

## روشهای مجموعه های راف و الگوریتم های ژنتیک در سیستم ترکیبی هوشمند خرید و فروش برای کشف قوانین خرید و فروش بازارهای آتی

محمد رضا وطن پرست<sup>۱</sup>

عباس بابایی<sup>۲</sup>

شعبان محمدی<sup>۳</sup>

تاریخ پذیرش: ۹۷/۰۴/۲۴

تاریخ دریافت: ۹۷/۰۸/۲۹

### چکیده

کشف قوانین هوشمند خرید و فروش تکنیکال از داده های پیچیده و غیرخطی بازار سهام و متعاقب آن توسعه سیستم های تصمیم یا خرید و فروش کار دشواری است. هدف پژوهش حاضر توسعه سیستم ترکیبی هوشمند خرید و فروش جهت کشف قوانین خرید و فروش تکنیکال از طریق تحلیل مجموعه راف و الگوریتم ژنتیک است. مجموعه داده های مورد استفاده شامل ۳۰ دقیقه باز، بالا، پائین، بسته و حجم قراردادهای آتی شاخص مرکب قیمت گذاری سهام بورس اوراق بهادار در بازه زمانی ۱۳۹۰ تا ۱۳۹۶ بود. به این منظور توصیه می گردد هنگام کشف قوانین خرید و فروش تکنیکال برای بازارهای آینده و حل مسائل بهینه سازی، گسسته سازی و کاهش داده ها، تحلیل مجموعه راف و در نهایت برای اتخاذ تصمیمات بهینه خرید و فروش رویکرد الگوریتم ژنتیک مورد استفاده قرار گیرد. برای آزمون مدل پیشنهادی و مقایسه آن با رویکردهای متناظر، تصادفی، همبستگی و رویکردهای الگوریتم ژنتیک مداخلاتی طراحی شد. همچنین، این مداخلات جامع، بسیاری از موضوعات سیستم خرید و فروش موجود، کاربرد روش پنجره لغزان، تعداد قوانین خرید و فروش و مدت دوره آموزشی را در برداشت. برای ارزیابی سیستم ترکیبی هوشمند مداخلاتی روی داده های تاریخی شاخص مرکب قیمت گذاری سهام بورس اوراق بهادار تهران انجام شد. به طور خاص، تحلیل عملکرد خرید و فروش بر طبق مجموعه های مقرات تصمیم و حجم دوره آموزش برای کشف قوانین خرید و فروش دوره آزمون انجام شد. یافته ها نشان داد مدل پیشنهادی در مقایسه با مدل معیار از نظر میانگین بازدهی و مقیاس ریسک تعدیل شده عملکرد بهتری داشته است.

**واژه های کلیدی:** سیستم خرید و فروش ترکیبی هوشمند، تحلیل تکنیکال، مجموعه های راف، الگوریتم ژنتیک.

۱- استادیار گروه حسابداری، واحد رشت، دانشگاه آزاد اسلامی، رشت، ایران. [vatanparast@iaurasht.ac.ir](mailto:vatanparast@iaurasht.ac.ir)

۲- دانشجوی دکتری مهندسی مالی، واحد رشت، دانشگاه آزاد اسلامی، رشت، ایران. [abbasbabaie9@gmail.com](mailto:abbasbabaie9@gmail.com)

۳- کارشناسی ارشد حسابداری، دانشکده شهید رجایی، دانشگاه فنی و حرفه ای استان خراسان، ایران (نویسنده مسئول) [Shaban1362@gmail.com](mailto:Shaban1362@gmail.com)

## ۱- مقدمه

فروش در زمان بندی بازار و تولید قوانین خرید و فروش - به شدت مورد توجه قرار گرفته است (کیم و انکه، ۲۰۱۶). با وجود آنکه با استفاده از تحلیل مجموعه راف می توان به خوبی قوانین تصمیم را از مجموعه داده های معینی استخراج نمود؛ اما باید بخاطر داشت برای تولید قوانین تصمیم مبتنی بر شاخص های تکنیکال (یعنی مقادیر پیوسته) انجام فرایندهای گسسته سازی داده ها و حداقل کاهش ضروری است (ماشکوف و همکاران، ۲۰۰۸؛ پالواک، ۱۹۹۷؛ ژونگ، ۲۰۰۱). با این حال، فرایندهای مذکور زمان بر بوده و با کاهش بعد ارتباط دارند. توجه به گسسته سازی بهینه یا انتخاب نقطه برش در تبدیل مقادیر پیوسته به مقادیر گسسته متناسب با نقطه برش های (نقطه برش) گسسته سازی - حداقل کاهش زیرمجموعه ویژگی های و طبقه بندی حداکثر تعداد اشیا - ضروری است (کیم و هان، ۲۰۰۰؛ جیا و همکاران، ۲۰۱۶؛ ماشکوف و همکاران، ۲۰۰۸؛ رامیرز و همکاران، ۲۰۱۶؛ جانوس و ازلساک، ۲۰۱۲). در این مطالعه الگوریتم ژنتیک برای یافتن نقطه برش های گسسته سازی برای کشف قوانین خرید و فروش بهینه و شبه بهینه به کار رفت تا همزمان هر دو مسئله برطرف شوند. با وجود آنکه الگوریتم ژنتیک برای مسائل زمان بر گزینه مناسبی نیست؛ اما به کمک آن می توان راه حل شبه بهینه ای پیدا کرد؛ بنابراین، در این مطالعه منظور از بهترین قانون خرید و فروش قانونی با بیشترین مقدار قابلیت و قانون شبه بهینه نزدیکترین مقدار بعد از آن است. این مطالعه با هدف ادغام الگوریتم ژنتیک در فرایندهای گسسته سازی و کاهش حجم داده تحلیل مجموعه راف و کشف قوانین خرید و فروش بهینه و شبه بهینه و اتخاذ تصمیمات بهینه خرید و فروش انجام شده است. در این مطالعه عوامل مهمی نظیر پنجره لغزان (با یا بدون مجموعه داده معتبر)، تابع قابلیت و حجم داده های آموزشی مورد توجه قرار گرفت. تحلیل مجموعه راف و الگوریتم ژنتیک برای کشف قوانین خرید و فروش سیستم خرید و فروش هوشمند ترکیبی در مطالعات معدودی مورد استفاده قرار گرفته

تاکنون مطالعات متعددی در ارتباط با کشف قوانین بهینه خرید و فروش مبتنی بر شاخص های تکنیکال بازار سهام با استفاده از رویکردهای مبتنی بر داده نظیر هوش مصنوعی، یادگیری ماشین، بازشناسی الگو، رویکردهای داده کاوی یا ترکیبی از این گونه روش های محاسباتی انجام شده است (چیانگو همکاران، ۲۰۱۶؛ هو همکاران، ۲۰۱۵؛ موسوی و همکاران، ۲۰۱۴؛ ویلس وانکه، ۲۰۱۵؛ ویاسیوقلو، ۲۰۱۰؛ چن و همکاران، ۲۰۱۶؛ هو و همکاران، ۲۰۱۵؛ وانگ و همکاران، ۲۰۱۴). اخیراً پژوهشگران روی توسعه سیستم های خرید و فروش ترکیبی هوشمند متمرکز شده اند که با استفاده از مزایای روش های فوق - الذکر باعث هم افزایی بیشتر می شوند. این در حالی است که درک قوانین خرید و فروش حاصل از برخی از روش های فوق برای سرمایه گذاران آماتور کار ساده ای نیست؛ زیرا تفسیر قوانین خرید و فروش با استفاده از داده کاوی با مدل های جعبه سیاه نظیر شبکه های عصبی مصنوعی یا ماشین بردار پشتیبان دشوار است. این مدل ها به سبب عدم شناخت ماهیت تعاملات بین شاخص های تکنیکال و مسیر بازار نمی توانند همواره راهنمای مناسبی برای رفتار واقعی سرمایه گذاران باشند (چاوارناکول و همکاران، ۲۰۰۹؛ مهدیف و انکه، ۲۰۱۴؛ ویلس وانکه، ۲۰۱۵؛ ژانگ و همکاران، ۲۰۱۵؛ لای و همکاران، ۲۰۰۹). تئوری مجموعه راف روش مناسبی برای کشف دانش احتمالی از داده های غیرقطعی، ناقص و غیردقیق از جمله داده های بازار سهام است (هو و همکاران، ۲۰۱۶؛ جینگ و همکاران، ۲۰۱۶؛ پاولاک، ۱۹۸۲). سیستم های خرید و فروش مبتنی بر شاخص های تکنیکال و تحلیل مجموعه راف محدودیت مدل های جعبه سیاه را به حداقل می رساند؛ زیرا به کمک قوانین "اگر-آنگاه" باعث می شود تا قوانین برای سرمایه گذاران شفاف تر، صریح تر و کاربردی تر شود. تحلیل مجموعه راف بخاطر داشتن مزایای فراوان در تحلیل داده های مالی - تحلیل بازار سهام، شناسایی سیگنال های خرید و

است. در این مطالعه برای فرایندهای تحلیل مجموعه راف برای بررسی کاهش حجم داده و به طور همزمان یافتن نقطه برش های بهینه یا نزدیک به بهینه برای گسسته سازی یک الگوریتم ژنتیک به کار رفته است. مهم تر از همه اینکه با استفاده از سازوکار کشف قوانین می توان به شکل خودکار به کشف قوانین پرداخت و قوانین را به شکل کمی و سهل الفهم درآورد تا سرمایه گذاران بتوانند اطلاعات بازارهای غیرقطعی را درک کنند. این امر سبب خروج مدل از جعبه سیاه به موضوعاتی کاملا شفاف و افزایش اعتماد سرمایه گذاران به تصمیمات و یافته های متعاقب آن می شود. برای ارزیابی سیستم خرید و فروش هوشمند آزمون هایی روی داده های گذشته نگر شاخص مرکب قیمت گذاری سهام بورس اوراق بهادار بازارهای آتی انجام شد. تئوری مجموعه های راف دارای مزایای متعددی است که مهمترین مزیت آن در تحلیل داده ها این است که به هیچگونه اطلاعات اضافی اولیه در مورد داده ها نیاز ندارد.

## ۲- مبانی نظری

### ۲-۱- مفاهیم بنیادین تئوری مجموعه راف

این تئوری در کسب دانش از ابعاد صنعتی مختلف بسیار موفق ظاهر شده و بواسطه داشتن رویکرد ریاضی با توجه به سه مفهوم رابطه ناگسسته، تقریب مجموعه و کاهش داده های مبهم و غیرقطعی را مدیریت می کند (پاولاک، ۱۹۸۲؛ پاولا، ۲۰۰۲؛ پاولاک، ۱۹۹۷). در این بخش مفاهیم بنیادین تئوری مجموعه راف به اجمال بیان شده است. نقطه شروع تحلیل مجموعه راف تشکیل جدول تصمیم  $S = \langle U, C, D \rangle$  و متشکل از ستون ها (ویژگی های) و ردیف ها (اشیا) است که  $U$  اتحاد جهانی و  $C$  و  $D$  به ترتیب برای نامیدن مجموعه های گسسته شرط (شرایط) و ویژگی های تصمیم به کار می رود (هو همکاران، ۲۰۱۶). هر زیرمجموعه  $B$  از  $C$  می تواند رابطه ای باینری با  $U$  را طبقه بندی کند. اگر

$a(x) = a(y)$  باشد یعنی  $(x, y \in U)$  و رابطه ناگسسته  $IND(B)$  که در آن  $a(x)$  و  $a(y)$  به ترتیب برای نامیدن مقدار خصوصیت  $a$  (یعنی  $\forall a \in B$ ) برای شی  $x$  و  $y$  به کار می رود. بنابراین، رابطه ناگسسته رابطه هم ارزی است که با مجموعه ای از ویژگی های بیان می شود. تقریب مجموعه مبتنی بر رابطه ناگسسته است و سه ناحیه را بر اساس کلاس های هم ارز نشان می دهد. برای تقریب یک مجموعه ... بر اساس رابطه ناگسسته  $B$  تقریب های کمتر و بیشتر مجموعه  $X$  بیان می شوند. به عبارت دیگر، تقریب های کمتر شامل همه اشیایی است که قطعاً به مجموعه  $X$  تعلق دارند و تقریب های بیشتر شامل اشیایی است که احتمالاً به مجموعه  $X$  تعلق دارند. تفاوت بین تقریب کمتر و بیشتر ناحیه مرزی مجموعه  $X$  نامیده می شود (یعنی فرمول ...). اگر ناحیه مرزی مجموعه  $X$  تهی باشد ... فرمول ... آنگاه مجموعه  $X$  مجموعه ای است و اگر ناحیه مرزی مجموعه  $X$  تهی نباشد ... فرمول ... آنگاه مجموعه  $X$  با توجه به  $B$  مجموعه راف نامیده می شود. کاهش، زیرمجموعه حداقل ویژگی های  $C$  است که از نظر گسستگی فرقی با مجموعه ویژگی های  $C$  ندارد (هو همکاران، ۲۰۱۶). بنابراین، ویژگی های غیرضروری را می توان بدون از بین رفتن اطلاعات نادیده گرفت زیرا ویژگی های موجود در کاهش ها دربردارنده تمام اطلاعات است. اشتراک همه کاهش هاها هسته مجموعه ای از ویژگی های اصلی - نامیده می شود. قوانین تصمیم با مقادیر شرایط و ویژگی های تصمیم تولید می شوند تا بتوان پس از یافتن کاهش هاها تقریب هایی منطقی تعیین نمود. در نتیجه، قوانین تصمیم به صورت "اگر شرط/شرایط ... آنگاه تصمیمات" بیان می شوند (جیا و همکاران، ۲۰۱۶). در این مطالعه برای تشکیل جدول تصمیم با سری های زمانی شاخص های تکنیکال متعدد به کار رفته در ویژگی های شرط و حرکت جهت دار به صورت ویژگی تصمیم بیان می شوند. بنابراین، بر اساس مفاهیم بالا می توان از تئوری مجموعه راف برای تولید سیگنال های مالی خرید و فروش (قوانین تصمیم) بازار سهام استفاده کرد. برای نمونه، قوانین تصمیم منتج از

کراس اور و جهش ایجاد می‌شوند. فرایند مذکور تا یافتن راه حل مطلوب/بهینه و رسیدن به تعداد معینی از نسل‌ها تکرار می‌شود. شبه کد اولیه الگوریتم ژنتیک به شرح زیر است: ۱: تولید جمعیت تصادفی از افراد، ۲: نسل‌ها=۳۰، ۳: ارزیابی قابلیت افراد، ۴: اگر شرایط خاتمه وجود ندارد انجام مراحل ۵ تا ۹ ضروری است، ۵: انتخاب ۲ نفر (والدین) برای تولید نسل، ۶: تولید نسل - های جدید با استفاده از عملگرهای کراس اور و جهش، ۷: ارزیابی قابلیت نسل جدید، ۸: جایگزینی والدین نامناسب جمعیت با والدین مناسب، ۹: نسل‌ها: نسل‌ها+۱، ۱۰: خاتمه شرط، ۱۱: برگشت به جمعیت بهینه. (آلن و کارجالاین، ۱۹۹۹). در این مطالعه همزمان از یک الگوریتم ژنتیک در دو فرایند تحلیل مجموعه راف به کار رفت و پس از بررسی کاهش بهینه حجم داده و نقطه برش‌های گسسته سازی قوانین خرید و فروش کشف شد. به طور کلی، تئوری مجموعه راف برای نمایش دانش و الگوریتم ژنتیک برای حل مسائل ترکیبی بهینه سازی سودمند است. بنابراین، مزیت مدل پیشنهادی هوشمند ترکیبی خرید و فروش مجهز به تحلیل مجموعه راف و الگوریتم ژنتیک کشف قوانین خرید و فروش متعاقب حل مسائل بهینه سازی کاملاً ساده و مبرهن است.

### ۲-۳- سیستم هوشمند ترکیبی خرید و فروش برای کشف قوانین

در چارچوب سیستم هوشمند ترکیبی خرید و فروش برای کشف قوانین خرید و فروش در فاز اول، برای تحلیل مجموعه راف جدول تصمیم شامل ویژگی‌های شرایط (یعنی شاخص‌های تکنیکال) و ویژگی تصمیم یعنی بالا (+۱) و پائین (-۱) بود. در فاز دوم سازوکار کشف قوانین برای تولید قوانین تصمیم منتج از تحلیل مجموعه راف ارائه شده که کاربرد آن کشف قوانین بهینه و شبه بهینه خرید و فروش است. در فاز آخر نیز راهبرد خرید و فروش مورد نیاز برای تولید سیگنال‌های خرید و فروش تدوین شد.

تئوری مجموعه راف نشان دهنده دانش حاصل از داده‌های بازار سهام است. ویژگی‌های شرایط شامل شاخص‌های تکنیکال از جمله میانگین متحرک همگرا و واگرا، شاخص قدرت نسبی و نرخ تغییر و دامنه‌های مرتبط با آن است. برای طبقه‌بندی مسیر بازار مقدار ویژگی‌های تصمیم به صورت بالا و پایین بیان می‌شود. ساختار ساده قوانین تصمیم باعث می‌شود سرمایه گذاران بتوانند قوانین را به سهولت درک نموده و صحت و سقم نتایج آن را مشخص کنند. به این ترتیب تئوری مجموعه راف بواسطه شناسایی روابط بین شاخص‌های تکنیکال و نمایش آن محدودیت‌های مرتبط با شفافیت مدل‌های جعبه سیاه را نخواهند داشت (جیا و هماکران، ۲۰۱۶).

### ۲-۲- الگوریتم‌های ژنتیک

در دهه‌های اخیر الگوریتم‌های ژنتیک عمدتاً برای حل بسیاری از مسائل مانند تخصیص بهینه منابع، حمل و نقل و مسائل زمان بندی مورد استفاده قرار گرفته است. الگوریتم‌های ژنتیک کلاسی از محاسبات تکاملی هستند که با الهام گرفتن از تکامل طبیعی روش‌های اکتشافی انطباقی هیوریستیک را به کار می‌برد (کیم و هان، ۲۰۰۰؛ نگویانو اسکورون، ۱۹۹۵). الگوریتم ژنتیک با تقلید از اصول انتخاب طبیعی و تکامل زیست‌شناختی برای یک مسئله معین راه‌حل‌های متفاوتی ارائه می‌دهد. بدین سبب برای حل مسائل ترکیبی بهینه سازی می‌توان الگوریتم ژنتیک را به کار برد. با وجود تصادفی بودن این الگوریتم‌ها کاربر قادر خواهد بود با استناد به شواهد تاریخی در فضای جستجو کاوشگری نموده و راه‌حل‌های مطلوبی را ارائه نماید. در فرایند کلی الگوریتم ژنتیک گروهی از راه‌حل‌های تصادفی معین ایجاد شده؛ سپس کاربر با ارزیابی راه‌حل‌های معین آن‌ها را بر اساس تابع قابلیت رتبه بندی می‌کند (اصفهانی پور و موسوی، ۲۰۱۱). انتخاب والدین بر اساس شاخص قابلیت انجام می‌شود و با تکثیر والدین یک یا چند نسل جدید ایجاد می‌شود؛ نسل جدید با استفاده از عملگرهای نو ترکیب نظیر

## ۲-۴- پیشینه پژوهش

عباسی و عالم تبریزی (۱۳۹۶) به انتخاب مکان احداث شعب بانک با رویکرد تئوری مجموعه های راف- برنامه ریزی آرمانی چند انتخابه پرداختند. باتمیز و همکاران (۱۳۹۵) روشی جدید در تعیین ورشکستگی با استفاده از تحلیل پوششی داده ها و تئوری مجموعه های راف فازی ارائه دادند. میرزایی و اسماعیل پور (۱۳۹۴) روشی ترکیبی برای افزایش دقت پیش بینی در کاهش داده با استفاده از مدل مجموعه راف و هوش تجمعی ارائه دادند. هو و همکاران (۲۰۱۶) با بررسی متون مرتبط با به کارگیری روش های محاسبات تکاملی برای کشف قوانین به کمک سیستم خرید و فروش هوشمند ترکیبی دریافتند از میان روش های مختلف محاسبات تکاملی نظیر الگوریتم تکاملی، هوش گروهی و روش های تکاملی ترکیبی، الگوریتم های ژنتیک برای یافتن و کشف قوانین خرید و فروش تکنیکال موجود در سیستم هوشمند خرید و فروش محبوبیت زیادی دارد. آلن و کاجالاین (۱۹۹۹)، او و همکاران (۲۰۰۶) پیشگامان اصلی به کارگیری الگوریتم ژنتیک در تدوین مدل کشف قوانین خرید و فروش تکنیکال هستند که برای شاخص استاندارد و عملگرهای محاسباتی را با شاخص های تکنیکال در هم آمیختند. دمپستر و جونز (۲۰۰۱) برای یافتن قوانین بهینه خرید و فروش تکنیکال برای بازار تبادلات خارجی سیستم خرید و فروش را با زبان برنامه نویسی ژنتیک ایجاد کردند. چن و همکاران (۲۰۰۹) نیز مدل خرید و فروش سهام را بر اساس برنامه نویسی شبکه ژنتیک تدوین کردند. اصفهانی پور و موسوی (۲۰۱۱) برای تولید خودکار مقررات خرید و فروش تکنیکال تعدیل شده بازار سهام بورس اوراق بهادار زبان برنامه نویسی ژنتیک را مورد استفاده قرار دادند. مابو و همکاران (۲۰۱۳) با استفاده از GNP و تلفیق قانون، تعیین بازار خرید و فروش بر اساس قوانین خرید و فروش استخراج شده از طریق یک سازوکار طبقه بندی مشخص تعدادی قوانین خرید و فروش وضع نمودند. وانگ و همکاران (۲۰۱۴) راهبرد پیچیده خرید

و فروش سهام را با سازوکار پاداش/جریمه و رویکرد بهینه سازی ازدحام ذرات طرح کردند. ژانگ و همکاران (۲۰۱۵) مدل اصلاح شده تر تکاملی کشف قوانین خرید و فروش سهام را پیشنهاد کردند. این مدل با شرایط مختلف بازار سازگار بود؛ زیرا سیستم پیشنهادی شامل قانون کاوی طبقه بندی، یادگیری تکاملی و تکنیک یادگیری تقویت شده است. کیم و انکه (۲۰۱۶) با استفاده از تحلیل مجموعه راف بازارهای آتی سیستم خرید و فروش تغییر قانون را توسعه دادند. آن ها قوانین محتمل خرید و فروش را با استفاده از گسسته سازی داده و روش های کاهش حجم تولید نموده و با استناد به یافته های قبلی خرید و فروش به تغییر قوانین پرداختند.

## ۲-۵- فرضیه پژوهش

مدل سیستم ترکیبی هوشمند خرید و فروش جهت کشف قوانین خرید و فروش تکنیکال از طریق تحلیل مجموعه راف و الگوریتم ژنتیک در مقایسه با مدل معیار از نظر میانگین بازدهی و مقیاس ریسک تعدیل شده عملکرد بهتری دارد.

## ۳- روش شناسی پژوهش

### ۳-۱- تبدیل داده ها به جدول تصمیم

در فاز اول، تحلیل مجموعه راف با تشکیل جدول تصمیم  $S = \langle U, C, D \rangle$  آغاز شد که شامل مجموعه کران دار اشیا  $U = \{x_1, x_2, \dots, x_m\}$   $m$  مجموعه کران دار ویژگی های شرطی  $C = \{c_1, c_2, \dots, c_n\}$  و ویژگی تصمیم  $D = \{d\}$  است. مقادیر اصلی داده های تعاملات بهنگام (شامل باز، بالا، پائین، آخرین بهای پرداختی) (قیمت در زمان بسته شدن بازار) و حجم معاملات در بازه زمانی  $(t-1, t]$  به فرمول های  $n$  شاخص تکنیکال تبدیل می شود تا مقادیر ویژگی های شرطی ایجاد شود. مقادیر ویژگی تصمیم با تغییر آخرین بهای پرداختی تعیین می شود که به صورت بالا (+۱) و پائین (-۱) نشان داده می شود. بالا (+۱) بدین معنا است که

ویژگی شرط را نشان می‌دهد (c ∈ C) در حالیکه  $I_{(I,k)}^c$  به فاصله نام از k فاصله ویژگی شرط اختصاص دارد (i = 1, 2, ..., k). فرمول تعداد نقطه برش لازم برای حد بالا k-1 است. به جز نقطه برش‌های حداقل  $P_1^C$  و حداکثر  $P_K^C$  حد پائین ۱ است. برای نمونه، روش هم عرض یکی از روش‌های گسسته سازی داده‌ها است که در آن ویژگی پیوسته به فواصلی با عرض یکسان تقسیم می‌شود. شاخص قدرت نسبی عددی بین ۰ تا ۱۰۰ و یکی از رایج‌ترین شاخص‌های مومنوم تکنیکال است (منخوف، ۲۰۱۰؛ وانگ، ۲۰۱۴؛ لیبو-همکاران، ۲۰۱۰؛ جیا و همکاران، ۲۰۱۶). به عنوان مثال، اگر گسسته سازی RSI به روش هم عرضی انجام شده باشد (در این نمونه k=4) آنگاه مقدار RSI برابر است با:

$$RSI = [0, 25] \cup [25, 50] \cup [50, 75] \cup [75, 100]$$

زوج  $(RSI, I_{(2,4)}^{RSI})$  به معنای RSI با فاصله دوم [25, 50] از بین ۴ فاصله است. پس از فرایند گسسته سازی جدول تصمیم جدید  $S^{dis} = \langle U, C^{dis}, D \rangle$  جایگزین جدول تصمیم اولیه  $S = \langle U, C, D \rangle$  می‌شود. تحلیل مجموعه راف برای استخراج قوانین تصمیم زیرمجموعه ویژگی‌ها را با داده‌های گسسته مورد استفاده قرار می‌دهد. به طور کلی، برخی از ویژگی‌های زائد جدول تصمیم (سیستم اطلاعاتی) را می‌توان بدون احتمال از بین رفتن اطلاعات ضروری حذف نمود. بنابراین، تولید کاهش در تحلیل مجموعه راف کاملاً ضروری است؛ زیرا کاهش به حداقل زیرمجموعه ویژگی‌ها اشاره دارد. در این مطالعه سازوکار کشف قانون فرایند جستجو تصادفی کاهش را توسط الگوریتم ژنتیک تسهیل می‌کند. برای بررسی کلیه کاهش احتمالی ترکیبات شاخص‌های تکنیکال مورد استفاده قرار می‌گیرند (رجوع شود به مرحله بعد). اساس کاهش تولید شده قوانین تصمیم به شکل "اگر ... شرط / شرایط ... آنگاه تصمیم" بیان می‌شود (شن، ۲۰۰۴) در در نتیجه، می‌توان یک قانون تصمیم (dr) را به شکل زیر نشان داد: اگر مقدار شاخص

نزدیکترین قیمت بعدی در زمان t+1 بزرگتر مساوی آخرین بهای پرداختی در زمان t است. در حالی که پائین (۱-) به معنای آن است که آخرین بهای پرداختی بعدی در زمان t+1 کوچکتر از آخرین بهای پرداختی در زمان t است. پژوهشگران و متخصصان برای تحلیل میانگین متحرک همگرا و واگرا، شاخص‌های تکنیکال رایج (تعداد=۳۷) نظیر شاخص قدرت نسبی، نوسانگرهای احتمالی و R% ویلیامز را برگزیدند. جزئیات مربوط به محاسبات شاخص‌های تکنیکال به عنوان ویژگی‌های شرطی جدول تصمیم آمده است.

### ۳-۲- ساز و کار کشف قوانین

در این فاز سازوکار کشف قانون در دو مرحله استخراج قوانین تصمیم با استفاده از تحلیل مجموعه راف و تکامل قوانین تصمیم استخراج شده به کمک الگوریتم ژنتیک آمده است. این مراحل تا توقف شرط الگوریتم ژنتیک تکرار می‌شود.

### ۳-۳- استخراج قوانین تصمیم با استفاده از

#### تحلیل مجموعه راف

با توجه به اینکه تحلیل مجموعه راف به جای ویژگی‌های عددی پیوسته بر خصوصیات گسسته تاکید دارد؛ یکی از روش‌های پیش پردازش داده‌ها گسسته سازی داده‌ها است تا زیرمجموعه ویژگی‌ها (یعنی کاهش) ایجاد شود. به طور کلی، گسسته سازی ویژگی‌های پیوسته (c ∈ C) شامل تبدیل آن به تعداد نامحدودی از فواصل مشتمل بر مجموعه‌ای از نقطه برش‌های پیشنهادی ... است که در به  $PC_1$  و  $PCK$  آن ترتیب برای نشان دادن حداقل و حداکثر مقادیر به کار می‌روند. لازم به ذکر است نقطه برش عددی حقیقی در دامنه مقادیر پیوسته است. یک فاصله کوچکتر یا مساوی نقطه برش است و فواصل دیگر بزرگتر از آن است؛ زیرا نقطه برش دامنه را به دو فاصله تقسیم می‌کند. علاوه بر این، زوج  $(c, I_{(I,k)}^c)$

مجموعه کاهش (یعنی کاردینالیتهی کاهش=۳) از بین ۳۷ شاخص تکنیکال است. دومین و سومین مجموعه نشان دهنده تعداد نقطه برشها است (یعنی ۱ و ۲ و ۳) و نقطه برشهای پیشنهادی (یعنی تقسیم یک ویژگی به ۲۰ فاصله بابر) برای گسسته سازی عناصر مربوط به کاهش است. در تصویر ۲ ساختار کروموزوم به کار رفته در الگوریتم ژنتیک نمایش داده شده است. الگوریتم ژنتیک در پی یافتن همزمان کاهش بهینه و شبه بهینه با تعداد نقطه برشها و نقطه برشهای پیشنهادی گسستهسازی در سازوکار کشف قوانین است. به منظور بررسی پارامترهای کشف قوانین بهینه و شبه بهینه تعریف تابع هدف مناسب برای ارزیابی قابلیت کروموزوم ضروری است (آلن، ۱۹۹۹). در این مطالعه همسو با مطالعات قبلی برای قابلیت نسبت شارپ در دوره آموزشی مورد استفاده قرار گرفت. این شاخص یکی از شاخصهای ریسک تعدیل شده و بازده است. در ذیل تابع هدف مورد استفاده بیان شده است که در آن  $E(R)$  نرخ بازدهی میانگین یافتههای خرید و فروش و  $\sigma$  انحراف استاندارد نرخ بازدهی است. علاوه براین، تعداد معاملات (یعنی  $\geq 30$ ) نشان دهنده محدوده نمونه گیری آماری است. کروموزومهای رمزگشایی شده به میزان حداکثر تابع قابلیت (یعنی نسبت شارپ) تکامل می یابند (بکیدوس، ۲۰۱۰؛ هسو و همکاران، ۲۰۱۱؛ شارپ، ۱۹۹۴؛ شن و لو، ۲۰۰۴).

$$\text{Maximize SR} = \frac{E(R)}{\sigma}$$

برای اطمینان یافتن از تکثیر کروموزوم ممتاز این فرایند با انتخاب ممتاز و با استفاده از عملیات ژنتیکی کراس اور و جهش انجام شد. در این مطالعه در ممتازگرایی کروموزومهایی به عنوان والدین نسل بعدی در نظر گرفته می شوند که بیشترین مقدار قابلیت را داشته باشند و کروموزومهای باقیمانده عملیات ژنتیکی را انجام می دهند. علاوه براین، برای ارتقا کیفیت قوانین تصمیم در این فرایند قوانین تصمیم با پشتیبانی و پوشش کمتر کنار گذاشته می شوند. بنابراین، مجموعه ای از قوانین تصمیم  $\{dr1,$

تکنیکال  $(c_1, I_{(i,k)}^{c_1}) \in (c_1)$  و اگر مقدار شاخص تکنیکال  $(c_2, I_{(i,k)}^{c_2}) \in (c_2)$  و... و اگر مقدار شاخص تکنیکال  $(c_n, I_{(i,k)}^{c_n}) \in (c_n)$  باشد آنگاه بالا (+۱) و پایین (-۱) است. بنابراین مجموعه محدودی از قوانین را می توان به شکل  $DR = \{dr1, dr2, \dots, dr1\}$  بیان کرد. کیفیت هر قانون تصمیم بر اساس شاخصهایی مانند پشتیبانی، صحت و پوشش مورد ارزیابی قرار می گیرد. پشتیبانی یک قانون تصمیم به معنای تعداد اشیا مربوط به سلف قانون است. فرمول محاسبه صحت قانون برابر است با: پشتیبانی خلف قانون به پشتیبانی سلف آن قانون. فرمول محاسبه پوشش قانون برابر است با حاصل تقسیم پشتیبانی به سلف تعداد کل اشیا. در این مطالعه، پالایش قوانین تصمیم و تشخیص ناکافی بودن آن بر اساس معیارهایی نظیر حمایت (۲۰ درصد > تعداد کل اشیا در هر مجموعه داده آموزشی) و پوشش و صحت آن به ترتیب بالای ۲۰ و ۵۰ درصد انجام می شود. بدین معنا که تولید قوانین تصمیم زمانی محقق می شود که حمایت و پوشش بالای ۳۰ درصد باشد. برای توجیه علت انتخاب صحت بالای ۵۰ درصد می توان به طبقه بندی مسیر بازار در دو گروه بالا و پائین اشاره کرد (پاولاک، ۲۰۰۲).

### ۳-۴- کشف قوانین تصمیم بهینه به کمک الگوریتم ژنتیک

در این مرحله برای بهبود قوانین تصمیم به دست آمده از مرحله قبلی الگوریتم ژنتیک به کار رفت. در صورتی که برای گسسته سازی یا کاردینالتهی کاهش نقطه برشهای بسیار زیاد یا بسیار محدود در نظر گرفته شده باشد قوانین در بازار کارایی چندانی نخواهند داشت؛ زیرا قوانین غالباً یا کاملاً ساده هستند یا کاملاً پیچیده؛ از این رو زمانی که الگوریتم ژنتیک مورد استفاده قرار می گیرد بهتر است چالشهای استفاده از آن رفع شود و به این منظور دامنههایی تعیین شوند که برای نمایش قوانین نیازمند ۳ مجموعه پارامتر برای هر کروموزوم یا فرد است. اولین

است. برای تولید سیگنال خرید و فروش لازم است که حد آستانه خرید و فروش صفر باشد ( $TS_t=0$ ) یعنی اگر  $TS_t$  در لحظه  $t$  بزرگتر از صفر باشد و قراردادهای آتی در زمان  $t-1$  جایگاهی نداشته باشد سیگنال خرید و فروش طولانی خواهد بود و به معنای سیگنال خرید است. از سوی دیگر، اگر  $TS_t$  در لحظه  $t$  کوچکتر از صفر باشد و قراردادهای آتی در زمان  $t-1$  جایگاهی نداشته باشد سیگنال خرید و فروش کوتاه خواهد بود و به معنای سیگنال فروش است. اگر  $TS_t$  در لحظه  $t$  صفر باشد و قراردادهای آتی در زمان  $t-1$  جایگاهی نداشته باشد سیگنال تولید شده عملیاتی نیست. در حالیکه اگر  $TS_t$  در لحظه  $t$  صفر باشد و قراردادهای آتی در زمان  $t-1$  طولانی یا کوتاه باشد این موقعیت به معنای سیگنال هلدینگ خواهد بود.

#### ۴- یافته‌های پژوهش

##### ۴-۱- مجموعه داده‌ها

مجموعه داده‌های مورد استفاده برای آزمایش‌های انجام شده در این مطالعه شامل ۳۰ دقیقه باز، بالا، پائین، بسته و حجم قراردادهای آتی شاخص مرکب قیمت گذاری سهام بورس اوراق بهادار بود. این مجموعه داده برگرفته از بورس اوراق بهادار تهران بود. دوره‌های آموزشی و آزمایشی شامل بررسی ترندهای بالا و پائین و پویایی بازارهای راکد بود که با هدف ارزیابی تناسب عملکرد خرید و فروش انجام شد. هدف اصلی از طراحی این مطالعه بررسی اثربخشی سازوکار کشف قوانین بود که شامل فعالیت‌های مرحله به مرحله برای یافتن نقاط برش گسسته سازی و کاهش ها بود. بر طبق یافته‌های کاهش ها ۳ مدل تجربی خرید و فروش شامل رویکرد تصادفی، همبستگی و الگوریتم ژنتیک طراحی شد. تاثیر تعداد مجموعه قوانین تصمیم بر عملکرد سیستم خرید و فروش بررسی و با توجه به مجموعه قوانین تصمیم عملکرد خرید و فروش ارزیابی شد. ارزیابی عملکرد خرید و فروش با استفاده از شاخص‌های رایج ارزیابی از

$DR = \{dr_1, \dots, dr_2\}$  به دست آمده از تحلیل مجموعه راف به روش بهینه سازی الگوریتم ژنتیک جایگزین مجموعه قوانین تصمیم بهینه می‌شوند (او و همکاران، ۲۰۰۶). کروموزوم‌های البت در آخرین نسل به عنوان قوانین خرید و فروش در دوره آزمون به کار می‌روند. زمانی که الگوریتم ژنتیک برای کشف مجموعه قوانین تصمیم بهینه مورد استفاده قرار می‌گیرد توجه به پارامترهای الگوریتم ژنتیک ضروری است؛ زیرا این پارامترها بر دامنه فضا جستجو و پیچیدگی زمانی فرایند تکامل تاثیر می‌گذارند (کیم وهان، ۲۰۰۰). با این حال، یک قانون کلی برای تعیین پارامترهای الگوریتم ژنتیک وجود ندارد. بنابراین، حجم جامعه، نرخ ممتازگرایی و تعداد مجموعه قوانین خرید و فروش مورد توجه قرار گرفت. تناسب عملکرد سایر پارامترها به طور تجربی و به روش آزمون و خطا اندازه گیری شد. در آزمون‌های مقدماتی دقیق حجم جامعه (۱۰۰۰)، نرخ ممتازگرایی (۰/۲)، نرخ کراس اور (۰/۵) و نرخ جهش (۰/۶۰) بود. معیار توقف مطالعه تولید ۱۰۰۰ نسل بود.

##### ۳-۵- فاز ۳: تولید سیگنال‌های خرید و فروش

در این مرحله مطابق با دمپسترو جونز (۲۰۰۱) تبدیل مجموعه قوانین تصمیم تولید شده از کروموزوم‌های ممتاز نسل آخر به سیگنال‌های خرید و فروش قراردادهای آتی ضروری بود. برای درک چگونگی تبدیل قوانین تصمیم به سیگنال‌های خرید و فروش و هلدینگ مجموع مقادیر تصمیم (بالا (+۱) و پائین (-۱)) قوانین تصمیم محاسبه شد. بر طبق تعداد مجموعه قوانین تصمیم ( $j$ ) سیگنال خرید و فروش  $TS_t$  در زمان  $t$  به روش زیر محاسبه می‌شود:

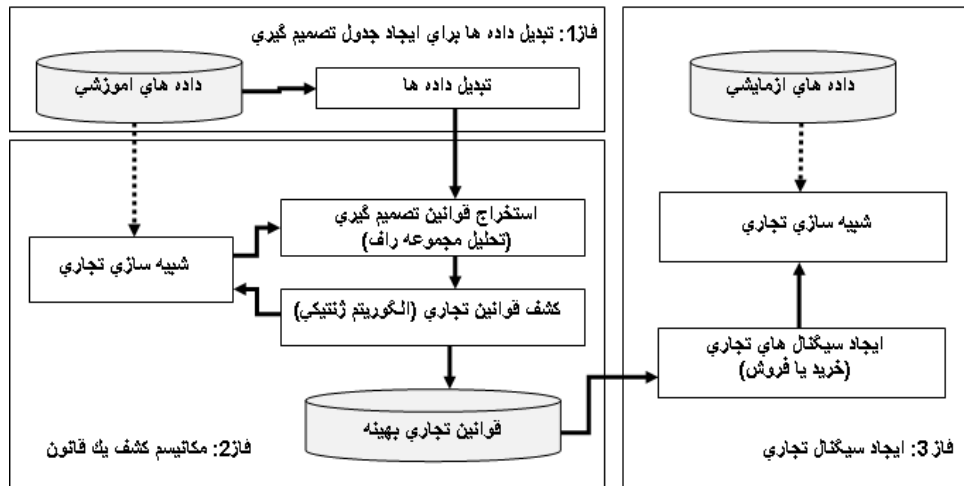
$$TS_t = \sum_{i=1}^j DR_{i,t}^*$$

در این فرمول  $z$  نشان دهنده تعداد کروموزوم‌های ممتاز نسل آخر (یعنی اولین تا  $z$  امین قانون تصمیم) در طول داده‌های آموزشی و سیگنال‌های خرید و فروش ( $TS_t$ ) مجموع مقادیر قوانین تصمیم در زمان  $t$



است. علاوه براین، برای محاسبه عملکرد خرید و فروش ۰/۲۵ درصد هزینه معاملات مورد استفاده قرار گرفت.

جمله نرخ بازدهی سالانه و نسبت شارپ انجام شد. همچنین نسبت حداکثر کشش نیز مورد استفاده قرار گرفت که نشان دهنده حداکثر سود انباشته حاصل از تغییر قیمت از سقف به کف آن در دوره آزمایشی



شکل ۱. چارچوب یک سیستم تجاری ترکیبی هوشمند برای کشف قوانین تجاری

آزمایشی ارزیابی مجموعه ای از قوانین خرید و فروش استخراج شده در مجموعه داده آموزشی با استفاده از عملکردهای خرید و فروش (نسبت شارپ یا سود) انجام شد. سپس مجموعه قوانین تصمیم بر اساس عملکرد خرید و فروش نوآرایی شد. از سوی دیگر، داده های رویکرد پنجره لغزان بدون مجموعه داده معتبر به مجموعه داده آموزشی (برای سه ماه) و مجموعه داده آزمایشی (به مدت یک ماه) تقسیم شد. طول مدت مجموعه داده آزمایشی از ۱۳۹۰ تا ۱۳۹۶ بود. جدول یک عملکرد خرید و فروش سازوکار کشف قوانین را با رویکرد تصادفی نشان می دهد. تعداد مجموعه قوانین تصمیم به ترتیب نزولی {۱۲۰، ۶۰، ۳۰، ۱۵، ۶، ۱} از هر قابلیت (نسبت شارپ یا سود) از بین همه ریداکت های مرکب (تعداد کل ریداکت ها) با انتخاب تصادفی ۱۰ شاخص تکنیکال در دوره های آموزشی مشخص شده است.

#### ۴-۲- رویکرد تصادفی

در این آزمایش، ۱۰ مورد از ۳۷ شاخص تکنیکال به شکل تصادفی انتخاب شده و با رویکرد گسسته سازی الگوریتم ژنتیک مورد استفاده قرار گرفتند. در واقع، این کار برای پاسخ به این سوال انجام شد که آیا هنگام ایجاد کاهش ها برای توسعه سازوکار کشف قوانین شاخص های تکنیکال در کشف قوانین خرید و فروش موثر واقع می شوند یا خیر. در این مطالعه برای ارزیابی قوانین خرید و فروش مقایسه مداخلات با توابع هدف مختلفی شامل حداکثر نسبت شارپ در مقایسه با سود) انجام شد. برای تعیین صحت و سقم قوانین خرید و فروش رویکرد پنجره لغزان با یا بدون مجموعه داده معتبر به کار رفت. در رویکرد پنجره لغزان با مجموعه داده معتبر داده ها به مدت دو ماه به یک مجموعه داده آموزشی، یک مجموعه داده معتبر (یک ماه) و یک مجموعه داده آزمایشی (یک ماه) تقسیم شدند. مجموعه داده معتبر با هدف پیشگیری از بیش قابلیت قوانین خرید و فروش تعیین شد. بدین معنا که پیش از به کارگیری قوانین کشف شده در مجموعه داده

جدول ۱. عملکرد تجاری مربوط به روش تصادفی

مدل	اندازه گیری	نسبت بازده (%) به وسیله تعداد مجموعه های قوانین تصمیم (j=)					
		۱	۶	۱۵	۳۰	۶۰	۱۲۰
بیشینه سازی نسبت شارپ	بازده سالیانه	۱/۶۱	۲/۴۵	۴/۲۴	۵/۴۵	۵/۸۸	۳/۱۰
	انحراف معیار	۱۱/۳۲	۶/۷۴	۱۳/۰۲	۱۰/۲۳	۱۲/۰۲	۷/۴۷
	افت حداکثری	-۳۹/۰۷	-۳۳/۶۱	-۴۱/۲۳	-۲۶/۶۶	-۲۲/۸۶	-۲۶/۳۷
	نسبت شارپ	۰/۱۷	۰/۳۸	۰/۳۸	۰/۵۸	۰/۴۸	۰/۴۴
بیشینه سازی بهره	بازده سالیانه	۳/۱۴	۳/۱۰	-۰/۵۱	۴/۱۷	۴/۲۴	۳/۲
	انحراف معیار	۱۱/۲۱	۲۲/۸۸	۱۱/۷۷	۱۳/۴۱	۱۱/۵۴	۱۲/۲۲
	افت حداکثری	-۳۲/۹۷	-۷۶/۲۲	-۳۸/۵۵	-۳۹/۱۴	-۳۶/۱۱	-۴۷/۶۳
	نسبت شارپ	۰/۲۸	۰/۱۸	-۰/۰۴	۰/۳۲	۰/۳۷	۰/۱۶
بیشینه سازی نسبت شارپ و مجموعه داده های معتبر	بازده سالیانه	۳/۶۵	۳/۱۳	۳/۶۶	۴/۱۱	۳/۵۳	۲/۵۵
	انحراف معیار	۱۷/۰۲	۱۵/۱۰	۱۰/۲۱	۱۲/۲۴	۱۶/۴۵	۱۵/۲۴
	افت حداکثری	-۲۸/۷۶	-۳۹/۹	-۳۱/۱۰	-۳۳/۶۳	-۱۹/۷۹	-۳۳/۴۱
	نسبت شارپ	۰/۲۳	۰/۲۳	۰/۴۰	۰/۳۲	۰/۲۸	۰/۱۸
بیشینه سازی بهره و مجموعه داده های معتبر	بازده سالیانه	۱/۲۶	-۴/۹۱	۱/۷۷	-۲/۶۱	۲/۸۴	۰/۰۸
	انحراف معیار	۱۴/۹۸	۱۱/۴۵	۱۲/۱۱	۱۲/۲۰	۱۱/۳۲	۲۱/۰۱
	افت حداکثری	-۴۲/۲۲	-۷۲/۲۵	-۳۸/۸۸	-۴۱/۲۴	-۴۳/۵۶	-۳۸/۴۱
	نسبت شارپ	۰/۰۸	-۰/۳۸	۰/۱۹	-۰/۲۲	۰/۱۹	۰/۰۳

این که این رویکرد از راهبرد خرید و هلد دوره آزمایشی مطلوب تر است؛ اما استفاده از آن به عنوان یک سیستم خرید و فروش عملی دشوار است. ین یافته موکد آن است که شاخص های تکنیکال متنوع می توانند با دفاع از ریسک نامطلوب عملکرد خرید و فروش را بهبود بخشند؛ زیرا ریداکت ها توسط ۱۰ شاخص تکنیکال تصادفی و برای دوره آموزشی تولید شده اند.

#### ۴-۳- رویکرد همبستگی

در این مطالعه مداخلات بر اساس تابع تعیین نقطه برش گسسته سازی مورد مقایسه قرار گرفتند. برای آگاهی یافتن از سودمندی روش گسسته سازی به کمک الگوریتم ژنتیک مقایسه سازوکار کشف قوانین بدون تابع ریداکت های جستجو با سایر روش های گسسته سازی به کار رفته در پژوهش های قبلی انجام شد (کیم و انکه، ۲۰۱۶؛ لی و همکاران، ۲۰۱۰؛ لی، ۲۰۱۲؛ یائو و هربرت، ۲۰۰۹). با وجود آنکه ریداکت-

با توجه به جدول ۱ به نظر می رسد سازوکار کشف قوانین با استفاده از تابع قابلیت حداکثر نسبت شارپ معمولاً در مقایسه با سازوکار کشف قوانین با استفاده از تابع قابلیت حداکثر سود عملکرد بهتری دارد. علاوه بر این، به طور متوسط سازوکار کشف قوانین به روش پنجره لغزان بدون مجموعه داده معتبر در مقایسه با روش پنجره لغزان با مجموعه داده معتبر عملکرد مطلوب تری دارد. بعد از این رویکردهای پنجره لغزان بدون مجموعه معتبر داده ها و تابع هدف (یعنی نسبت شارپ) قرار دارند که سازوکار کشف قوانین آن ها شامل همبستگی و رویکردهای الگوریتم ژنتیک است. با توجه به تعداد مجموعه قوانین تصمیم، مدل های پیشنهادی دارای نرخ بازدهی سالانه مشخص هستند. نرخ بازدهی انباشته سازوکار کشف قوانین با استفاده از حداکثر نسبت شارپ و پنجره لغزان بدون مجموعه معتبر داده ها با احتساب تعداد مجموعه قوانین تصمیم است. نرخ سود انباشته و نسبت شارپ رویکرد تصادفی در مقایسه با راهبرد خرید و فروش بیشتر است. با وجود

عملکرد خرید و فروش طول مدت دوره آموزشی ۳ ماه و طول دوره آزمایشی ۱ ماه بود (مجموعه داده آزمایشی ۱۳۹۰ تا ۱۳۹۶). رویکرد پنجره لغزان مجدداً برای دوره های آموزشی و آزمایشی مورد استفاده قرار گرفت. تعداد مجموعه قوانین به ترتیب نزولی {۱۲۰، ۶۰، ۳۰، ۱۵، ۶، ۱} از بین همه ریداکت های مرکب (تعداد کل ریداکت ها) مشخص شده است. عملکرد خرید و فروش سازوکار کشف قوانین با DMGA و FEB به ترتیب در جدول ۲ و ۳ آمده است.

های مشابه (زیرمجموعه شاخص های تکنیکال) در تحلیل مجموعه راف به کار رفت؛ اما نتایج گسسته-سازی همسان نبود. برای تولید ریداکت های مساوی تحلیل همبستگی بین مقادیر شاخص های تکنیکال و ویژگی های آخرین بهای پرداختی شاخص مرکب قیمت گذاری سهام بورس اوراق بهادار انجام شد. به این ترتیب، ۱۰ شاخص تکنیکال با همبستگی بالا برای دوره های آموزشی انتخاب شد؛ اما گسسته سازی هر شاخص متفاوت بود. در این مداخله برای ارزیابی

جدول ۲. عملکرد تجاری مربوط به مکانیسم کشف قانون با استفاده از EFB

سال	نسبت بازده (%) به وسیله تعداد مجموعه های قوانین تصمیم (j=)					
	۱	۶	۱۵	۳۰	۶۰	۱۲۰
۱۳۹۰	۸/۲۲	۱۲/۵۴	۲۷/۵۵	۲۲/۷۴	۲۳/۷۷	-۲۵/۲۱
۱۳۹۱	۱۳/۶۱	۱۶/۰۰	۱۴/۰۴	۱۲/۴۱	۱۸/۸۴	۲۰/۱۲
۱۳۹۲	۱۲/۲۸	۰/۵۹	۱۹/۲۰	۱۶/۵۵	۱۴/۲۸	۲۶/۳۳
۱۳۹۳	-۲/۱۱	-۳۴/۷۱	-۳۱/۵۲	-۲۹/۱۷	-۳۱/۴۷	۶/۲۴
۱۳۹۴	-۳/۱۹	۹/۴۴	۱۱/۳۳	۱۰/۰۱	۹/۸۱	۳۳/۵
۱۳۹۵	۱۱/۳۲	۰/۴۱	-۱/۸۵	-۱/۷۵	۶/۱۰	-۲/۰۲
۱۳۹۶	-۳/۶۵	-۰/۴۸	-۸/۱۴	-۶/۱۱	-۱/۰۹	-۲/۸۴
بازده سالیانه	۲/۳۵	۰/۶۶	۳/۱۹	۲/۶۴	۴/۳۵	۳/۹۴
انحراف معیار	۱۲/۵۱	۱۵/۷۴	۱۶/۱۲	۱۶/۲۴	۱۹/۲۱	۱۴/۶۴
افت حداکثری	۵۱/۷۷	۵۳/۰۹	۴۸/۲۳	۵۱/۲۳	۵۲/۶۴	۳۴/۴۷
نسبت شارپ	۰/۱۶	۰/۰۴	۰/۲۶	۰/۱۴	۰/۳۴	۰/۳۴

جدول ۳. عملکرد تجاری مربوط به مکانیسم کشف قانون با استفاده از DMGA

سال	نسبت بازده (%) به وسیله تعداد مجموعه های قوانین تصمیم (j=)					
	۱	۶	۱۵	۳۰	۶۰	۱۲۰
۱۳۹۰	-۹/۱۲	۳/۱۰	۷/۲۴	-۱۱/۲۴	-۱۹/۱۱	۱۴/۷۸
۱۳۹۱	-۱۲/۱۰	-۱۷/۸۲	-۱۴/۴۵	-۳/۲۴	۷/۶۸	۲۱/۳۸
۱۳۹۲	۶/۴۵	۲۵/۳۷	۳۱/۱۱	۳۶/۲۱	۴۱/۱۹	۱/۶۴
۱۳۹۳	-۲/۲۷	۴/۷۳	۶/۸۴	۱۰/۴۶	-۵/۳۸	-۲۳/۵۲
۱۳۹۴	-۵/۴۱	-۳/۱۹	۴/۶۹	۰/۸۲	۲۱/۲۹	۸/۵۴
۱۳۹۵	۳۳/۲۸	۱۷/۵۹	۲۰/۱۲	۱۷/۰۱	-۱۱/۲۷	۲۰/۴۹
۱۳۹۶	-۰/۴۷	-۱/۴۱	-۶/۵۲	-۰/۷۱	۶/۶۱	-۱/۹۷
بازده سالیانه	۱/۲۴	۳/۵۲	۵/۲۱	۶/۵۴	۵/۴۱	۵/۶۷
انحراف معیار	۱۴/۲۷	۱۳/۲۹	۱۳/۵۰	۱۴/۴۲	۱۸/۵۲	۱۶/۹۰
افت حداکثری	۲۹/۳۲	۲۷/۷۸	۱۹/۲۰	۲۱/۷۷	۳۴/۵۵	۴۲/۷۱
نسبت شارپ	۰/۱۲	۰/۲۹	۰/۳۸	۰/۴۱	۰/۳۳	۰/۳۷

راهبرد خرید- هلد دوره آزمایشی عملکرد بهتری دارد. این امر نشان می‌دهد برای کشف قوانین خرید و فروش سازوکار کشف قوانین کافی است و سازوکار کشف قوانین با DMGA در مقایسه با FEB کاملاً پایدارتر است. با این حال، سیستم خرید و فروش با استفاده از سازوکار کشف قوانین FEB از راهبرد خرید - هلد دوره آزمایشی مطلوب‌تر است و به کارگیری آن به عنوان سیستم خرید و فروش عملی دشوار است؛ زیرا حداکثر افت سرمایه در این رویکرد بیشتر از راهبرد خرید- هلد است. نکته قابل توجه این که سیستم‌های خرید و فروش با مجموعه قوانین بهینه تصمیم و قوانین متعدد دوره آزمایشی چندان رضایت بخش نبودند. این یافته‌ها نشان می‌دهد تعداد قوانین تصمیم بر عملکرد خرید و فروش تاثیر می‌گذارند.

مقایسه سازوکارهای کشف قوانین دو رویکرد مذکور از نظر تعداد مجموعه قوانین تصمیم انجام شد. یافته‌ها نشان داد رویکرد DMGA دارای بیشترین نرخ سود سالیانه و نسبت شارپ و کمترین درصد افت سرمایه است. صرف نظر از تعداد مجموعه قوانین تصمیم و غیر از مجموعه بهینه قوانین تصمیم (یعنی  $J=1$ ) نسبت شارپ رویکرد DMGA مشخص بود. مقادیر مذکور در مقایسه با سایر مدل‌ها بالاتر بود. به ویژه در سازوکار کشف قوانین با DMGA سود بیشتر و در مقایسه با سایر عملکردهای خرید و فروش ریسک کمتر بود. این یافته نشان دهنده آن است که کاربرد سازو کار کشف قوانین با DMGA بسیار مهم است و باعث می‌شود سازگاری سیستم هوشمند ترکیبی خرید و فروش با قوانین خرید و فروش افزایش یابد دو مدل با تعداد مجموعه قوانین ۶۰ و ۳۰ و  $J=15$  در مقایسه با

جدول ۴. طرح پنجره کشویی و مجموعه داده های تجربی

تعداد کل پنجره های آزمایشی	مجموعه داده های آزمایشی		اندازه پنجره
	مجموعه داده های تجاری	مجموعه داده های تجاری	
			اندازه پنجره
			۳ ماه
		۱۳۹۰	۶ ماه
۹۱	۱ ماه	۱۳۹۶	۹ ماه
			۱۲ ماه

زمان دوره آموزشی و رویکرد پنجره لغزان و تعداد مجموعه قوانین تصمیم  $\{12, 9, 6, 3\}$  TPE و  $\{200, 100, 50, 25, 10, 1\}$   $J$  انجام شد. ساز و کار کشف قوانین شامل توابع جستجو نقاط برش، گسسته سازی و ریداکت‌های مورد استفاده برای کشف قوانین بود. علاوه بر این، ارزیابی عملکرد خرید و فروش در مقایسه با یافته‌های راهبرد خرید - فروش و رویکرد مرسوم تولید قوانین خرید و فروش با استفاده از تحلیل مجموعه راف بدون سازوکار کشف قوانین (یعنی فاز دوم) بود. جداول ۵ تا ۸ نشان می‌دهند سازوکار کشف قوانین با بهترین عملکرد خرید و فروش و سازوکار کشف قوانین با بدترین عملکرد خرید و

#### ۴-۴- رویکرد الگوریتم ژنتیک

در این رویکرد تاثیر مدت دوره آموزشی بر کشف قوانین خرید و فروش و تعداد مجموعه قوانین تصمیم بر قراردادهای آتی خرید و فروش مورد بررسی قرار گرفت. همانطور که قبلاً هم اشاره شد مدت دوره آموزشی عامل مهم و موثری است. مناسب بودن مدت زمان دوره آموزشی باعث بهبود عملکرد خرید و فروش می‌شود. بنابراین، مدت دوره آموزشی سیستم پیشنهادی برای کشف قوانین خرید و فروش ۳، ۶ و ۱۲ ماه بود و مدت دوره آزمایشی یک دوره ۱ ماهه به مدت ۹۱ ماه بود. در این مداخله تحلیل دقیق عملکرد خرید و فروش سیستم پیشنهادی با توجه به مدت

سالانه رویکرد مرسوم انحراف استاندارد نسبت حداکثر افت سرمایه و نسبت شارپ نیز مشخص است. بر طبق تعداد مجموعه های قوانین تصمیم در مدل پیشنهادی در پایان سال هفتم برای ۵۰ و  $J=25$  نرخ سود قابل توجهی به دست می آید. علاوه بر این، حداکثر افت سرمایه مدل پیشنهادی با  $(TP=6)$  و ۵۰ و  $J=25$  در دوره آزمایشی به مشخص بود. با توجه به غیر نرمال بودن توزیع سود خرید و فروش ماهانه تحلیل آماری با استفاده از آزمون نان پارامتری ویل کاکسون انجام شد. یافته ها در سطح معنادار ۱۰ درصد نشان داد راهبرد خرید - فروش و مدل پیشنهادی اختلاف معناداری دارند. رویکرد مرسوم و مدل پیشنهادی نیز اختلاف معناداری داشتند. در نتیجه، مدل پیشنهادی با  $(TP=6)$  و  $J=50$  دارای بیشترین سود انباشته و کمترین درصد افت سرمایه است. مدل پیشنهادی زمانی اهمیت خود را نشان می دهد که بازار راکد باشد. این مدل باعث خلق فرصت برای معامله گران می شود. علاوه بر این، مدل بهینه خرید و فروش در مقایسه با مدل RCTS کیم و انکه (۲۰۱۶) عملکرد بهتری دارد. این یافته ها نشان می دهد مدل پیشنهادی نسبتاً پایدار بوده و عملکرد معتبری دارد؛ زیرا نسبت شارپ و حداکثر افت سرمایه را تا بیش از ۵۰ درصد بهبود می بخشد. برای آزمودن اختلاف مدل پیشنهادی و RCTS از نظر عملکرد خرید و فروش با توجه به سود خرید و فروش آزمون آماری ویل کاکسون یا من ویتنی به کار رفت. دو مدل در سطح معنادار ۱۰ درصد اختلاف معناداری داشتند.

فروش، انحراف استاندارد نسبت شارپ را نشان می دهد به ویژه زمانی که ارزیابی عملکرد کلی خرید و فروش در مقایسه با سایر ابعاد و طبق بازه زمانی دوره آموزشی و با میانگین سوددهی ۶ ماهه  $(TP=6)$  انجام شده باشد دارای بیشترین مطلوبیت عملکرد خرید و فروش است. این یافته ها نشان می دهد به طور متوسط دوره آموزشی ۶ ماهه در مقایسه با سایر دوره های آموزشی ارجحیت بیشتری دارد. علاوه بر این، در دوره های آموزشی کوتاه مدت ۳ ماهه هیچ سازوکاری برای کشف قوانین ایجاد نشد و اطلاعات مورد نیاز برای کشف قوانین تصمیم وجود نداشت. از سوی دیگر، دوره های آموزشی طولانی تر (۱۲ و ۹  $TP=$ ) برای سازوکار کشف قوانین نامناسب هستند؛ زیرا در این شرایط فضای جستجو به قدری وسیع است که جستجو و یافتن راه حل ها به سادگی امکان پذیر نخواهد بود. از نظر تعداد مجموعه قوانین کاربرد قوانین بهینه تصمیم ( $J=1$ ) یا قوانین تصمیم متعدد ( $J=200$ ) صرف نظر از مدت دوره آموزش برای سیستم های خرید و فروش مناسب نیستند. قوانین متعدد خرید و فروش سیگنال های نادرستی ایجاد می کند. از سوی دیگر، استفاده از سیستم خرید و فروش با قانون بهینه یا یکتا نیز نامناسب است؛ زیرا در چنین سیستم هایی احتمال بیش قابلیت وجود دارد. در تصویر ۶ سودهای انباشته سازوکار کشف قوانین با  $(TP=6)$  و ۵۰ و  $J=25$  در دوره آزمایشی نمایش داده شده است. برای مجموعه داده مورد بررسی نرخ سود سالانه راهبرد خرید - فروش و نسبت شارپ مشخص است؛ در حالیکه نرخ سود

جدول ۵. عملکرد تجاری مربوط به مکانیسم کشف قانون با استفاده از یک دوره تجاری سه ماهه

سال	نسبت بازده (%) به وسیله تعداد مجموعه های قوانین تصمیم					
	۱	۱۰	۲۵	۵۰	۱۰۰	۲۰۰
۱۳۹۰	-۸/۴۱	۸/۲۸	۱۲/۷۴	۱۰/۶۱	۱۰/۲۵	۹/۷۱
۱۳۹۱	۱۹/۵۴	۱۰/۳۶	۱۳/۶۱	۲۰/۳۶	۵/۳۱	۲/۴۷
۱۳۹۲	۷/۳۱	۴/۷۱	-۸/۴۴	-۹/۷۲	۶/۴۲	۶/۵۵
۱۳۹۳	-۴/۴۱	-۵/۴۹	-۳/۲۷	۳/۵۸	-۶/۳۸	-۱۲/۳۴
۱۳۹۴	۱/۲۸	۱۱/۵۵	۲۱/۲۲	۱۰/۸۸	-۲/۶۲	-۰/۶۱
۱۳۹۵	۵/۷۴	-۹/۴۴	-۶/۳۱	-۶/۵۲	-۲/۵۸	۹/۳۹

سال	نسبت بازده (%) به وسیله تعداد مجموعه های قوانین تصمیم					
	۱	۱۰	۲۵	۵۰	۱۰۰	۲۰۰
۱۳۹۶	۱۱/۱۹	۹/۶۷	۹/۴۳	۱۰/۳۶	۱۴/۴۶	۷/۷۵
بازده سالیانه	۶/۰۳	۴/۸۱	۷/۳۳	۶/۴۱	۴/۳۳	۴/۶۴
انحراف معیار	۸/۷۲	۷/۶۹	۱۰/۷۷	۸/۸۱	۷/۱۱	۹/۵۲
افت حداکثری	۲۸/۳۰	۲۹/۱۲	۲۹/۸۱	۱۴/۶۹	۱۰/۲۲	۲۵/۴۱
نسبت شارپ	۰/۵۷	۰/۵۶	۰/۵۳	۰/۵۵	۰/۵۴	۰/۴۶

جدول ۶. عملکرد تجاری مربوط به مکانیسم کشف قانون با استفاده از یک دوره تجاری شش ماهه

سال	نسبت بازده (%) به وسیله تعداد مجموعه های قوانین تصمیم					
	۱	۱۰	۲۵	۵۰	۱۰۰	۲۰۰
۱۳۹۰	۲۶/۵۵	۶/۵۵	۱۲/۷۴	۶/۷۷	۴/۳۳	-۲/۷۱
۱۳۹۱	-۲۱/۷۱	۹/۶۲	-۷/۳۹	۱/۶۵	۱۳/۶۲	۵/۶۴
۱۳۹۲	-۱/۴۴	۸/۸۵	۳/۶۳	۴/۳۲	۰/۱۹	۵/۶۶
۱۳۹۳	-۲/۳۱	-۱۷/۵۲	۹/۴۷	۶/۵۲	۱۸/۷۰	۸/۴۸
۱۳۹۴	۳/۸۲	۲۱/۳۶	۲۵/۳۲	۲۵/۲۷	۱۰/۵۴	۹/۵۳
۱۳۹۵	-۱۶/۶۳	۴/۳۴	۲۳/۴۱	۲۱/۸۱	۲/۶۱	۱۱/۲۸
۱۳۹۶	۲۳/۳۳	۱۲/۲۴	۴/۷۹	۹/۴۹	-۵/۳۸	-۴/۲۵
بازده سالیانه	۱/۵۱	۶/۳۶	۱۰/۴۱	۱۰/۴۷	۶/۴۷	۴/۴۸
انحراف معیار	۱۶/۷۷	۱۰/۴۷	۱۰/۵۴	۸/۰۹	۷/۶۲	۵/۶۳
افت حداکثری	۴۷/۶۴	۳۴/۵۸	۲۴/۵۶	۱۵/۷۱	۲۴/۳۹	۲۸/۲۹
نسبت شارپ	۰/۱۲	۰/۵۵	۰/۸۵	۱/۰۱	۰/۷۷	۰/۸۵

جدول ۷. عملکرد تجاری مربوط به مکانیسم کشف قانون با استفاده از یک دوره تجاری نه ماهه

سال	نسبت بازده (%) به وسیله تعداد مجموعه های قوانین تصمیم					
	۱	۱۰	۲۵	۵۰	۱۰۰	۲۰۰
۱۳۹۰	-۱۲/۲۵	-۲/۲۷	-۱۶/۶۴	-۳۱/۵۵	۱۹/۲۳	۶/۲۵
۱۳۹۱	-۵/۶۱	۰/۳۶	-۶/۵۷	۲/۶۶	-۱۹/۷۷	-۷/۶۳
۱۳۹۲	-۱۴/۴۲	۰/۴۵	۶/۹۱	-۳/۳۶	۶/۳۱	۱۲/۷۴
۱۳۹۳	۳۳/۳۱	۱۸/۵۲	۳۱/۰۱	۲۴/۱۷	۰/۰۲	۷/۴۸
۱۳۹۴	۱/۴۱	-۷/۶۷	۲۷/۰۹	۳۲/۱۹	۲۹/۳۹	۲۲/۴۴
۱۳۹۵	۱۹/۷۵	۲۱/۸۱	۸/۲۷	۲۱/۷۴	۱۶/۶۸	۱۵/۳۳
۱۳۹۶	۹/۰۹	۶/۹۰	۱/۸۷	-۱/۹۱	۱/۳۷	-۳/۲۷
بازده سالیانه	۴/۱۲	۵/۸۸	۶/۰۷	۷/۵۹	۸/۲۴	۷/۸۴
انحراف معیار	۱۱/۱۹	۹/۵۱	۱۹/۶۱	۲۱/۷۶	۱۶/۵۵	۶/۶۷
افت حداکثری	۴۶/۳۷	۳۵/۶۸	۳۲/۵۷	۳۱/۲۹	۲۳/۴۶	۳۱/۳۵
نسبت شارپ	۰/۳۲	۰/۵۶	۰/۴۴	۰/۳۵	۰/۷۲	۰/۷۴

جدول ۸. عملکرد تجاری مربوط به مکانیسم کشف قانون با استفاده از یک دوره تجاری دوازده ماهه

سال	نسبت بازده (%) به وسیله تعداد مجموعه های قوانین تصمیم					
	۱	۱۰	۲۵	۵۰	۱۰۰	۲۰۰
۱۳۹۰	-۲۸/۶۶	-۴۱/۸۵	-۳۰/۴۲	-۳۷/۵۹	-۳۹/۸۸	-۲۸/۳۳
۱۳۹۱	-۱۳/۳۹	-۳۱/۷۴	-۲۸/۳۳	-۳۵/۶۱	-۲۸/۷۴	-۱۹/۸۸
۱۳۹۲	۷/۵۵	۸/۳۳	۲۲/۱۱	۱/۴۶	۵/۶۶	-۲/۵۴
۱۳۹۳	-۱۰/۴۱	-۱۹/۶۶	۲۱/۲۲	-۰/۳۹	-۹/۵۸	-۲/۶۶
۱۳۹۴	-۸/۱۹	۷/۶۳	۱۷/۴۶	۳۲/۵۴	-۲/۴۶	۰/۷۴
۱۳۹۵	۳/۶۶	۲۱/۵۴	۲۵/۵۳	۸/۳۸	۱۳/۵۷	۲۷/۷۵
۱۳۹۶	۱۵/۵۲	-۷/۳۶	-۱۶/۴۸	-۱۷/۸۹	-۱۷/۵۳	-۱۹/۶۷
بازده سالیانه	-۴/۲۲	-۶/۴۱	-۰/۰۵	-۶/۶۴	-۸/۴۹	-۵/۳۶
انحراف معیار	۲۱/۶۶	۱۹/۵۲	۱۸/۲۹	۲۴/۷۲	۲۰/۲۴	۲۶/۵۴
افت حداکثری	۶۴/۲۷	۸۸/۳۴	۴۸/۴۷	۶۸/۷۹	۷۷/۱۹	۵۸/۴۹
نسبت شارپ	-۰/۴۱	-۰/۴۰	۰/۰۶	-۰/۳۹	-۰/۶۲	-۰/۳۵

## ۵- بحث و نتیجه گیری

در این مطالعه برای کشف قوانین خرید و فروش در بازارهای آتی سیستم هوشمند ترکیبی خرید و فروش با استفاده از تحلیل مجموعه راف و الگوریتم ژنتیک طراحی شد. برای کشف قوانین بهینه و شبه بهینه خرید و فروش سازوکار جدیدی برای کشف قانون ایجاد شد و برای تکامل قوانین استخراج شده بوسیله تحلیل مجموعه راف الگوریتم ژنتیک مورد استفاده قرار گرفت. با توجه به تعداد مجموعه قوانین تصمیم و مدت زمان دوره آموزشی شاخص مرکب قیمت گذاری بازار سهام در بازارهای آتی سودمندی سیستم خرید و فروش تایید شد. سیستم هوشمند ترکیبی خرید و فروش برای کشف قوانین خرید و فروش با مدت زمان دوره آموزشی مشخص و مجموعه قوانین تصمیم در مقایسه با سایر ترکیبات آزمایشی دارای بیشترین نرخ سود سالیانه است و ترکیب تعداد مناسب مجموعه قوانین تصمیم با مدت زمان دوره آموزشی در بهبود عملکرد خرید و فروش موثر واقع می شود. عملکرد سیستم پیشنهادی نشان می دهد سازوکار کشف قوانین می تواند به جستجو قوانین بهینه خرید و فروش بپردازد. این یافته ها عمدتاً موکد آن است که تحلیل مجموعه راف در تسهیل تولید قوانین تصمیم در سازوکارهای کشف قوانین الگوریتم ژنتیک

در ارتقا قوانین تصمیم موثر واقع می شود. یافته های این مطالعه سازوکار کشف قوانین حل مسائل بهینه سازی گسستگی داده ها و ریداکت ها را در تحلیل مجموعه راف وبا استفاده از رویکرد الگوریتم ژنتیک نشان داد. با وجود آنکه در این فرایندها احتمال از بین رفتن اطلاعات وجود دارد؛ اما مدل پیشنهادی در این مطالعه بهتر از الگوریتم ژنتیک عمل می کند، زیرا اساس طراحی این مدل بالاترین نرخ سود و کمترین مقدار ریسک مجموعه داده آزمایشی بوده است. این مطالعه با حل مسائل بهینه سازی توسعه مدل های قوانین خرید و فروش را تسهیل می کند. بر طبق رویکردهای قابل مقایسه (شامل رویکردهای تصادفی، همبستگی و الگوریتم ژنتیک) و عواملی نظیر پنجره لغزان با یا بدون مجموعه داده معتبر، تعداد قوانین خرید و فروش و مدت زمان دوره آموزشی مدل پیشنهادی عملکرد مطلوبتری دارد. در نتیجه مطالعه حاضر مطالعه ای تجربی و جامع است که در مقایسه با متون فعلی دربردارنده بسیاری از مباحث سیستم خرید و فروش است. تا کنون چنین مقایسه جامعی انجام نشده بود. با این حال، داده های مالی نظیر داده های بازار سهام در پیچیده و چند بعدی بودن شهرت دارند. یافته های حاصل از این پژوهش با یافته های چن و همکاران (۲۰۰۹) و هو همکاران (۲۰۱۶) مطابقت دارد.

- \* Bemires, S.D., 2010. Fuzzy adaptive decision-making for boundedly rational trader's inspeculative stock markets. *Eur. J. Oper. Res.* 202(1), 285-293.
- \* Boyacioglu, M.A., Avci, D., 2010. An adaptive network-based fuzzy inference system (ANFIS) for the prediction of stock market return: the case of the Istanbul stock exchange. *Expert Syst. Appl.* 37, 7908-7912.
- \* Chavarnakul, T., Enke, D., 2009. A hybrid stock trading system for intelligent technicalanalysis-based equivolume charting. *Neurocomputing.* 72, 3517-3528.
- \* Chen, Y.-S., Cheng, C.-H., Chiu, C.-L., Huang, S.-T., 2016. A study of ANFIS-based multifactor time series models for forecasting stock index. *Appl. Intell.* DOI 10.1007/s10489-016-0760-8.
- \* Chen, Y., Mabu, S., Shimada, K., Hirasawa, K., 2009. A genetic network programming with learning approach for enhanced stock trading model. *Expert Syst. Appl.* 36, 12537-12546.
- \* Chiang, W.C., Enke, D., Wu, T., Wang, R., 2016. An adaptive stock index trading decision support system. *Expert Syst. Appl.* 59, 195-207.
- \* Dempster, M.A.H., Jones, C. M., 2001. A real-time adaptive trading system using genetic programming. *Quant. Financ.* 1, 397-413.
- \* Esfahanipour, A., Mousavi, S., 2011. A genetic programming model to generate risk adjusted technical trading rules in stock markets. *Expert Syst. Appl.* 38, 8438-8445.
- \* Hsu, Y., Chen, A., Chang, J., 2011. An inter-market arbitrage trading system based on extended classifier systems. *Expert Syst. Appl.* 38(4), 3784-3792.
- \* Hu, J., Pedrycz, W., Wang, G., Wang, K., 2016. Rough sets in distributed decision information systems. *Knowl. Based Syst.* 94, 13-22.
- \* Hu, Y., Feng, B., Zhang, X., Ngai, E.W.T., Ngai, M., 2015a. Stock trading rule discovery with an evolutionary trend following model. *Expert Syst. Appl.* 42, 212-222.
- \* Hu, Y., Liu, K., Zhang, X., Su, L., Ngai, E.W.T., Liu, M., 2015b. Application of evolutionary computation for rule discovery in stock algorithmic trading: A literature review. *Appl. Soft Comput.* 36, 534-551.

بنابراین، با وجود آنکه الگوریتم ژنتیک الگوریتم جستجوی رایجی است، بخاطر حجم زیاد و چند بعدی بودن داده‌ها یافتن راه حل مناسبی در فضای وسیع جستجو کاری دشوار و زمان بر بود. از این رو، قبل از جستجو یک راه حل استفاده از تکنیک‌های کاهش حجم داده نظیر روش‌های انتخاب اشیا و ویژگی‌ها ضروری بود. مدل پیشنهادی را می‌توان با تولید قوانین تصمیم مبتنی بر شرایط بازار فعلی (ترند بالا، پائین و مسطح یا راکد) توسعه داد. علاوه بر این، می‌توان با استفاده از سازوکار کشف قوانین سیستمی خبره به عنوان ابزار کشف دانش تولید کرد. بنابراین، با استفاده از یک سیستم ترکیبی دانش محور متشکل از سیستم تصمیم یار و سیستم خبره می‌توان سیستم نوین خرید و فروش را طراحی نمود.

#### فهرست منابع

- \* باتمیز، آیدا؛ فرانک حسین زاده سلجوقی؛ علی اکبر ثانوی. (۱۳۹۵). روشی جدید در تعیین ورشکستگی با استفاده از تحلیل پوششی داده‌ها و تئوری مجموعه‌های راف فازی، مجله مدل سازی پیشرفته ریاضی، مقاله ۱، دوره ۶، شماره ۱، صفحه ۲۲-۱.
- \* عباسی، فاطمه؛ اکبر عالم تبریز (۱۳۹۶). انتخاب مکان احداث شعب بانک با رویکرد تئوری مجموعه‌های راف- برنامه‌ریزی آرمانی چند انتخابه، پژوهش‌های نوین در تصمیم‌گیری، مقاله ۶، دوره ۲، شماره ۱، بهار ۱۳۹۶، صفحه ۱۱۹-۱۴۸.
- \* میرزائی، الهه؛ منصور اسماعیل پور. (۱۳۹۴). ارائه روشی ترکیبی برای افزایش دقت پیش‌بینی در کاهش داده با استفاده از مدل مجموعه راف و هوش تجمعی، فصلنامه‌پژوهش‌های دانش‌های و داده‌ها، دوره ۱۴، شماره ۳، صفحات ۵۱-۶۴.
- \* Allen, F., Karjalainen, R., 1999. Using genetic algorithms to find technical trading rules. *J. Financ. Econ.* 51, 245-271.



- \* Moshkov M.J., Piliszczuk M., Zielosko B., 2008. Partial covers, decree and decision rules in rough sets – Theory and applications. *Studies Comput. Intell.* 145, Springer.
- \* Mousavi, S., Esfahanipour, A., Zarandi, M. H. F., 2014. A novel approach to dynamic portfolio trading system using multitree generic programming. *Knowl. Based Syst.* 66, 68-81.
- \* Nguyen H.S., Skowron A., 1995. Quantization of real values attributes rough set and Boolean reasoning approach. *Proc. 2nd Joint Annual Conf. Inf. Sci., Wrightsville Beach, NC, 1995*, 34-37.
- \* Oh, K. J., Kim, T. Y., Min, S. -H., Lee, H. Y., 2006. Portfolio algorithm based on portfolio beta using generic algorithm. *Expert Syst. Appl.* 30, 527-534.
- \* Ozturk, M., Toroslu, I. H., Fidan, G., 2016. Heuristic based trading system on Forex data using technical indicator rules. *Appl. Soft Comput.* 43, 170-186.
- \* Pardo, R., 2008. The evaluation and optimization of trading strategies. Wiley.
- \* Pawlak, Z., 1982. Rough sets. *Int. J. Comput. Inf. Sci.* 11, 341-356.35
- \* Pawlak, Z., 2002. Rough sets and intelligent data analysis. *Inf. Sci.* 147, 1-12.
- \* Pawlak, Z., Grzymala-Busse, J., Sloinski, R., Ziarko, W., 1997. Rough set. *Commun.ACM.* 38(11), 88-95.
- \* Sharpe, W.F., 1994. The Sharpe ratio. *J. Portfolio Manage.* 21, 49-58.
- \* Shen, L., Loh, H. T., 2004. Applying rough sets to market timing decisions. *Decis.Support Syst.* 37, 583-597.
- \* Wang, F., Yu, P. L.H., Cheung, D. W., 2014. Combining technical trading rules using particle swarm optimization. *Expert Syst. Appl.* 41, 3016-3026.
- \* Wiles, P.S., Enke, D., 2015. A hybrid neuro-fuzzy model to forecast the soybean complex. *Proceedings of the 2015 American Society of Engineering Management conference, Indianapolis, IN, October.*
- \* Wiles, P.S., Enke, D., 2015. Optimizing MACD parameters via genetic algorithms for soybean futures. *Procedia Comput. Sci.* 61, 85-91.
- \* Yao, J., Herbert, J.P., 2009. Financial time-series analysis with rough sets. *Appl. Soft Comput.* 9, 1000-1007.
- \* Jia, X., Shang, L., Zhou, B., Yao, Y., 2016. Generalized attribute reduct in rough set theory. *Knowl. Based Syst.* 91, 204-218.
- \* Jing, Y., Li, T., Luo, C., Horng, S.-J., Wang, G., Yu, Z., 2016. An incremental approach for attribute reduction based on knowledge granularity. *Knowl. Based Syst.* 104, 24-38.
- \* Kim, K.-j., Ahn, H., 2012. Simultaneous optimization of artificial neural networks for financial forecasting. *Appl. Intell.* 36, 887-898.
- \* Kim, K., Han, I., 2000. Genetic algorithms approach to feature discretization in artificial neural networks for the prediction of stock price index. *Expert Syst. Appl.* 19(2), 125-132.
- \* Kim, Y., Enke, D., 2016. Developing a rule change trading system for the futures market using rough set analysis. *Expert Syst. Appl.* 59, 165-173.
- \* Kotsiantis, S., Kanellopoulos, D., 2006. Discretization techniques: A recent survey. *GESTS Int. Trans. Comput. Sci. Eng.* 32(1), 47-58.
- \* Lai R.K., Fan C., Huang W., Chang P., 2009. Evolving and clustering fuzzy decision tree for financial time series data forecasting. *Expert Syst. Appl.* 36, 3761-3773.
- \* Lee, S. J., Ahn, J. J., Oh, K. J., Kim, T. Y., 2010. Using rough set to support investment strategies of real-time trading in futures market. *Appl. Intell.* 32, 364-77.34.
- \* Lee, S. J., Oh, K. J., Kim, T. Y., 2012. How many reference patterns can improve profitability for real-time trading in futures market? *Expert Syst. Appl.* 39, 7458-7470.
- \* Luo, C., Li, T., Yi, Z., Fujita, H., 2016. Matrix approach to decision-theoretic rough sets for evolving data. *Knowl. Based Syst.* 99, 123-134.
- \* Mabu, S., Hirasawa, K., Obayashi, M., Kuremoto, T., 2013. Enhanced decision making mechanism of rule-based genetic network programming for creating stock trading signals. *Expert Syst. Appl.* 40, 6311-6320.
- \* Mehdiyev, N., Enke, D., 2014. Interest rate prediction: A neuro-hybrid approach with data preprocessing. *Int. J. Gen. Sys.* 43(5), 535-550.
- \* Menkhoff, L., 2010. The use of technical analysis by fund managers: International evidence. *J. Bank. Financ.* 34(11), 2573-2586.

- \* Zhang, X., Y. Hu, K. Xie, W. Zhang, L. Su, Liu, M., 2015. An evolutionary trend reversion model for stock trading rule discovery. *Knowl. Based Syst.* 79, 27-35.
- \* Zhong, N., Dong, J., 2001. Using rough sets with heuristics for feature selection. *J. Intell. Inf. Syst.* 16, 199-214