

کشف و یادگیری پدیده‌های استثنایی با به‌کارگیری تئوری استثنائات و تئوری رضایتمندی

مسعود عابسی^۱، الهه حاجی گل‌یزدی^۲

چکیده: منطق یادگیری از استثنائات چالش مهمی در حیطه داده‌کاوی و کشف دانش است. در این پژوهش بر اساس تئوری استثنائات و رضایتمندی، الگویی نوین برای بهبود شایان توجه میزان اعتماد و اطمینان به کشف و یادگیری از استثنائات ارائه می‌شود. ابتدا به کمک رویکرد تلفیقی پیشنهادی بر اساس تئوری استثنائات، حدود رفتار نرمال و استثنایی داده‌ها مشخص می‌شود و پس از آن با به‌کارگیری تئوری رضایتمندی، راه‌حل‌های رضایت‌بخش به‌دست می‌آید. استخراج دانش از داده‌های نرمال و استثنایی به کمک رویکرد یادگیری پایین به بالا و به‌کارگیری الگوریتم پیشنهادی RISE ارتقا یافته صورت می‌گیرد. به منظور تعیین کارایی الگوی پیشنهادی، کشف سهام استثنایی در پایگاه اطلاعاتی بازار بورس ایران هدف قرار گرفت. برتری نتایج روش پیشنهادی با نتایج به‌دست‌آمده از به‌کارگیری سایر الگوریتم‌های داده‌کاوی، روزه‌ای برای توجه به رویکرد پیشنهاد شده است. همچنین با بهره‌مندی از شاخص g -means میزان دقت این روش سنجیده شد. نتایج نشان داد روش پیشنهاد شده از قابلیت شناسایی و یادگیری از داده‌های استثنایی برخوردار است.

واژه‌های کلیدی: تئوری استثنائات، تئوری رضایتمندی، داده‌کاوی، یادگیری پایین به بالا.

۱. استادیار مدیریت صنعتی، دانشکده صنایع، دانشگاه یزد، یزد، ایران

۲. دانشجوی دکتری مهندسی صنایع، دانشکده صنایع، دانشگاه یزد، یزد، ایران

تاریخ دریافت مقاله: ۱۳۹۳/۰۸/۲۸

تاریخ پذیرش نهایی مقاله: ۱۳۹۴/۰۹/۰۶

نویسنده مسئول مقاله: الهه حاجی گل‌یزدی

E-mail: elahehajigol@gmail.com

مقدمه

یادگیری از داده‌های استثنایی، یکی از موضوعات مهم و پیچیده پژوهش است که کاربردهای فراوانی در دنیای امروز دارد. کشف و مطالعه الگوهای استثنایی در پایگاه داده، از جذابیت خاصی برخوردار است که از کاربردهای آن می‌توان به کشف ناهنجاری‌های سیستم و تجزیه و تحلیل داده‌های پزشکی اشاره کرد. استثنایی به پدیده‌های موجود در پایگاه داده اطلاق می‌شود که رفتاری متفاوت از الگوهای اصلی و مورد انتظار از خود بروز می‌دهند. اغلب در فرایند داده‌کاوی، یادگیری از داده‌های استثنایی دشوار است؛ زیرا داده‌های غیرعادی حجم کمی از مجموع داده‌های پایگاه داده را دربرمی‌گیرند. همچنین مدل‌های معمول یادگیری کارایی کافی را برای شناسایی و یادگیری از این داده‌ها ندارند؛ زیرا این مدل‌ها با فرض توازن توزیع داده‌ها عمل می‌کنند. این فرضیه سبب می‌شود الگوریتم‌های یادگیری معمول، بر اساس معیارهای هزینه خطا، دقت و توزیع دسته‌ها، در شناسایی داده‌های استثنایی عملکرد ضعیفی داشته باشند. بنابراین مطالعه و یافتن راهکارهای عملی برای غلبه بر مشکلات شناسایی و یادگیری از داده‌های استثنایی، ارزشمند خواهد بود.

مسئله کشف داده‌های استثنایی با عنوان کاوش دسته‌های استثنایی، کشف تصادفی^۱، کشف موارد جدید^۲ و مسئله کاوش استثنائات^۳ نیز شناخته می‌شود. داده‌های استثنایی از لحاظ ماهیت با داده‌های پرت بسیار تفاوت دارند. شناسایی داده‌های استثنایی به دلیل دانش نهفته‌ای که دارند، بسیار ارزشمند است. داده‌های پرت، اغلب به دلیل خطای انسانی، خطای ماشین (ابزار) یا خطا در سیستم رخ می‌دهند، در حالی که داده‌های استثنایی به دلیل انحراف طبیعی از میانگین (قد بلند)، رفتار تقلبی یا تغییر در رفتار سیستم، ایجاد می‌شوند. در واقع داده‌های استثنایی داده‌های مثبت پیش‌بینی نشده و داده‌های پرت داده‌های منفی پیش‌بینی نشده‌اند.

مبنای نظری پژوهش حاضر، به کارگیری تئوری استثنائات^۴ و تئوری رضایتمندی^۵ (سیمون ۱۹۷۴) است که به منظور مدیریت رخدادهای غیرعادی، شامل کشف حالت‌های استثنایی، استخراج دانش و یادگیری از فرایندهای استثنایی، به کار گرفته می‌شود. بر اساس تئوری استثنائات برخی از داده‌ها رفتار متفاوتی از رفتار مورد انتظار نشان می‌دهند. از آنجا که کشف استثنائات با تفسیر یافته‌های مشاهده شده در محتوای حوزه مسئله ارتباط دارد، نقطه آغاز مناسب

1. Chance discovering
2. Novelty detection
3. Exception mining
4. Abnormality Theory
5. Satisficing Theory

برای توضیح استثنائات، مدل مفهومی انواع دانشی است که رفتار عادی و غیرعادی سیستم را شرح می‌دهند.

از دید تئوری رضایتمندی، بسیاری از مسائل پیرامون ما به بهینه‌سازی نیاز ندارند و کافی است راه‌حل رضایت‌بخشی برای آنها کشف شود. رویکرد رضایتمندی در حل مسئله، همانند لبه‌های قیچی عمل می‌کند؛ زیرا فضای مسئله را به فضای کوچک‌تری که شامل راه‌حل‌های رضایت‌بخش می‌شود، تبدیل می‌کند. این رویکرد فضای مسئله را کوچک کرده و پیچیدگی مسئله را بی‌آنکه تغییر عمده‌ای در کیفیت اطلاعات ایجاد کند، به‌طور شایان توجهی کاهش می‌دهد.

در این پژوهش برآنیم چارچوبی برای تلفیق تئوری استثنائات و تئوری رضایتمندی ایجاد کنیم و از آن برای کشف استثنائات بهره ببریم. ابتدا به‌منظور شناسایی قوانین استثنایی‌شدن داده‌ها، مدل مفهومی رفتار غیرعادی سهام شکل می‌گیرد که در بردارنده آستانه‌های قابل قبول برای استثنایی‌شدن داده‌هاست. پس از شناسایی داده‌های استثنایی، قوانین به‌کمک الگوریتم RISE ارتقایافته^۱ استخراج می‌شود. به‌منظور تعیین کارایی الگوی پیشنهادی، حیطه عملی مطالعه رصد رفتار متفاوت انواع سهام برای شناسایی و تشکیل سید سهام استثنایی بر اساس تئوری استثنائات و تئوری رضایتمندی در نظر گرفته شده است. سید سهام استثنایی سهامی را پوشش می‌دهد که رفتارها و ویژگی‌های مثبت غیرمعمولی در بازار از خود نشان می‌دهد؛ به‌طوری که سبب کسب بیشترین ثروت شود. بنابراین، ساختن سیستم کارا برای انتخاب سید استثنایی از سهام موجود در بازار بورس به تفسیر دو مسئله اصلی نیاز دارد. اول؛ سیستم باید یاد بگیرد، بفهمد و به‌صورت خودکار مدلی از رفتارهای غیرمعمول و استثنایی از سهام در دست بررسی بسازد. دوم؛ سیستم باید بتواند از دانشی که یاد گرفته است استفاده کند و با نظارت بر رفتارهای فعلی سهام، هرگونه انحراف در الگوهای نرمال فعالیت را کشف کند و از آنها به‌منظور ساختن سید سهام استثنایی بهره‌مند شود.

پژوهش بدین شرح ادامه می‌یابد؛ نخست در بخش پیشینه پژوهش، سوابق شناسایی و یادگیری از داده‌های استثنایی، تئوری استثنائات و چگونگی شناسایی داده‌های استثنایی با بهره‌مندی از این تئوری بررسی می‌شود و با تشریح رویکرد رضایتمندی در کشف استثنائات ادامه می‌یابد. سپس به‌منظور استخراج قوانین پنهان در پایگاه داده، به معرفی الگوریتم RISE ارتقایافته پرداخته می‌شود. بخش روش‌شناسی پژوهش، به ارائه مدل پیشنهادی برای کشف داده‌های استثنایی و استخراج قوانین موجود در پایگاه داده می‌پردازد. سپس یافته‌های پژوهش در

1. Enhanced RISE algorithm

حیطه شناسایی و یادگیری سهام استثنایی بیان می‌شود. بخش آخر نیز به خلاصه‌ای از نتایج اختصاص دارد.

پیشینه پژوهش

مطالعه در زمینه کشف و یادگیری داده‌های استثنایی با کاوش حول مسئله یادگیری از داده‌های نامتوازن یا به عرصه وجود گذاشت. روند تاریخی پیشرفت سیستم‌های یادگیری از داده‌ها و حالت‌های نامتوازن، در تحقیقات چاولا، جاپکویچ و ایز (۲۰۰۷) و ویس (۲۰۰۴) بررسی شدند. چن، سو و ژنگ (۲۰۰۸) رویکرد داده‌کاوی را بر اساس دانه‌های اطلاعاتی^۱ برای کشف دانش از داده‌های نامتوازن به کار بردند. بورز و وندن پل (۲۰۰۹) موضوع از دست‌دادن مشتری را به‌منزله رخداد استثنایی در صنعت خدمات بررسی کردند که هدف از آن ارتقای کارایی روش‌های نمونه‌سازی با به‌کارگیری سنج‌های ارزیابی مناسب‌تر بود. کو، ژو و ژانگ (۲۰۰۸) با به‌کارگیری ابزار آماری به کاوش الگوی فعالیت‌های هدف (غیرعادی)، فعالیت‌های مغایر با هدف و فعالیت‌هایی با تأثیر معکوس پرداختند، در حالی که ساختار داده نامتوازن در نظر گرفته شد. مسئله کشف تقلب در سیستم‌های بانکی (وئوق، تقوی‌فرد و البرزی، ۱۳۹۳ و محقر، لوکاس، حسینی و منشی، ۱۳۸۹) و در صنعت بیمه (تقوی‌فرد و جعفری، ۱۳۹۴) برای یافتن رفتارهای نادر پرخطر برای سیستم مورد بررسی، از مصادیق دیگر کشف استثنائات است.

روش‌های ارائه‌شده در مطالعات پیشین، فقط برای شناسایی موردها و حالت‌های غیرعادی اعم از داده‌های غیرعادی مثبت (استثنائات) و غیرعادی منفی (داده‌های پرت) به‌کار رفته‌اند و تاکنون روشی برای تشخیص و شناسایی داده‌های استثنایی از داده‌های پرت و یادگیری از داده‌های استثنایی ارائه نشده است. پژوهش حاضر به بحث و بررسی چالش‌های پروسه کاویدن و کشف دانش از داده‌های استثنایی می‌پردازد و به‌دنبال یافتن راهکار مناسب برای یادگیری از داده‌ها و حالت‌های استثنایی به‌کمک تئوری استثنائات است.

تئوری استثنائات

رویکردهای متفاوتی در انواع زمینه‌های علمی و عملی برای استثنائات وجود دارد که از جمله آنها می‌توان به استثنائات موضوعی^۲، استثنائات آماری^۳، استثنائات ژنتیکی^۴، استثنائات بیولوژیک^۵،

1. Information granuls
2. Subjective abnormality
3. Statistical abnormality
4. Genetic abnormality
5. Biological abnormality

انحراف از استانداردهای اجتماعی^۱ و رویکردهای تئوریک اشاره کرد. نخستین بار هافمن (۱۹۷۹) تئوری استثنائات را در علم ژنتیک مطرح کرد. پس از ظهور تئوری استثنائات در علم ژنتیک، مک‌کارتی در سال ۱۹۸۰ بحث تئوری استثنائات را در استنتاج آغاز کرد. مک‌کارتی با مثال معروفی به معرفی استثنائات پرداخت: این قانون خاص را در نظر بگیرید «پرندگان به‌صورت معمولی می‌توانند پرواز کنند» اگر x پرنده‌ای خاص باشد، $AB(x)$ به این معناست که « x دسته استثنایی از جامعه پرندگانی است که نمی‌توانند بپرنند» (مانند پنگوئن). مک‌کارتی با به‌کارگیری قوانین علی و معلولی به شناسایی استثنائات پرداخت. پس از رویکرد مک‌کارتی، رویکردهای تئوریک به مسئله شناخت استثنائات مطرح شد. رویکردهای تئوریک به استثنائات بر اساس ایجاد یا توسعه تئوری توسط شخصی آغاز می‌شود. اگر برای مسئله بتوان حیطة نرمالی تعریف کرد، استثنائات شکستی در توسعه این تئوری در نظر گرفته می‌شوند.

تئوری مفهومی است که برای یافتن استثنائات به کار می‌رود و بسته به نوع دانش موجود عمل می‌کند. در واقع استثنائات با تفسیر یافته‌های مشاهده‌شده در محتوای حوزه مسئله ارتباط دارند. نقطه آغاز مناسب برای توضیح استثنائات، مدل مفهومی انواع دانشی است که در کاربردهای مختلف استثنائات اهمیت دارد. دانش ضمنی در سیستم یافتن استثنائات ممکن است بر پایه توضیحی از ساختار عادی و رفتار وظیفه‌ای سیستم یا بیان رفتار غیرعادی سیستم باشد. یافته‌های جمع‌آوری‌شده‌ای که با رفتار نرمال سیستم مطابقت دارند «یافته‌های نرمال» نام دارند و در غیر این صورت به آنها «یافته‌های غیر نرمال» می‌گویند. این تئوری‌ها بر اساس انواع دانش کسب‌شده و یافته‌های مشاهده‌شده شکل می‌گیرند؛ مانند تئوری‌های «انحراف از ساختار و رفتار نرمال» و «انطباق با رفتار غیر نرمال».

تئوری کشف استثنائات بر اساس سازگاری

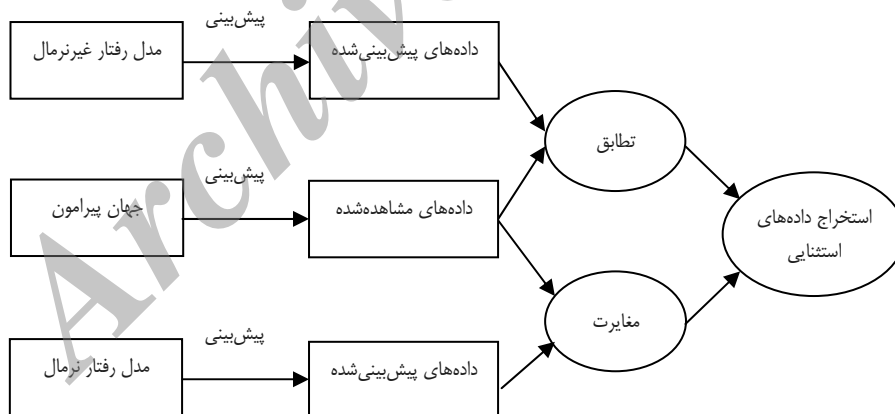
ری ریتز (۱۹۸۷) نخستین بار این تئوری را به‌منزله چارچوبی منطقی برای کشف عارضه سیستم‌های فیزیکی با استفاده از مدل ساختار و رفتار نرمال سیستم مطرح کرد. ایده اصلی تئوری یادشده، حاصل پژوهش‌های ریتز و مک‌کارتی درباره مسئله استنتاج غیریک‌نواخت^۲ است. بر اساس این تئوری، استثنائات بر مبنای مقایسه داده‌های مشاهده‌شده با ساختار و رفتار نرمال سیستم و مغایرت با آن کشف می‌شوند.

1. Violation of socially accepted standards
2. Non-monotonic Reasoning

تئوری کشف استثنائات بر اساس تطابق با رفتار غیرعادی

کشف استثنائات بر اساس تطابق با رفتار غیرعادی و با در نظر گرفتن دانش رفتارهای استثنایی سیستم عمل می‌کند؛ به نحوی که به شبیه‌سازی رفتار غیرعادی سیستم می‌پردازد. با فرض وجود عیب‌های مشخص، می‌توان برخی از حالت‌های قابل مشاهده غیرعادی را پیش‌بینی کرد. در عمل، حوزه دانش به کار برده شده در این سیستم، ارتباطات علت و معلولی است. تئوری‌های معتبر در این زمینه، تئوری‌های پوشش مجموعه‌ها^۱ و استدلال قیاسی^۲ است. جیمز رگیا، تئوری پوشش مجموعه‌ها را که بر اساس دانش علی به صورت ارتباطات ریاضی بیان می‌شود، ارائه کرد. توراسا و کنزوله نیز تئوری استدلال قیاسی را که بر مبنای منطق است مطرح کردند. پژوهش حاضر از رویکرد پوشش مجموعه‌ها بهره می‌برد.

به منظور ارتقای دقت در کشف استثنائات، چارچوب تتوریک تلفیقی جدیدی مرکب از تئوری کشف استثنائات بر اساس سازگاری و تئوری کشف استثنائات بر اساس تطابق با رفتار غیرعادی به صورت شکل ۱ پیشنهاد می‌شود. استثنائات بر مبنای میزان سازگاری داده‌های مشاهده شده با مدل رفتار غیرعادی و مغایرت داده‌های مشاهده شده با رفتار عادی سیستم کشف می‌شوند. یافته‌های جمع‌آوری شده‌ای که با رفتار عادی سیستم مغایرت دارند یا مطابق با رفتار غیرعادی سیستم‌اند «یافته‌های استثنایی» نامیده می‌شوند.



شکل ۱. الگوی پیشنهادی برای شناسایی داده‌های استثنایی با به کارگیری تئوری استثنائات

1. Set-covering theory
2. Abduction theory

رویکرد رضایتمندی در کشف استثنائات

در سال ۱۹۵۷ هربرت سیمون واژه رضایتمندی را در زمینه تصمیم‌گیری مسائل اقتصادی مطرح کرد و میر (۱۹۸۳) و وارد (۱۹۹۲) این مفهوم را توسعه دادند. پس از آن محققان زیادی (اسلات، ۱۹۸۹ و فلنر، گوت و مارتین، ۲۰۰۶) در زمینه‌های گوناگونی از این مفهوم استفاده کردند. برای مثال، پلوس (۱۹۹۳) از رویکرد رضایتمندی در علم روان‌شناسی و کانلیسک (۱۹۹۶) در علم اقتصاد بهره برد. مالاخو (۲۰۱۴) تئوری رضایتمندی را برای تجزیه و تحلیل مسائل اقتصادی خرید به کار برد. وی برای تعیین میزان اقتصادی اندازه جست‌وجو قبل از خرید، رویکرد رضایتمندی را برگزید. شوارتز و همکارانش (۲۰۰۲) معتقدند مسئله اصلی در انتخاب جواب مطلوب، میزان رضایت کسب‌شده از آن است. این تئوری بر مبنای دسترسی‌نداشتن به اطلاعات کافی یا هزینه زیاد یافتن جواب بهینه برای تصمیم‌گیری کارآمد است. رویکرد رضایتمندی^۱ راهبرد تصمیم‌گیری با پیمایش در فضای حل مسئله است که جست‌وجو در مقادیر ممکن را تا جایی ادامه می‌دهد که به آستانه‌های قابل قبول^۲ دست یابد. زمانی که دستیابی به راه‌حل بهینه هزینه‌بر باشد، رویکرد رضایتمندی در کنار تأمین جواب رضایت‌بخش بسیار سریع‌تر و راحت‌تر از روش‌های بهینه‌سازی عمل می‌کند. هر مسئله رضایتمندی به کمک تابع شاخص برای سنجش میزان رضایت کافی می‌تواند به عنوان مسئله بهینه‌سازی فرموله شود. اگر x نشان‌دهنده فضای مسئله و S نشان‌دهنده فضای رضایت‌بخش مسئله باشد، انتخاب راه‌حلی که بتواند محدودیت‌ها را ارضا کند، به صورت زیر است:

$$\text{Max} I_S(s) \quad \text{رابطه ۱}$$

$$S \in X \quad \text{رابطه ۲}$$

$$I_S(s) = \begin{cases} 1 & s \in S \\ 0 & s \notin S \end{cases} \quad \text{رابطه ۳}$$

به منظور شناخت فضای رضایت‌بخش مسئله، از تئوری استثنائات بهره می‌بریم. بر اساس چارچوب پیشنهادی، یافته‌های جمع‌آوری‌شده‌ای که مغایر با رفتار عادی سیستم یا مطابق با رفتار غیرعادی سیستم‌اند، یافته‌های استثنایی نامیده می‌شوند. بنابراین باید رفتارهای عادی و غیرعادی سیستم شناسایی شود. بدین منظور آستانه‌های قابل قبول رفتارهای عادی و غیرعادی استخراج می‌شود. پس از شناخت آستانه‌های قابل قبول برای سیستم، به جست‌وجو در فضای

1. Satisficing Solution
2. Acceptable Thresholds

حل مسئله پرداخته می‌شود. این جست‌وجو از نقطه ابتدایی آغاز می‌شود و تا زمانی که حالت‌های هدف محقق شود، در فضای مسئله ادامه می‌یابد. همزمان ظرفی برای جواب ایجاد می‌شود و زمانی که داده‌ای به حالت هدف رسید به ظرف جواب انتقال می‌یابد. پس از جست‌وجوی فضای جواب و رسیدن به معیار پایانی، ظرف جواب حاوی داده‌های غیرعادی است.

روش‌شناسی پژوهش

منطق یادگیری از استثنائات در حوزه یادگیری ماشین، مسئله شایان توجهی است. در پژوهش حاضر چارچوب جدیدی بر اساس رویکرد تلفیقی تئوری استثنائات و تئوری رضایت‌مندی برای کشف پدیده‌های استثنایی و شناسایی الگوهای رفتاری پنهان آنها ارائه شده است. تئوری استثنائات با هدف کشف استثنائات بر پایه راه‌حل‌های رضایت‌بخش به کار گرفته می‌شود و چرخه شناسایی استثنائات، یادگیری رفتار آنها و به کارگیری قوانین شناسایی شده را تکمیل می‌کند. به منظور تشکیل فضای رضایت‌بخش از نظر خبرگان بهره برده شده است. بر اساس فضای رضایت‌بخش شناسایی شده، مسئله برنامه‌ریزی صفر و یک شکل می‌گیرد و با حل مسئله، داده‌های استثنایی شناسایی می‌شوند.

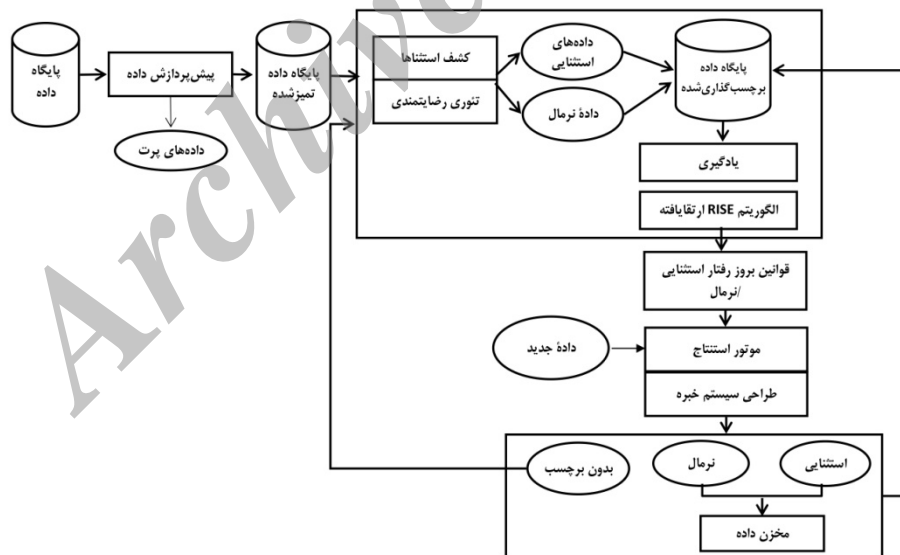
پس از شناسایی داده‌های استثنایی و تفکیک آن از داده‌های نرمال، باید دانش رفتار پدیده‌های عادی و استثنایی کشف شود. الگوریتم‌های یادگیری سنتی مانند درخت تصمیم بر پایه جست‌وجوی حریص از رویکرد یادگیری بالا به پایین پیروی می‌کنند. این الگوریتم‌ها اغلب در شناسایی قوانین عمومی موجود در پایگاه داده عملکرد بهتری دارند. بدین ترتیب که یادگیری به کمک مؤثرترین متغیر و ایجاد قانون عمومی آغاز می‌شود و با در نظر گرفتن تک‌تک متغیرهای مهم با استفاده از ساختاری که به طور طبیعی در فضای فرضیه‌ها رخ می‌دهد، صورت می‌پذیرد. این قوانین، داده‌های متعلق به دسته‌های اصلی را پوشش می‌دهد و از داده‌های استثنایی صرف نظر می‌کند. بنابراین الگوریتم‌های یادگیری سنتی، عملکرد مناسبی در رفتار استثنائات ندارند. به منظور غلبه بر کاستی‌ها و مشکلات این الگوریتم‌ها در یادگیری از استثنائات، روش جدیدی مبتنی بر رویکرد یادگیری پایین به بالا با نام الگوریتم RISE ارتقا یافته برای کشف دانش استثنائات پیشنهاد شده است. در این رویکرد، توجه و تمایل به ایجاد قوانین خاص با دقت زیاد است.

بر اساس الگوریتم RISE ارتقا یافته، ابتدا داده‌ها به دو دسته عادی و استثنایی طبقه‌بندی می‌شوند و سپس داده‌های عادی بر اساس میزان شباهتشان، به بیشترین تعداد خوشه ممکن تقسیم می‌شوند. در نتیجه، داده‌ها بر اساس بیشترین شباهت در گروه‌های مشابه قرار می‌گیرند.

فرایند خوشه‌بندی، دقت قوانین مستخرج را افزایش می‌دهد. فرایند شناسایی قوانین رفتاری داده‌های هر خوشه، با انتخاب تصادفی درصدی از داده‌ها آغاز می‌شود؛ به طوری که مطابق با هر نقطه داده انتخابی، قانونی ساخته می‌شود. برای مثال اگر نقطه داده $A = (a_1, a_2, \dots, a_n)$ به طور تصادفی از دسته عادی انتخاب شده باشد، قانون R به صورت زیر ایجاد می‌شود:

رابطه ۴) $R: IF(x_1 = a_1) \text{ and } (x_2 = a_2) \text{ and } \dots \text{ and } (x_n = a_n) \text{ Then } (x \text{ is normal})$

پس از ساخت قوانین اولیه، باید قوانین با توجه به نقاط همسایگی عمومی تر شوند. عمومی‌سازی به کمک تابع فاصله اقلیدسی صورت می‌گیرد؛ یعنی داده‌هایی که در همسایگی معینی وجود دارد، پوشش داده شوند و قوانین با حذف محدودیت روی متغیرها یا بازکردن بازه‌ها، عمومی تر شوند. مدل RISE ارتقایافته، مدل یادگیری خاص به عام برای یادگیری رفتار استثنائات است. از آنجا که استثنائات از ابتدای کار شناسایی شدند و در دسته جداگانه‌ای قرار گرفتند و سپس قوانین رفتاری آنها استخراج شد، دقت یادگیری رفتار استثنائات افزایش می‌یابد. شکل ۲ فرایند کشف و یادگیری از رفتار استثنائات را نشان می‌دهد. به منظور به‌کارگیری قوانین در کشف استثنائات جدید، سیستم خیره‌ای طراحی شد که از قوانین ایجادشده در چارچوب تئوری استثنائات، برای شناسایی استثنائات جدید بهره می‌برد.



شکل ۲. چارچوب پیشنهادی کشف و یادگیری استثنائات

در این قسمت به ارائه چارچوب پیشنهادی برای شناسایی و یادگیری از داده‌های استثنایی با بهره‌مندی از تئوری‌های استثنائات و رضایتمندی پرداخته می‌شود که در ادامه به گام‌های آن اشاره شده است:

گام اول؛ شناسایی آستانه‌های قابل قبول برای بروز رفتار استثنایی: در این گام فضای رضایت‌بخش مسئله ترسیم می‌شود. این فضا به کمک اطلاعات استخراج‌شده از نظر خبرگان شناسایی می‌شود.

گام دوم؛ تشکیل مسئله صفر و یک.

گام سوم؛ حل مسئله: در گام سوم مجموعه جواب‌های مسئله صفر و یک مشخص می‌شود. بدین منظور از ظرف جواب برای نگهداری جواب‌های رضایت‌بخش استفاده می‌شود. مجموعه جواب رضایت‌بخش، پدیده‌های استثنایی شناسایی شده را شکل می‌دهد.

گام چهارم؛ دسته‌بندی داده‌ها: ابتدا داده‌ها بر اساس برچسب عادی و استثنایی دسته‌بندی می‌شوند و سپس با خوشه‌بندی دوباره داده‌های عادی، داده‌های مشابه در دسته جداگانه‌ای قرار می‌گیرند.

گام پنجم؛ از داده‌های موجود در خوشه‌های ایجادشده گام چهارم، درصدی (α) به‌طور تصادفی انتخاب می‌شود و مطابق با هر داده در نمونه تصادفی انتخاب‌شده، قانونی ساخته می‌شود.

گام ششم؛ داده‌هایی که نزدیک‌ترین فاصله را با قانون ایجادشده دارند و تاکنون قانون دیگری آنها را پوشش نداده است، به کار گرفته می‌شوند تا با حداکثر دقت و حداقل عمومی‌سازی، قانون را عمومی‌تر کنند. این کار توسط حذف شرایط یا باز کردن بازه‌ها برای متغیرهای عددی انجام می‌گیرد. به‌منظور سنجش کارایی فرایند عمومی‌سازی در هر مرحله از شاخص g-means و support استفاده می‌شود. در صورتی تغییرات لحاظ می‌شوند که شاخص g-means بدتر نشود و قانون ایجادشده درصد مشخصی از داده‌های موجود در آن دسته را پوشش دهد.

گام هفتم؛ پس از شناسایی قوانین بروز رفتار عادی و استثنایی، الگوهای رفتاری استخراج‌شده در چارچوب پیشنهادی تئوری استثنائات به‌منظور طراحی موتور استنتاجی برای کشف استثنائات جدید، به کار گرفته می‌شوند. استثنائات جدید را می‌توان بر اساس قوانین رفتاری عادی و استثنایی شناسایی کرد. بدین ترتیب که داده‌هایی که منطبق بر قوانین رفتار عادی نیستند یا مطابق قوانین رفتار استثنایی عمل می‌کنند، به‌عنوان پدیده‌های استثنایی شناسایی می‌شوند.

جدول ۱. الگوریتم RISE ارتقا یافته

گام ایجاد قوانین	گام عمومی سازی
ES is the training set SS= select α % of ES randomly Let RS be SS For each rule R in RS N= the nearest neighborhoods E to R by $d < d^*$ let \hat{R} = Generalization (R,N) Let \hat{RS} = RS with R replaced with \hat{R} if $Acc(\hat{RS}) \geq \beta \% Acc(RS)$ Then replace RS by \hat{RS} if \hat{R} is identical to another rule in RS then delete \hat{R} from RS Until $Acc(RS) \geq \gamma$ Return RS	اگر $R = (a_1, a_2, \dots, a_m, C_R)$ یک رول و $N = (e_1, e_2, \dots, e_m, C_N)$ نمونه نزدیک باشد: function generalization (R,N) a_i is either true, $x_i = r_i$ or $r_{i,lower} \leq x_i \leq r_{i,upper}$ For attribute i-th IF $a_i = \text{True}$ then do nothing else if $e_i > r_{i,upper}$ then $e_i = r_{i,upper}$ else if $e_i < r_{i,lower}$ then $e_i = r_{i,lower}$

یافته‌های پژوهش

هدف اصلی پژوهش حاضر کشف و یادگیری رفتار استثنایی سیستم‌ها با به‌کارگیری تئوری استثنائات و تئوری رضایتمندی است. چارچوب پیشنهادی، چالش‌های پیش‌روی داده‌کاوی داده‌های استثنایی را برطرف کرده و الگوی رفتار غیرعادی سیستم را کشف می‌کند. حیطه عملی پژوهش، رصد رفتار سهام به‌منظور شناسایی سهام استثنایی و تشکیل سبد سهام فوق مثبت در نظر گرفته شده است.

مطالعات پیشین در حوزه شناسایی سهام استثنایی بر این باورند که سهام استثنایی، همان سهام با بازده زیاد است، اما در پژوهش حاضر به سهامی استثنایی گفته می‌شود که برای سرمایه‌گذار منفعت استثنایی به همراه داشته باشد. از مهم‌ترین مراحل اجرای پروژه، شناسایی و انتخاب متغیرهای دخیل در استثنایی شدن سهام است. متغیرهای انتخابی باید نسبت به استثنائات حساس باشند. به‌منظور اندازه‌گیری منفعت کسب‌شده از سرمایه‌گذاری، بر اساس مطالعات صورت گرفته و نظر خبرگان، متغیرهای تأثیرگذار در تشخیص سهام استثنایی استخراج شدند. با اجرای آزمون آماری t ، از بین متغیرهای منتخب، متغیرهای سود هر سهم، سهام جایزه و افزایش سرمایه شرکت برگزیده شدند. این متغیرها تفاوت معناداری را بین سهام عادی و استثنایی ایجاد می‌کنند. سرمایه‌گذاری استثنایی با رشد استثنایی ثروت برای سرمایه‌گذار همراه است. این رشد می‌تواند از طریق کسب سود استثنایی ایجاد شود. همچنین صدور سهام جایزه با حجم زیاد، سبب چند برابر شدن ثروت سهامدار می‌شود. اطلاعات مالی در این سه شاخص برای شرکت‌های فعال در بازار بورس ایران در ۱۳۲۷ رکورد گردآوری شده است.

در گام بعد به دلیل اهمیت پاکسازی ورودی‌های مدل و تأثیر آلودگی داده‌ها بر کاهش عملکرد الگوریتم‌های داده‌کاوی، داده‌ها پیش‌پردازش می‌شوند. بدین ترتیب، اطلاعات سهام از طریق میانگین و انحراف معیار مجموعه داده‌های گردآوری شده با به‌کارگیری مقدار Z ، نرمالیز شدند. با توجه به رابطه مستقیم متغیرهای منتخب با کسب سود، داده‌هایی که در فاصله بیشتر از 3σ - میانگین قرار دارند، داده‌های پرت محسوب شده و از محاسبات خارج می‌شوند.

به منظور تشکیل پروفایلی از سهام یادشده و کشف استثنائات، باید از مشخصات سهام مجموعه‌ای ایجاد کرد که امکان نمایش داشته باشد. فرض کنید $X_{i,j}$ نشان‌دهنده سهم i ام در مشخصه j باشد، در حالی که $i = \{1, 2, \dots, n\}$ معرف n سهم بررسی شده و $j = \{1, 2, \dots, m\}$ متغیرهای در نظر گرفته شده برای داده‌کاوی است. در این صورت M نشان‌دهنده پروفایل سهام در دست بررسی است.

$$M = \begin{bmatrix} X_{1,1} & X_{1,2} & \dots & X_{1,m} \\ X_{2,1} & X_{2,2} & \dots & X_{2,m} \\ \vdots & \vdots & \dots & \vdots \\ X_{n,1} & X_{n,2} & \dots & X_{n,m} \end{bmatrix}$$

فضای رضایت‌بخش مسئله با به‌کارگیری تئوری استثنائات ترسیم می‌شود. بر این اساس یافته‌های مشاهده شده‌ای که مغایر با رفتار عادی سیستم یا مطابق با رفتار غیرعادی سیستم‌اند «یافته‌های استثنایی» نامیده می‌شوند. بنابراین رفتار عادی و غیرعادی سهام باید شناخته شود. بدین منظور باید آستانه‌های قابل قبولی برای بروز رفتار غیرعادی تعیین کرد. آستانه بروز رفتار استثنایی بر اساس عملکرد تک‌تک متغیرها مشخص می‌شود، به این ترتیب که حد قابل قبول برای بروز رفتار استثنایی، $3\sigma +$ از میانگین هر متغیر است. جدول ۲ اطلاعات سهام بررسی شده را نشان می‌دهد.

جدول ۲. مشخصه سهام بررسی شده

مشخصه	سود هر سهم	تعداد سهام جایزه	افزایش سرمایه شرکت
میانگین	۸/۵۲	۱۴/۱۶	۲۲/۳۷
انحراف معیار	۹۹/۹۸	۶۴/۳۳	۲۷۶/۴۷
حداقل	.	.	.
حداکثر	۱۰۰۹۶	۹۹۰۰	۹۰۰
میانگین + ۳ × انحراف معیار	۳۵۱۵	۲۰۷	۸۵۲

مسئله مطرح‌شده به پشتوانه تئوری رضایتمندی و با بهره‌مندی از تابع شاخص برای سنجش میزان کافی رضایت‌بخشی، به صورت مسئله برنامه‌ریزی صفر و یک فرموله می‌شود. I_1 ، I_2 و I_3 متغیرهای صفر و یک برای ترسیم فضای رضایت‌بخش ایجادشده از آستانه قابل قبول در مسئله‌اند. هدف، حداکثر شدن مجموع سه شاخص روی مجموعه داده در دست بررسی است. اگر EPS نشان‌دهنده سود هر سهم، BS و CA به ترتیب معرف تعداد سهام جایزه و میزان افزایش سرمایه شرکت باشد، محدودیت‌های ۶ تا ۸ با توجه به آستانه‌های قابل قبول (جدول ۱) برای بروز رفتار استثنایی ایجاد می‌شوند. سهامی استثنایی است که دست کم یکی از این محدودیت‌های ۶ تا ۸ را ارضا کند (رابطه ۹).

$$\text{Max } I_1 + I_2 + I_3 \quad \text{رابطه ۵}$$

$$I_1(3515 - \text{EPS}) \leq 0 \quad \text{رابطه ۶}$$

$$I_2(207 - \text{BS}) \leq 0 \quad \text{رابطه ۷}$$

$$I_3(852 - \text{CA}) \leq 0 \quad \text{رابطه ۸}$$

$$I_1 + I_2 + I_3 \geq 1 \quad \text{رابطه ۹}$$

$$I_1 \text{ یا } I_2 \text{ و } I_3 = 0 \quad \text{رابطه ۱۰}$$

راهبرد تصمیم‌گیری بر پایه تئوری رضایتمندی با پیمایش در فضای حل مسئله، جست‌وجو در مقادیر ممکن را تا جایی ادامه می‌دهد که به آستانه‌های قابل قبول دست یابد. با جست‌وجو در فضای حل مسئله ۳۱ شرکت به‌عنوان سهام غیرعادی برگزیده شدند. جدول ۳ اطلاعات تعدادی از این سهام را نشان می‌دهد.

جدول ۳. سهام استثنایی کشف‌شده از طریق روش پیشنهادی

نام شرکت	سود سهم	سرمایه شرکت	سهام جایزه	نام شرکت	سود سهم	افزایش سرمایه	سهام جایزه
پتروشیمی پردیس	۱۰۰۹۶	.	.	سالمین	.	.	۹۰۰
ارتباطات سیار ایران	۹۰۲۰	.	.	بیمه دانا	.	.	۸۶۸
سیمان قائن	۸۰۰۰	.	.	قند اصفهان	.	.	۷۱۲
پالایش نفت تهران	۸۰۰۰	.	.	هنکل پال وش	.	.	۵۱۷
صنایع شیمیایی ایران	۸۰۰۰	.	.	بیمه البرز	.	.	۵۰۰
پتروشیمی خارک	۷۵۰۰	.	.	داروسازی الحاوی	.	.	۵۰۰
پتروشیمی ایرانیان	.	۹۹۰۰	.	تجهیزات سنگین	.	.	۴۸۸

پس از شناسایی سهام غیرعادی، گام بعد یادگیری رفتار استثنایی سهام و کسب توانایی برای پیش‌بینی سهام استثنایی است. به همین منظور از رویکرد یادگیری پایین به بالا بهره برده می‌شود. ابتدا داده‌های موجود در پایگاه داده بر اساس برجسب عادی یا غیرعادی دسته‌بندی می‌شوند و پس از آن، داده‌های متعلق به دسته عادی با اجرای روش k-means خوشه‌بندی خواهند شد. این نوع خوشه‌بندی به دلیل راهبردی که برای جداسازی داده‌ها و امکان کنترل تعداد خوشه‌ها دارد، انتخاب شده است و تلاش می‌کند فضای مسئله را به گونه‌ای دسته‌بندی کند که داده‌های هر دسته ضمن داشتن کمترین فاصله و بیشترین شباهت به یکدیگر با دسته‌های دیگر بیشترین فاصله را داشته باشند. بنابراین سهام در چهار دسته شامل یک خوشه از داده‌های غیرعادی و سه خوشه از داده‌های عادی قرار گرفتند. خوشه‌بندی، داده‌های به نسبت مشابه را در یک گروه قرار می‌دهد و سبب افزایش دقت قوانین استخراج‌شده از آن خوشه می‌شود. اطلاعات خوشه‌ها در جدول ۴ خلاصه شده است.

جدول ۴. اطلاعات خوشه‌ها

خوشه	دسته	تعداد	میانگین			انحراف معیار		
			سود سهام	سهام جایزه	افزایش سرمايه	سود سهام	سهام جایزه	افزایش سرمايه
۱	غیرعادی	۳۱	۳۴۴۲	۲۱۹/۴	۲۹۱	۳۴۷۳/۲	۲۵۷/۹۷	۱۶۹۷/۸۳
۲	عادی	۱۱۰۵	۲۶۰	۲/۹	۱۶/۲	۲۸۱	۱۱	۵۸,۴
۳	عادی	۱۳۸	۲۰۷۵/۶	-۰/۹۱	۵/۱۴	۷۸۲/۷	۸/۷۷	۳۱
۴	عادی	۵۳	۰	۱۴۱/۵۰	۲۴/۳	۰	۵۲/۵	۶۸/۴۳

از سهام موجود در هر خوشه درصدی ($\alpha\%$) به‌طور تصادفی انتخاب‌شده و به ازای هر نقطه داده قانونی منطبق بر آن ساخته شده است. شایان ذکر است، بسته به حجم داده‌های هر خوشه، مقادیر متفاوتی را می‌توان برای α در خوشه‌های مختلف لحاظ کرد. جدول ۵ تأثیر تغییر در مقدار α را بر دقت پیش‌بینی و تعداد قانون استخراج‌شده نشان می‌دهد. بر اساس بررسی‌های صورت‌گرفته، بهترین مقدار برای α در خوشه‌های ۱، ۲، ۳ و ۴ به ترتیب برابر با ۱۵ درصد، ۲ درصد، ۲/۵ درصد و ۵ درصد است. داده‌های خوشه ۱ متعلق به سهام استثنایی است. از آنجا که سهام استثنایی حجم کمی از داده‌ها (۲/۳ درصد از حجم داده) را به خود اختصاص داده است، به قانون‌های اولیه بیشتری (۱۵ درصد معادل ۵ قانون) برای پوشش تمام سهام نیاز داریم. در این

حالت، دقت پیش‌بینی به حداکثر رسیده است و مسئله از لحاظ پیچیدگی و زمان حل به کمترین میزان می‌رسد.

جدول ۵. تعیین تعداد بهینه قوانین مستخرج

					خوشه
٪۱۵	٪۱۲	٪۱۰	٪۵	٪۱۰	۱
٪۲	٪۲	٪۵	٪۷	٪۱۰	۲
٪۲٫۵	٪۵	٪۵	٪۷	٪۱۰	۳
٪۷	٪۷	٪۵	٪۵	٪۱۰	۴
٪۱۰۰	٪۹۶	٪۸۸	٪۷۸	٪۷۵	دقت پیش‌بینی
۳۱	۳۴	۶۶	۹۰	۱۳۴	تعداد قانون استخراجی

در مرحله بعد باید قوانین بر اساس داده‌های همسایه عمومی تر شوند؛ یعنی قوانین از تعداد محدودی از داده‌ها به تمام داده‌های موجود در پایگاه داده تسری یابد. به کمک تابع فاصله اقلیدسی، نقاط داده در همسایگی قوانین اولیه تعیین می‌شود. سهامی که نزدیک‌ترین فاصله را تا قانون ایجادشده دارند و تا به حال هیچ‌یک از قوانین آنها را پوشش نداده‌اند، به کار گرفته می‌شوند. بدین ترتیب با حداکثر دقت و حداقل عمومی‌سازی در قوانین اولیه، قوانین جدید ایجاد می‌شود. این روش از طریق حذف شرایط یا بازکردن بازه‌ها برای متغیرهای عددی ضمن حفظ میزان دقت از پیش تعیین شده برای قانون جدید، اجرا می‌شود. چنانچه اندازه فاصله انتخابی کم باشد، تعداد تکرارها و زمان عمومی‌سازی افزایش می‌یابد و در صورتی که فاصله زیاد باشد، از دقت قوانین کاسته می‌شود. با در نظر گرفتن $k = 0/3$ ، پنج قانون برای تشخیص داده‌های استثنایی استخراج می‌شود که با به‌کارگیری قوانین همپوشانی، این پنج قانون در سه قانون زیر خلاصه خواهد شد:

- اگر سود هر سهم بیشتر از ۵۰۰۰ باشد، سهم غیرعادی است؛
- اگر تعداد سهام جایزه بیشتر از ۳۰۰ باشد، سهم غیرعادی است؛
- اگر افزایش سرمایه شرکت بیشتر از ۹۵۰۰ باشد، سهم غیرعادی است.

با توجه به قوانین مستخرج از داده‌های استثنایی، درمی‌یابیم افزایش سرمایه شرکت نسبت به متغیر سود هر سهم و تعداد سهام جایزه، اهمیت کمتری در بروز رفتار استثنایی سهام دارد. پس از استخراج قوانین حاکم بر رفتار عادی و استثنایی سهام، سیستم خبره‌ای طراحی شد که با ورود داده متعلق به سهام جدید، توانایی شناسایی سهام استثنایی را دارد. در مواجهه با داده جدید به دو صورت داده‌های استثنایی تشخیص داده می‌شود: ۱. سهامی که رفتارشان با هیچ‌یک از الگوهای

عادی همخوانی ندارد و ۲. سهامی که رفتارشان با الگوی استثنایی مطابقت دارد. پس از تشخیص برچسب داده جدید، این داده بر پایگاه داده اصلی افزوده می شود و در آینده برای شناسایی داده های استثنایی جدید به کار می رود.

به منظور سنجش صحت عملکرد مدل پیشنهاد شده برای کشف و یادگیری سهام استثنایی، آزمونی از این مدل روی داده های سه ماهه آخر سال ۱۳۹۳ به اجرا درآمد. همچنین از خبرگان درخواست شد سهام استثنایی این دوره را شناسایی کنند. نتایج مقایسه خروجی مدل حاضر و نظر خبرگان بازار بورس، نشان داد دانش استخراج شده از سهام استثنایی با نظر خبرگان مطابقت دارد.

جدول ۶. سهام استثنایی شناسایی شده روش پیشنهادی و نظر خبرگان

ردیف	نام سهم	سود هر سهم	درصد افزایش سرمایه جایزه
۱	شرکت پالایش نفت تهران	.	۶۷۲/۲
۲	صنایع تولیدی اشتاد ایران (سهامی عام)	.	۴۰۱/۴
۳	نئوپان ۲۲ بهمن	.	۳۰۰
۴	گلوکوزان	۵/۹۷۰	.

نتیجه گیری و پیشنهادها

کشف و پیش بینی رفتارهای استثنایی سیستم ها، مسئله ای چالش انگیز است. هدف از پژوهش حاضر، طراحی چارچوبی کارا برای مدیریت رخدادهای غیرعادی، شامل کشف داده ها و حالت های استثنایی از بین انبوه داده های موجود در پایگاه داده، استخراج دانش و یادگیری از فرایندهای استثنایی با به کارگیری تئوری های استثنائات و رضایتمندی است. از روش پیشنهادی به منظور رصد رفتار سهام مختلف و شناسایی سهام استثنایی بهره برده شده است. بدین ترتیب که با به کارگیری تئوری استثنائات حدود قابل قبول برای بروز رفتار استثنایی و رفتار عادی سهام شناسایی شد و تئوری رضایتمندی به منظور کشف سهام استثنایی به کار رفت. پس از تفکیک داده های غیرعادی از عادی، دانش پنهان سهام غیرعادی و عادی با اجرای رویکرد یادگیری پایین به بالا بر مبنای الگوریتم RISE ارتقایافته استخراج شد. بر اساس روش پیشنهادی به بررسی عملکرد ۱۳۲۷ سهم پرداخته شد که فقط ۲/۳ درصد از آنها رفتار فوق تصور خوبی از خود بروز دادند. از مجموع ۳۱ سهم غیرعادی کشف شده، پنج قانون به دست آمد و این پنج قانون در سه قانون خلاصه شد و به منظور پیش بینی رفتار سهام جدید به کار رفت.

از قوت های پژوهش حاضر، می توان به دیدگاه حاکم بر تحقیق در تعریف سهام استثنایی و به کارگیری ابزار کارآمد برای کشف آنها اشاره کرد. هدف ما حداکثرسازی ثروت سهامداران با

شناسایی سهام استثنایی بر مبنای بروز رفتار فراتر از انتظار مثبت و تشکیل پرتفوی استثنایی بود؛ در حالی که تحقیقات مشابه تنها کسب بازده بالا را معیاری برای استثنایی‌شدن سهام دانسته و برای شناسایی و تشخیص آن به اجرای آزمون‌های آماری اقدام کردند. همچنین روش‌های ارائه‌شده در تحقیقات پیشین فقط برای شناسایی موارد و حالت‌های غیرعادی اعم از داده‌های غیرعادی مثبت (استثنائات) و غیرعادی منفی (داده‌های پرت) به‌کار رفته است؛ درحالی‌که روش پیشنهادی فقط به‌منظور تشخیص و شناسایی داده‌های استثنایی (داده‌های غیرعادی مثبت) ارائه شده است.

در پژوهش‌های بعدی می‌توان مجموعه متغیرهای بیشتری که بروز رفتار استثنایی سهام را بیشتر توجیه می‌کند، مانند سود تقسیمی، حق تقدم، درجه نقدشوندگی، نوسان‌های قیمت و... در نظر گرفت. همچنین پیشنهاد می‌شود به‌منظور افزایش دقت تشخیص آستانه رفتار استثنایی سهام از ریاضیات فازی استفاده شود.

References

- Alavije, M.R., Askari, S.H. & Paraste, S. (2015). Intelligent Online Store: User Behavior Analysis based Recommender System. *Journal of Information Technology Management*, 7(2): 385-406. (in Persian)
- Albanis, G. & Batchelor, R. (2007). Combining heterogeneous classifiers for stock selection. *Intelligent Systems in Accounting, Finance and Management*, 15 (1-2): 1-27.
- Barber, B.M. & Lyon, J.D. (1997). Detecting long-run abnormal stock returns: The empirical power and specification of test statistics. *Journal of Financial Economics*, 43(3): 341-372.
- Boshes, J. (2009). *Change point detection in cyber attack data*. PHD theses, Arizona state university.
- Burez, J. & Van den Poel, D. (2009). Handling class imbalance in customer churn prediction. *Expert Systems with Applications*, 36(3): 4626-4636.
- Califf, M.E. & Mooney, R.J. (2003). Bottom-Up Relational Learning of Pattern Matching Rules for Information Extraction. *Journal of Machine Learning Research*, 4:177-210.
- Cao, L., Zhao, Y. & Zhang, C. (2008). Mining Impact-Targeted Activity Patterns in Imbalanced Data. *IEEE Transactions on knowledge and data engineering*, 20(8): 1053 – 1066.

- Chang, T. S. (2011). A comparative study of artificial neural networks, and decision trees for digital game content stocks price prediction. *Expert Systems with Applications*, 38 (12): 14846–14851.
- Chawla, N.V., Japkowicz, N. & Icz, A.K. (2004). Editorial: Special Issue on Learning from Imbalanced Data Sets. *Sigkdd Explorations*, 6(1):1–6.
- Chen, M. C., Chen, L. S., Hsu, C.C. & Zeng, W.R. (2008). An information granulation based data mining approach for classifying imbalanced data. *Information Sciences*, 178(16): 3214-3227.
- Chen, S. (2011). *Adaptive Learning from data flow and imbalanced data*. PhD Thesis, Stevens institute of technology, Hoboken.
- Clark, E. (2014). Exploiting stochastic dominance to generate abnormal stock returns. *Journal of Financial Markets*, 20(1): 20-38.
- Conlisk, J. (1996). Why bounded rationality? *Journal of Economic Literature*, 34(2): 669-694.
- Fellner, G., Guth, W. & Martin, E. (2006). Satisficing or Optimizing? An Experimental Study, Max-Planck-Institute for Ökonomik. *Papers on Strategic Interaction*, www.econbiz.de/Record/satisficing-or-optimizing-an-experimental-study-fellner-gerlinde/10004870567.
- Galván, J.R., Elices, A., Muñoz, A., Czernichow, T. & Sanz-Bobi, M.A. (1998). System for detection of abnormalities and fraud in customer consumption. *12th Conference on the Electric Power Supply Industry*, Thailand.
- García, V., Sánchez, J.S. & Mollineda, R.A. (2012). On the effectiveness of preprocessing methods when dealing with different levels of class imbalance. *Knowledge-Based Systems*, 25(1): 13-21.
- Gigerenzer, G. (2010). Moral Satisficing: Rethinking Moral Behavior as Bounded Rationality. *Topics in Cognitive Science*, 2(3): 528-554.
- Gong, R.S. (2010). *A Segmentation and Re-balancing Approach for Classification of Imbalanced Data*. PHD theses, University of Cincinnati.
- Hu, D. H., Zhang, X. X., Yin, J., Zheng, V. W. & Yang Q. (2009). Abnormal Activity Recognition Based on HDP-HMM Models. *the Twenty-First International Joint Conference on Artificial Intelligence*. Morgan Kaufmann Publishers Inc. San Francisco, CA, USA.
- Huang, K. Y. & Jane, C. J. (2009). A hybrid model for stock market forecasting and portfolio selection based on ARX, grey system and RS theories. *Expert Systems with Applications*, 36 (3): 5387-5392.

- Joshi, M.V. (2002). *Learning Classifier Models for Predicting Rare Phenomena*. PhD thesis, University of Minnesota, USA.
- Kershaw, D. (2010). *Anomaly-based network intrusion detection using outlier subspace analysis approach*. PhD Thesis, Dalhousie University Halifax.
- Kim, Y. & Sohn, S.Y. (2012). Stock fraud detection using peer group analysis. *Expert Systems with Applications*, 39(10): 8986–8992.
- Kou, Y. (2006). *Abnormal Pattern Recognition in Spatial Data*. PHD theses, Faculty of Virginia Polytechnic Institute and State University.
- Malakhov, S. (2014). Satisficing Decision Procedure and Optimal Consumption-Leisure Choice. *International Journal of Social Science Research*, 2(2): 138-151.
- McCarthy, J. (1986). Applications of circumscription to formalizing common-sense knowledge. *Artificial Intelligence*, 28(1): 89-116.
- Mohaghar, A., Lucas, C., Hoseini, F. & Monshi, A. A. (2009). Use of business intelligence as a strategic information technology in banking: fraud discovery & detection. *Journal of Information Technology Management*, 1(1): 105-120. (in Persian)
- Olson, D. & Mossman, C. (2003). Neural network forecasts of Canadian stock returns using accounting ratios. *International Journal of Forecasting*, 19(3): 453-465.
- Reiter, R. (1987). A Theory of Diagnosis from First Principles. *Artificial Intelligence*, 32(1): 57-95.
- Schwartz, B., Ward, A., Monterosso, J., Lyubomirsky, S., White, K. & Lehman, D. (2002). Maximizing Versus Satisficing: Happiness is a Matter of Choice. *Journal of Personality and Social Psychology*, 83 (5): 1178-1197.
- Simon, H.A. (1997). *Models of bounded rationality, Empirically grounded economic reason*. Vol. 3. Cambridge, Mass. MIT Press.
- Slote, M. (1989). *Beyond Optimizing: A Study of Rational Choice*, Cambridge, Mass. Harvard University Press.
- Taghavifard, M.T. & Jafari, Z. (2015). Fraud Detection Using a Fuzzy Expert System In Motor Insurance. *Journal of IT Management*, 7(2): 239-258. (in Persian)
- Tezel, S. K. & Latecki, L. J. (2009). Improving SVM Classification on Imbalanced Data Sets in Distance Spaces. *Ninth IEEE International Conference on*. 6-9 Dec. DOI:10.1109/ICDM.2009.59.

- Vosough, M., Taghavifard, M.T. & Alborzi, M. (2015). Bank card fraud detection using artificial neural network. *Journal of Information Technology Management*, 6(4): 105-120. (in Persian)
- Ward, D. (1992). The role of satisficing in foraging theory. *Oikos*, 63 (2): 312–317.
- Weiss, G. (2004). Mining with rarity: A unifying framework. *SIGKDD Explorations Special Issue on Learning from Imbalanced Datasets*, 6(1):7–19.
- Xiang, T. & Gong, S. (2008). Video Behavior Profiling for Anomaly Detection. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 30(5): 893–908.
- Zhang, J. & Mani, I. (2003). *KNN approach to unbalanced data distributions: A case study involving information extraction*. ICML' 2003 Workshop on Learning from Imbalanced Datasets.
- Zhu, P. & Hu, Q. (2013). Rule extraction from support vector machines based on consistent region covering reduction. *Knowledge-Based Systems*, 42(1): 1-8.

Archive of SID