه نتایج نشان داد الگوهای پرتکرار استخراج شده با رویکرد پیشنهادی از انسجام بیشتری برخوردارند و الگوهای پرتکراری که در الگوریتم اپریوری کلاسیک از دست رفته‌اند، در رویکرد پیشنهادی به راحتی کشف خواهند شد.



شکل ۸. مقایسه رویکرد پیشنهادی و الگوریتم اپریوری کلاسیک

نتیجه‌گیری و پیشنهادها

در این پژوهش، روشی کارآمد برای بهبود الگوریتم اپریوری مبنی بر تعیین خودکار حداقل دامنه پشتیبانی از قاعده به منظور تولید الگوهای پرتکرار و استخراج قواعد همباش از پایگاه داده‌ها ارائه شد. از ویژگی‌های شایان توجه رویکرد پیشنهادی، انتقال داده‌های قطعی به محیط فازی است؛ چرا که بر اساس دلایل بیان شده در پیشنهاد نظری، استخراج قواعد همباش از مجموعه داده‌های قطعی، به تولید قواعدی با دقت کم و ضعیف منجر خواهد شد. تعیین حداقل دامنه پشتیبانی از قاعده این پژوهش به کمک روش‌های آماری و روش میانگین‌گیری انجام گرفت و پرتکراربودن اقلام داده در پایگاه داده‌ها با آن سنجیده شد. اقلام داده‌ای که دامنه پشتیبانی از قاعده بزرگ‌تر یا مساوی حداقل دامنه پشتیبانی از قاعده داشتند، به مثابه مجموعه اقلام داده پرتکرار به مراحل بعدی راه یافتند و بقیه آنها حذف شدند.

همان‌طور که گفته شد، مهم‌ترین مزیت رویکرد پیشنهادی این است که کاربران از تعیین حداقل دامنه پشتیبانی از قاعده معاف‌اند. برای تعیین حداقل دامنه پشتیبانی از قاعده، از روش میانگین‌گیری از حوزه دانشی آمار استفاده شده است؛ با این حال سایر روش‌هایی که در این حوزه وجود دارد (مانند واریانس، میانه، انحراف معیار و...) را نیز می‌توان برای انجام این مهم به کار برد و نتایج را با روش این پژوهش مقایسه کرد.

از آنجاکه تمام الگوریتم‌های حوزه استخراج قواعد همباش از کاربران درخواست تعیین حداقل دامنه پشتیبانی از قاعده را دارند، پیشنهاد می‌شود رویکرد پیشنهادی این پژوهش برای الگوریتم‌های دیگر این حوزه به کار رود و نتایج، تجزیه و تحلیل شود.

در نهایت، الگوریتم اپریوری معیار اندازه‌گیری دیگری دارد که حداقل میزان اعتماد به قاعده نامیده می‌شود. کاربران هنگام کار، باید این معیار را نیز تعیین کنند؛ پیشنهاد می‌شود برای تعیین حداقل میزان اعتماد به قاعده خودکار نیز مطالعاتی صورت گیرد، با این کار انتظار می‌رود قواعد جالب‌تری استخراج شود.

References

- Agrawal, R. & Shafer, J.C. (1996). Parallel mining of association rules, *IEEE Transactions on Knowledge and Data Engineering*, 8(6): 962–969.
- Agrawal, R. & Srikant, R. (1994). Fast algorithms for mining association rules in large databases [A].*Proc. of the 20th Int'l Conf on Very Large Data Bases* [C]. Santiago: Morgan Kaufmann, 478-499.
- Akhondzadeh-Noughabi, L. & Albadvi, A. & Aghdasi, M. (2014). Mining customer dynamics in designing customer segmentation using data mining techniques.

- Quarterly Journal of Information technology management*, 6(1): 1-30. (in Persian)
- Azar, A., Sangi, M., Izadkhah, M-M. & Anvari, A. (2015). Synergy management model of the holding by fuzzy approach, the role of information technology in its implementation. *Quarterly Journal of Information technology management*, 7(1): 1-22. (in Persian)
- Azizi, SH., Abadi, V.H. & Balaghi Inanlou, M. (2014). Segmentation of Internet Banking Users Based on Expectations: A Data Mining Approach. *Quarterly Journal of Information technology management*, 6(3): 419-434. (in Persian)
- Bezdek, J.C. (1981). *Pattern Recognition with Fuzzy Objective Function Algorithms*. Kluwer Academic Publishers Norwell, MA, USA.
- Cakir, O. & Aras, M.E. (2012). A recommendation engine by using association rules. *Procedia – social and Behavioral Sciences*, 62(24): 452 – 456.
- Chen, C., Hong, T. & Tseng, V. (2009). An improved approach to find membership functions and multiple minimum supports in fuzzy data mining. *Expert Systems with Applications*, 36(6): 10016–10024.
- Dunham, M.H. (2002). *Data Mining: Introductory and Advanced Topics*. Prentice Hall PTR Upper Saddle River, NJ, USA.
- Gottwald, S. (2006). Universes of Fuzzy Sets and Axiomatizations of Fuzzy Set Theory. *Studia Logica*, 82(2): 211-244.
- Han, J., Cheng, H., Xin, D. & Yan, X. (2007). Frequent pattern mining: current status and future Directions. *Data Mining and Knowledge Discovery*, 15(1): 55-88.
- Hu, Y. & Chen, Y. (2006). Mining association rules with multiple minimum supports: a new mining algorithm and a support tuning mechanism. *Decision Support Systems*, 42(1): 1 – 24.
- Hu, Y., Wu, F. & Liao, Y. (2013). An efficient tree-based algorithm for mining sequential patterns with multiple minimum supports. *The Journal of Systems and Software*, 86(5): 1224- 1238.
- Huang, T. (2013). Discovery of fuzzy quantitative sequential patterns with multiple minimum supports and adjustable membership functions. *Information Sciences*, 222(10): 126-146.
- Jalilmanesh, A. & Homaiounvala, A. (2011). Organizational Knowledge Mapping Based on Library Information System. *IADIS Collaborative Technologies, Rome (Italy)*, 20-26.
- Jang, J., Sun, C. & Mizutani, E. (1997). *Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence*. Paperback.
- Lee, Y., Hong, T. & Wang, T. (2008). Multi-level fuzzy mining with multiple minimum supports. *Expert Systems with Applications*, 34(1): 459–468.

- Lei, Z. & Ren-Hou, L. (2007). An Algorithm for Mining Fuzzy Association Rules Based on Immune Principles. *Proceedings of the 7th IEEE International Conference on Bioinformatics and Bioengineering*, BIBE. Boston, MA.
- Liu, B. (2007). *Web Data Mining: Exploring Hyperlinks, Contents, and Usage Data*, Springer.
- Pea, J., Qualite, L. & Tille, Y. (2007). Systematic smpeling is a minimum support design. *Computational statistics & Data Analysis*, 51(12): 5591-5602.
- Radfar, R., Nezafati, N. & Yousefi Asli, S. (2014). Classification of Internet banking customers using data mining algorithms. *Quarterly Journal of Information technology management*, 6(1): 71–90. (in Persian)
- Shihab, A.I. & Burger, P. (1998). The Analysis of Cardiac Velocity MR Images Using Fuzzy Clustering. *Proceeding of SPIE Medical Imaging Physiology and Function from Multidimensional Images*, 3337(14): 176–183.
- Tseng, M. & Lin, W. (2007). Efficient mining of generalized association rules with non-uniform minimum support. *Data & Knowledge Engineering*, 62(1): 41-64.
- Lotfizadeh, A. (1965). Fuzzy sets. *Information and Control*, 8 (3): 338-353.



پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرستال جامع علوم انسانی