

پیش‌بینی روند قیمت سهام با استفاده از ماشین بردار پشتیبان تعديل‌یافته همراه با انتخاب ویژگی هیبرید

سعید باجلان^{*}، سعید فلاحپور^{**}، ناهید دانا^{***}

چکیده

در پژوهش حاضر، مدلی برای پیش‌بینی روند قیمت سهام برپایه‌ی ماشین بردار پشتیبان وزن‌دهی شده توسط حجم‌های روزانه معاملات، همراه با روش انتخاب ویژگی هیبرید F-SSFS ارائه می‌شود. به منظور ارزیابی دقت پیش‌بینی، مدل پیشنهادی با مدل ماشین بردار پشتیبان ساده همراه با انتخاب ویژگی هیبرید و نیز با روش‌های انتخاب ویژگی مرسوم از جمله بهره اطلاعات^۱، عدم قطعیت متقارن^۲ و انتخاب ویژگی بر پایه همبستگی^۳، از طریق انجام آزمون تی زوجی، مقایسه می‌شود؛ همچنین به عنوان مجموعه ویژگی‌های اولیه که در واقع ورودی ماشین بردار پشتیبان تعديل‌یافته هستند، از شاخص‌های تحلیل تکنیکال و شاخص‌های آماری که برای ۱۰ سهم محاسبه شده‌اند، استفاده می‌شود. نتیجه این پژوهش نشان می‌دهد که عملکرد ماشین بردار پشتیبان وزن‌دهی شده، در مورد مسئله پیش‌بینی روند قیمت سهام، به میزان قابل توجهی بهتر از ماشین بردار پشتیبان ساده است. علاوه بر این، نتایج عملیاتی نشان می‌دهد که ماشین بردار پشتیبان وزن‌دهی شده همراه با انتخاب ویژگی هیبرید پیشنهادی، بالاترین میزان دقت پیش‌بینی را نسبت به سه روش انتخاب ویژگی دیگر دارد. براساس نتایج این پژوهش می‌توان ادعا کرد مدل VW-SVM همراه با انتخاب ویژگی F-SSFS عملکرد بهتری در پیش‌بینی قیمت سهم، نسبت به روش‌های موجود دارد.

کلیدواژه‌ها: پیش‌بینی روند؛ ماشین بردار پشتیبان؛ انتخاب ویژگی؛ قیمت سهم.

تاریخ دریافت مقاله: ۱۳۹۵/۰۶/۲۳، تاریخ پذیرش مقاله: ۱۳۹۵/۱۲/۱۳

* استادیار گروه مالی و بیمه، دانشکده مدیریت دانشگاه تهران.

** استادیار گروه مالی و بیمه، دانشکده مدیریت دانشگاه تهران.

*** کارشناس ارشد مهندسی مالی، دانشگاه تهران (نویسنده مسئول).

E-mail: nahiddana@gmail.com

2. Information Gain

3. Symmetrical uncertainty

4. Correlation based feature selection

۱. مقدمه

پیش‌بینی قیمت سهام و حرکات و روند آن، همواره به عنوان یکی از چالش برانگیزترین حوزه‌های به کارگیری پیش‌بینی با استفاده از سری‌های زمانی مطرح بوده است. هرچند که تاکنون، پژوهش‌های داخلی و خارجی بسیاری در ارتباط با پیش‌بینی قیمت سهم و شاخص انجام شده است، پژوهش‌های انجام شده در حوزه پیش‌بینی جهت حرکت و روند قیمت و یا شاخص بسیار اندک است. به خصوص در ارتباط با بازار داخلی کشور، تعداد پژوهش‌هایی که به این موضوع پرداخته‌اند بسیار محدود است و نیاز به تحقیقات بیشتر در این زمینه وجود دارد. پیش‌بینی دقیق جهت تغییرات قیمت، در ارائه استراتژی معاملاتی سودمند، بسیار با اهمیت است [۱۸].

در میان فرآیندهای پیش‌بینی سری‌های زمانی، پیش‌بینی قیمت سهام به علت اینکه بازار سهام اساساً پویا، غیرخطی، پیچیده، غیرپارامتریک و ماهیتا تصادفی است، جزء پیچیده‌ترین فرآیندها است [۱].

علاوه بر این، بازار سهام تحت تاثیر عوامل اقتصاد کلان بسیاری از جمله رخدادهای سیاسی، شرایط کلی اقتصادی، انتظارات سرمایه‌گذاران، انتخاب‌های سرمایه‌گذاران نهادی، حرکات سایر بازارهای سهام و روان‌شناسی سرمایه‌گذاران است [۲۱].

پژوهش‌های اخیر در زمینه پیش‌بینی روند تغییرات قیمت سهام حاکی از برتری روش‌های جدید داده کاوی و مدل‌های غیرخطی نسبت به روش‌های سنتی مانند لوجیت، پروبیت و گام تصادفی دارند. ماشین بردار پشتیبان که در ۱۹۹۵ توسط وینیک پیشنهاد شد، یک تکنیک یادگیری ماشینی نسبتاً جدید است که امکان به کارگیری در حوزه وسیعی از مسائل را دارد. این تکنیک توانایی رسیدن به جواب بهینه با حجم داده آموزش کم را نیز دارد.

طبق مطالعات صورت‌گرفته و تجارب فعالان بازار سهام، روندهای قیمتی در بازار سهام تحت تاثیر حجم معاملات سهم هستند و دخالت‌دادن این پارامتر در طبقه‌بندی کننده، به میزان چشمگیری دقت پیش‌بینی تغییرات روند قیمت را بهبود می‌دهد [۲]. نتایج پژوهش‌ها نشان داده است که رابطه‌ای منفی بین حجم معاملات و نوسان پذیری وجود دارد و استفاده از متost حجم معاملات می‌تواند عملکرد پیش‌بینی نوسانات و در نتیجه بهینه‌سازی بازده را بهبود دهد [۱۰]. علاوه بر این، پژوهش بدri و همکارانش (۱۳۹۵)، نشان داد که رابطه علی‌یک طرفه‌ای از سمت متغیرهای کلان اقتصاد به سمت ارزش جاری بازار سهام و حجم معاملات بازار سهام وجود دارد [۲].

هرچند که طبق پژوهش‌های انجام شده، ماشین بردار پشتیبان عملکرد قابل قبولی در

پیش‌بینی و طبقه‌بندی دارد؛ اما دقت عملکرد آن به میزان قابل توجهی تحت تاثیر تعداد متغیرهای ویژگی ورودی آن است؛ بنابراین کاهش تعداد ویژگی‌هایی که باید در آموزش ماشین بردار پشتیبان به کار گرفته شود، تاثیر بهسازی در افزایش دقت نتایج و کاهش هزینه دارد [۱۹، ۲۵]؛ لذا یکی از بهبودهایی که در مطالعات جدید، با توجه به پیشرفت‌های کاربرد روش‌های هوش مصنوعی به کار گرفته شده است، استفاده از انتخاب ویژگی به عنوان یک پیش مرحله برای مدل طبقه‌بندی کننده اصلی می‌باشد.

این پژوهش به پیش‌بینی روندهای قیمتی بازار سهام، با استفاده از ماشین بردار پشتیبان وزن‌دهی شده با حجم معاملات همراه با روش انتخاب ویژگی هیبرید می‌پردازد. در ادامه، نتایج آن با نتایج ماشین بردار پشتیبان ساده همراه با این روش انتخاب ویژگی و سایر تکنیک‌های انتخاب ویژگی عنوان شده، مقایسه می‌شود.

۲. مبانی نظری و پیشینه پژوهش

انتخاب ویژگی. به طور کلی الگوریتم‌های انتخاب ویژگی به دو دسته تقسیم می‌شوند: اول، روش‌های فیلتر کننده [۷، ۲۳] و دوم، روش‌های پوششی [۱۵]. روش‌های فیلتر کننده، احتیاج به هیچ بازخوردی از طبقه‌بندی کننده ندارند و این روش، عملکرد طبقه‌بندی را به وسیله یکسری روش‌های ارزیابی غیرمستقیم، مثل شاخص‌های فاصله‌ای که نشان‌دهنده میزان تفکیک شدگی صحیح طبقات از یکدیگر می‌باشند، تخمین می‌زنند [۱۳]؛ اما برخلاف این‌ها، روش‌های پوششی، وابسته به طبقه‌بندی کننده هستند و بسته به دقت آن، میزان «خوبی» زیرمجموعه انتخاب شده را مستقیماً می‌سنجند. در مورد این دو روش باید گفت که نتایج بسیاری از بسیاری، برتری روش‌های پوششی را بر فیلتر کننده، ثابت کرده‌اند [۱۶، ۲۰]؛ اما با وجود عملکرد خوب روش‌های پوششی، به علت پیچیدگی محاسباتی بالایی که به همراه دارند، کاربردهایشان محدود است. در این پژوهش به منظور بهره‌گیری از مزایای هر دو روش فیلتر کننده و پوششی، از یک روش انتخاب ویژگی هیبریدی به نام روش FSSFS^۱ متشکل از انتخاب ویژگی فیشر به عنوان بخش فیلتر کننده و روش جستجوی ترتیبی پیشرو پشتیبانی شده به عنوان بخش پوششی، استفاده می‌شود.

روش فیشر. روش انتخاب ویژگی فیشر که در این پژوهش به عنوان بخشی از فرآیند انتخاب ویژگی هیبرید پیشنهاد شده است، یک روش فیلتر کننده ساده اما پایه‌ای است که میزان تمایز و

1. F-score-supported sequential forward search

تفاوت بین دو مجموعه داده را می‌سنجد [۵]. روش انتخاب ویژگی فیشر، برای هر ویژگی در مجموعه اویله از ویژگی‌ها، با توجه به تساوی زیر، یک امتیاز محاسبه می‌کند. با داشتن بردار داده‌های آموزش به صورت x_k و n_+ و n_- به ترتیب، به عنوان تعداد نمونه‌های $k=1,2,\dots,m$ مثبت و تعداد نمونه‌های منفی امتیاز فیشر برای آمین ویژگی به صورت زیر محاسبه می‌شود:

$$F(i) \equiv \frac{(\bar{x}_i^{(+)} - \bar{x}_i)^2 + (\bar{x}_i^{(-)} - \bar{x}_i)^2}{\frac{1}{n_{+}-1} \sum_{k=1}^{n_+} (x_{k,i}^{(+)} - \bar{x}_i^{(+)})^2 + \frac{1}{n_{-}-1} \sum_{k=1}^{n_-} (x_{k,i}^{(-)} - \bar{x}_i^{(-)})^2}$$

که در این عبارت، $\bar{x}_i^{(+)}$ و $\bar{x}_i^{(-)}$ به ترتیب میانگین کل و میانگین ویژگی‌های مثبت و منفی می‌باشد و $x_{k,i}^{(+)}$ و $x_{k,i}^{(-)}$ ویژگی آن از k آمین ویژگی به ترتیب مثبت و منفی است. صورت کسر در تساوی بالا، تمایز بین مجموعه‌های مثبت و منفی را نشان می‌دهد و مخرج کسر تفاوت‌ها را در داخل هر یک از دو مجموعه مثبت و منفی اندازه‌گیری می‌کند. هرچه میزان امتیاز فیشر محاسبه شده برای هر ویژگی بیشتر باشد، احتمال این که آن ویژگی بتواند کمک بیشتری به فرآیند طبقه‌بندی بکند، بیشتر است.

روش انتخاب ویژگی جست‌وجوی ترتیبی پیشرو پشتیبانی‌شده. جست‌وجوی ترتیبی پیشرو پشتیبانی‌شده، همان جست‌وجوی ترتیبی پیشرو که نوعی از روش‌های انتخاب ویژگی پوششی است، می‌باشد که به صورت یک‌پارچه با ماشین بردار پشتیبان وزن‌دهی شده در آمده است. در این بخش به توضیح مختصر این فرآیند انتخاب ویژگی پرداخته می‌شود. ابتدا ماشین بردار پشتیبان وزن‌دهی شده با حجم معاملات را به تعداد k بار برای هر ویژگی f_i آموزش داده، تا بهترین ویژگی انتخاب شود. از لحاظ ریاضیاتی به عنوان مجموعه داده‌های آموزش داریم،

$$F_1^i = f_i, f_i \in F$$

۹

$$V_1^i = \{1, 2, \dots, N\}$$

از آنجاکه بردار ورودی یک بعدی است، حجم و پیچیدگی محاسباتی بسیار اندک است. پس از انجام این آموزش، ویژگی‌ای که طبقه‌کننده به ازای آن بهترین عملکرد را داشته باشد، به عنوان «اولین، بهترین» ویژگی انتخاب می‌شود؛ بنابراین پس از اولین مرحله، برای زیر مجموعه اویله از ویژگی‌ها و مجموعه آموزش مرتبط با آن خواهیم داشت $\{f_i\} = F_1$ و $\{v_j\} = V_1$. برای

اضافه کردن ویژگی به این زیرمجموعه اولیه ویژگی، به صورت زیر عمل می‌شود:

$$\begin{aligned} F_{n+1}^i &= F_n \cup \{f_i\} \text{ for } f_i \in F_n^{av} \\ V_{n+1}^i &= V_n \cup \{v_i\} \end{aligned}$$

و برای هریک از ویژگی‌های باقی‌مانده این عملیات یک بار تکرار می‌شود و سپس ویژگی‌ای که به ازای اضافه شدن آن به مجموعه قبلی بهترین عملکرد برای طبقه‌بندی کننده حاصل شود، به عنوان ویژگی جدید به زیرمجموعه ویژگی‌ها اضافه می‌شود و این فرآیند تا زمانی ادامه می‌یابد که هیچ بهبود قابل توجهی در عملکرد مدل حاصل نشود.

سایر روش‌های انتخاب ویژگی مرتبط. در این پژوهش از سه روش انتخاب ویژگی برای مقایسه با روش انتخاب ویژگی هیبرید پیشنهادی استفاده می‌شود. این سه روش که روش‌های آماری برای انتخاب ویژگی هستند، به شرح زیر می‌باشند [۱۳]:

بهره اطلاعات: این روش، اهمیت هر ویژگی را با استفاده از اندازه‌گیری اینکه هر ویژگی، به چه میزان توان تقسیم‌بندی داده‌ها به طبقات هدف را دارد، اندازه‌گیری می‌کند. بهره اطلاعات به صورت زیر محاسبه می‌شود:

$$InfoGain = H(Y) - H(Y|X)$$

که در آن X و Y ویژگی‌ها هستند و داریم:

$$\begin{aligned} H(Y) &= - \sum_{y \in Y} p(y) \log_2(p(y)) \\ H(Y) &= - \sum_{x \in X} p(x) \sum_{y \in Y} p(y|x) \log_2(p(y|x)) \end{aligned}$$

عدم قطعیت متقارن: از این تابع برای سنجش میزان توانایی تفکیک‌کنندگی هر ویژگی استفاده می‌شود. ویژگی با بیشترین مقدار تابع، دارای بیشترین توان تفکیک‌کنندگی است.

$$SU = 2.0 * \frac{InfoGain}{H(Y) + H(X)}$$

انتخاب ویژگی بر پایه همبستگی: این روش، یک زیرمجموعه از ویژگی‌ها را با در نظر گرفتن توانای پیش‌بینی فردی آن ویژگی همراه با درجات افزونگی میان آن‌ها، ارزیابی می‌کند:

$$CFS_s = \frac{k \bar{r}_{cf}}{\sqrt{k + k(k-1)\bar{r}_{ff}}}$$

که در آن CFS_s میزان امتیاز هر زیرمجموعه ویژگی، S شامل k ویژگی می‌باشد و \bar{r}_{cf} میانگین همبستگی ویژگی کلاس ($f \in S$) و \bar{r}_{ff} میانگین همبستگی متقابل ویژگی-ویژگی است. تفاوت بین الگوریتم‌های فیلتری معمول و CFS این است که الگوریتم‌های معمولی برای هر ویژگی یک امتیاز مجزا محاسبه می‌کنند؛ در حالی که CFS یک «مریت^۱» هیوریستیک برای هر زیرمجموعه محاسبه می‌کند و مشخص می‌کند که کدام زیرمجموعه از همه بهتر است.

ماشین بردار پشتیبان وزن دهنده: در ارتباط با ماشین بردار پشتیبان در منابع داخلی و خارجی بسیاری از [۸، ۱۳] و بسیاری مقالات و منابع دیگری توضیحات لازم ارائه شده است که در اینجا به منظور جلوگیری از اطناپ تنها به توضیح مدل ماشین بردار پشتیبان وزن دهنده شده پرداخته می‌شود.

هدف اصلی الگوریتم ماشین بردار پشتیبان، یافتن ابرصفحه جداکننده‌ای است که با حل مسئله بهینه‌سازی زیر، حاشیه‌ی $\|w\|$ را بیشینه کند. در این راستا از اصول کمینه‌سازی ریسک که [۶] مورد بحث قرار گرفته است، استفاده می‌کند.

$$\min \frac{1}{2\|w\|^2} + \sum_{i=1}^m C_i \xi_i,$$

با محدودیت:

$$y_i(wx_i - b) \geq 1 - \xi_i \\ \xi_i \geq 0$$

که در آن ξ متغیر اسلک غیر صفر است و C یک پارامتر جریمه برای هر ورودی مشخص x_i و y_i مقدار هدف مربوط به آن است. در ماشین بردار پشتیبان تعديل شده با وزن دار کردن تابع جریمه

1. Merit

توسط حجم معاملات که در این پژوهش از آن استفاده می‌کنیم، عبارت جریمه به صورت زیر تعریف می‌شود:

$$C_i = V_i C$$

که در آن داریم، V_t ، که در آن V_t نشان‌دهنده حجم معامله شده از سهم در روز t و d طول پنجره زمانی معاملاتی است. با استفاده از ضرایب لاغرانژ α_i و μ_i می‌توان مسئله بهینه‌سازی به صورت زیر بازنویسی می‌شود:

$$\max L(w, b, \alpha) = \frac{1}{2||w||^2} + C \sum_{i=1}^m \xi_i - \sum_{i=1}^m \alpha_i (y_i (wx_i - b) - 1 + \xi_i) - \sum_{i=1}^m \mu_i \xi_i$$

با محاسبه مشتقات جزئی، می‌توان دوگان این مسئله را به صورت زیر نوشت:

$$Q(\alpha) = \sum_{i=1}^m \alpha_i - 1/2 \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j \varphi(x_i) \varphi(x_j)$$

که این مسئله باید با درنظرگرفتن محدودیت‌های زیر بیشینه شود:

$$\begin{aligned} \sum_{i=1}^m \alpha_i y_i &= 0 \\ \alpha_i &\geq 0 \end{aligned}$$

پیشینه پژوهش. با وجود اینکه مدل‌های آماری توانسته‌اند پیش‌بینی‌های نسبتاً خوبی را در مورد قیمت ارائه دهند؛ اما مفروضات محدود کننده‌ای که در برخی از این مدل‌ها وجود دارد، برآثر بخشی آن‌ها موثر بوده و در نتیجه، به تدریج روش‌های دیگری برای مقابله با این محدودیت‌ها و بهبود عملکرد پیش‌بینی‌ها ارائه شد. با توجه به نتایج پژوهش‌های داخلی و خارجی بسیاری، برتری روش‌های ماشین بردار پشتیبان بر روش‌هایی از جمله روش شبکه‌های عصبی مصنوعی و نیز روش‌های آماری ثابت شده است [۸، ۱۹]؛ بنابراین در ادامه به ذکر پژوهش‌هایی که بیشترین ارتباط را با موضوع مورد بررسی دارند پرداخته می‌شود.

بریو و باتر به منظور مقایسه عملکرد مدل‌های پیش‌بینی کننده ماشین بردار پشتیبان و شبکه عصبی انتشار پسرو، اقدام به پیش‌بینی شاخص نزدک با استفاده از انتخاب ویژگی با روش آنالیز مولفه اصلی و آنالیز عاملی^۱، بر روی شاخص‌های تکنیکال کردند که نتایج نشان‌دهنده برتری ماشین بردار پشتیبان بود.

استفاده از ترکیب ماشین بردار پشتیبان و الگوریتم ژنتیک به منظور پیش‌بینی روند حرکت قیمت سهام نشان داد که دقت مدل ترکیبی از مدل ماشین بردار پشتیبان به تنها یی بیشتر است [۶].

هوانگ و همکارانش (۲۰۱۱)، اقدام به پیش‌بینی قیمت سهم با استفاده از روش انتخاب ویژگی پوششی همراه با یک سیستم مرکب از چندین طبقه‌بندی کننده، شامل ماشین بردار پشتیبان و شبکه عصبی کردند. نتایج آن‌ها نشان داد که دقت پیش‌بینی‌ها با استفاده از روش انتخاب ویژگی پوششی نسبت به روش‌های فیلتر کننده مختلف بالاتر است [۱۳].

مینگ (۲۰۰۹)، با هدف پیش‌بینی روند تغییرات قیمت شاخص نزدک، اقدام به انجام پژوهشی با ترکیب مدل ماشین بردار و انتخاب ویژگی هیبرید حاصل از ترکیب انتخاب ویژگی فیشر و جست‌وجوی ترتیبی پیشروی پشتیبانی شده، نمود. به عنوان ویژگی‌های ورودی مدل وی از ۳۰ سهم موجود در این شاخص استفاده نمود، نتایج پژوهش مینگ نشان داد که استفاده از ماشین بردار پشتیبان همراه با انتخاب ویژگی هیبرید دقت بیشتری در پیش‌بینی روند نسبت به شبکه عصبی انتشار پسرو و نیز استفاده از سایر روش‌های انتخاب ویژگی دارد [۱۷].

در پژوهش دیگری که منظور ارزیابی و مقایسه روش انتخاب ویژگی فرکتال^۲ با سایر روش‌ها، از جمله رلیف^۳، سی‌اف‌اس^۴ و چند روش دیگر، با استفاده از طبقه‌بندی کننده ماشین بردار پشتیبان توسط لیونگ انجام شد، برتری روش فرکتال بر سایر روش‌های فلت‌تری انتخاب ویژگی اثبات شد [۱۸].

در پژوهشی که توسط زیکوسکی (۲۰۱۴) انجام شد، از ماشین بردار پشتیبان وزن دهنده شده با حجم معاملات واقعی روزانه، همراه با انتخاب ویژگی فیشر، به منظور پیش‌بینی روند استفاده شد. وی به عنوان ورودی از ۷ شاخص تحلیل تکنیکال به منظور پیش‌بینی روند قیمت سهام استفاده نمود. وی با نشان‌دادن برتری عملکرد مدل پیشنهادی خود، برتری این مدل را بر مدل ماشین بردار پشتیبان ساده و ماشین بردار پشتیبان بدون انتخاب ویژگی را اثبات نمود [۲۴].

1. Factor analysis

1. Fractal

2. Relief

3. CFS

در ایران در حوزه مطالعات پیش‌بینی روند، می‌توان به پژوهش فلاح‌پور، گل‌ارضی و فتوره‌چیان (۱۳۹۲)، اشاره نمود. آن‌ها اقدام به پیش‌بینی روند حرکت و تغییرات قیمت سهام در بازار بورس اوراق بهادار تهران نمودند. آن‌ها متغیرهای ورودی ماشین بردار پشتیبان را توسط الگوریتم ژنتیک، بهینه‌سازی نمودند. نتایج پژوهش آن‌ها نشان داد که ماشین بردار پشتیبان برپایه الگوریتم ژنتیک، دقت بسیار بیشتری در پیش‌بینی نسبت به ماشین بردار پشتیبان ساده دارد [۱۱].

در پژوهشی که توسط منجمی، ابرازی و رعیتی (۱۳۸۸)، انجام شد، قیمت سهام در بازار بورس اوراق بهادار، توسط شبکه عصبی فازی و الگوریتم ژنتیک، پیش‌بینی شد. نتایج پژوهش آن‌ها نشان داد که مدل ترکیبی پیشنهادی هم از لحاظ دقت و هم از لحاظ سرعت عملکرد بهتری دارد [۲۰].

در پژوهشی که توسط عبادی (۱۳۸۸)، برای پیش‌بینی شاخص قیمت سهام بازار بورس تهران، با استفاده از شبکه‌های عصبی مصنوعی انجام شد، مشخص شد که شبکه عصبی عملکرد خوبی در پیش‌بینی این شاخص دارد [۹]. همچنین در پژوهش دیگری که به منظور مطالعه تاثیر عوامل رفتاری بر قیمت سهام توسط هاشمی (۱۳۸۹) بر روی سهام ۱۰ شرکت از شرکت‌های شاخص داوجونز انجام شد، مشخص شد که عوامل رفتاری در قیمت ۹ سهم از ۱۰ سهم موثر بود و مدنظر قرار دادن آن‌ها منجر به افزایش دقت پیش‌بینی می‌شود [۱۴].

۳. روش‌شناسی پژوهش

در مجموع مراحل کار در این پژوهش را از انتخاب ویژگی با روش پیشنهادی تا طبقه‌بندی با استفاده از مدل ماشین بردار پشتیبان وزن‌دهی شده، می‌توان به صورت زیر جمع‌بندی و خلاصه کرد. ابتدا مقدار امتیاز فیشر برای هر ویژگی f_i محاسبه می‌شود.

سپس، امتیازهای محاسبه شده را به ترتیب نزولی مرتب می‌کنیم و تعداد k ویژگی اول را که عبارت است از $K = \left[i * \frac{|F|}{4} \right] \in \{1, 2, \dots, m\}$ برای $|F|$ تعداد کل ویژگی‌ها می‌باشد و m بزرگترین عدد صحیحی می‌باشد که در رابطه‌ی $1 / 2^m \geq 1$ صدق کند.

در مرحله بعد، ویژگی با بیشترین امتیاز را برای ساخت F_n^{av} انتخاب می‌کنیم.

پس از انتخاب اولین ویژگی، ویژگی بعدی را که باید به F_n^{av} اضافه کنیم، با توجه به تساوی $F_{n+1}^i = F_n \cup \{f_i\}$ ، برای $V_{n+1}^i = V_n \cup \{v_i\}$ و $f_i \in F_n^{av}$ ، همان‌طور که در زیربخش توضیح روش انتخاب ویژگی جست‌وجوی ترتیبی پیشرو پشیبانی شده، توضیح دادیم انتخاب می‌کنیم.

پس از آن مجموعه داده‌های آموزش را با استفاده از $V_{n+1} = F_{n+1}^j$ و SV_{n+1}^j بروزرسانی می‌کنیم و متوسط دقت طبقه‌بندی را محاسبه می‌کنیم. این مراحل را تا جایی تکرار می‌کنیم که هیچ افزایش قابل توجهی در دقت طبقه‌بندی ایجاد نشود.

پس از انتخاب زیرمجموعه بهینه از ویژگی‌ها، مدل ماشین بردار پشتیبان وزن‌دهی شده با حجم معاملات را با استفاده از زیرمجموعه انتخاب شده، آموزش می‌دهیم، تا طبقه‌بندی کننده ماشین بردار پشتیبان وزن‌دهی شده را به دست آوریم؛ سپس دقت طبقه‌بندی را برآورد می‌کنیم. در جدول ۱، به صورت خلاصه، شاخص‌های تحلیل تکنیکالی که به عنوان بردارهای ورودی ماشین بردار پشتیبان، استفاده می‌کنیم، ارائه شده است. لازم به ذکر است که در عباراتی که در ادامه می‌آید، P_t^C ، P_t^L ، P_t^H و P_t^O به ترتیب نشان‌دهنده مقادیر مربوط به قیمت شروع، بالاترین قیمت، پایین‌ترین قیمت و قیمت پایان روز می‌باشند.

جدول ۱. شاخص‌های تحلیل تکنیکال به عنوان ویژگی‌های ورودی فرآیند پیشنهادی

نام شاخص	نحوه محاسبه	توضیحات
حجم جاری معاملات، یک شاخص		
آنی است که میزان افزایش و کاهش حجم معاملات را اندازه‌گیری می‌کند و روندهای حجم و قیمت را به یکدیگر مرتبط می‌سازد	$OBV_t = OBV_{t-1} + V_t, \text{ آنگاه } P_t^C > P_{t-1}^C$ $OBV_t = OBV_{t-1} - V_t, \text{ آنگاه } P_t^C < P_{t-1}^C$ $OBV_t = OBV_{t-1}, \text{ آنگاه } P_t^C = P_{t-1}^C$	حجم جاری معاملات OBV
شاخصی است که میزان نوسانات را برای دوره مورد نظر محاسبه می‌کند و براساس یک شاخص کمکی به نام دامنه واقعی (TR) به دست می‌آید	$TR_t = \max\{P_t^H - P_t^L, P_t^H - P_t^{C-1}, P_t^L - P_t^{C-1}\}$ $ATR_t^n = \frac{1}{n \sum_{i=0}^n TR_{t-i}}$	دامنه متوسط وقوعی ATR
معامله‌گران از شاخص قدرت نسبی، به منظور تعیین وضعیت‌های اشباع خرید و یا فروش استفاده می‌کنند	$RSI_t^n = 100 - \frac{100}{1 - RS_t^n}$ $RS_t^n = \frac{\sum_{t=0}^n U_t}{\sum_{t=0}^n D_t}$ که در آن: $U_t = P_t^C - P_{t-1}^C, \text{ آنگاه } P_t^C > P_{t-1}^C$ $D_t = P_{t-1}^C - P_t^C, \text{ آنگاه } P_t^C > P_{t-1}^C$	شاخص قدرت نسبی RSI

از این شاخص برای تعیین میزان قدرت و پایداری روند فعلی و از آن مهم‌تر برای زمانی که روند آماده تغییر جهت استفاده می‌شود.	$\%R = 100 * \frac{\max P_t^n - P_t}{\max P_t^n - \min P_t^n}$ <p style="text-align: center;">که در آن داریم،</p> $\text{Max } P_t^n = \max\{P_t, P_{t-1}, \dots, P_{t-n}\}$ $\text{Min } P_t^n = \min\{P_t, P_{t-1}, \dots, P_{t-n}\}$	نوسان‌گر %R ویلیام
شاخص ورتکس نشان‌دهنده تغییر جهت‌ها است. ایده اصلی آن است که اعلانات متوالی از بازار می‌تواند حاوی اطلاعاتی در مورد جهت روند باشد	$V_t^{n(+)} = \frac{\sum_{k=0}^d (P_{t-k}^H - P_{t-k}^L)}{\sum_{k=0}^d TR_{t-k}}$ $V_t^{n(+)} = \frac{\sum_{k=0}^d (P_{t-k}^L - P_{t-k}^H)}{\sum_{k=0}^d TR_{t-k}}$	شاخص ورتکس
به طور ساده، عایدی یک سرمایه‌گذاری، نرخ بازده n روزه R_t^n است و ریسک مرتبط با آن انحراف استاندارد این بازده‌ها در طول یک دوره n روزه است	$R_t^n = \ln \frac{P_t^C}{P_{t-n}^C}$ $\sigma_t^n = \sqrt{\frac{\sum_{i=1}^n (P_{t-i}^C - \bar{P})^2}{n}}$	نرخ بازده و انحراف استاندارد

پس از محاسبه و به دست آوردن مقادیر مربوط به هر یک از بردارهای ورودی، با توجه به اینکه مقادیر مربوط به دامنه تغییرات هریک از شاخص‌ها متفاوت است، برای افزایش دقت پیش‌بینی، احتیاج به نرمال‌سازی داده‌ها داریم، نرمال‌سازی داده‌ها دقت طبقه‌بندی کننده SVM را افزایش می‌دهد [۲۲]. نرمال‌سازی را به صورت زیر انجام می‌دهیم [۲۲]:

$$x'_i = L + (U - L) \frac{x_i - m_i}{M_i - m_i}$$

که در آن $R \in \mathbb{U}$ و $L \in \mathbb{U}$ و m_i و M_i به ترتیب نشان‌دهنده مقادیر بیشینه و کمینه هر ویژگی می‌باشد و به صورت زیر تعریف می‌شود:

$$M^f = \max\{x_i\}$$

$$m_i = \min\{x_i\}$$

فرضیه پژوهش. فرضیه پژوهش حاضر، به صورت زیر بیان می‌شود:

دقت پیش‌بینی قیمت سهام، با استفاده از روش انتخاب ویژگی هیبرید، همراه با ماشین بردار پشتیبان وزن‌دهی شده با حجم روزانه معاملات از سایر روش‌های رقیب بیشتر می‌باشد.

۴. یافته‌های پژوهش

در ادامه نتایج پژوهش در دو بخش که اولی مربوط به انتخاب ویژگی با روش پیشنهادی و سپس مقایسه دقت پیش‌بینی روش پیشنهادی با روش‌های رقیب می‌باشد، آورده شده است. داده‌های مورد استفاده در این پژوهش، مربوط به ۱۰ سهم انتخاب شده، از بین سهام شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران، می‌باشد. داده‌های روزانه هر سهم از بازه ۱۳۸۴/۰۸/۰۱ تا ۱۳۹۴/۰۸/۳۰ جمع آوری شده است؛ همچنین سهم‌ها از بین سهام شرکت‌های بورسی منهای بانک‌ها و سرمایه‌گذاری‌ها انتخاب شده‌اند. از داده‌های روزانه ۸ سال نخست برای آموزش شبکه و از داده‌های ۲ سال آخر برای تست استفاده شده است.

نتایج مربوط به دقت انتخاب ویژگی با استفاده از الگوریتم هیبرید فیشر و جستجوی ترتیبی پیش‌رو برابر پایه ماشین بردار پشتیبان. همان‌طور که در بخش ۳ در مورد فرآیند انتخاب ویژگی توضیح داده شد، k به عنوان مقدار آستانه ویژگی‌های انتخابی، مقدار ۴، ۲ و ۶ که حالت حدی‌ای است که در آن انتخاب ویژگی هیچ تاثیری بر مجموعه ویژگی‌های اولیه ندارد، اتخاذ می‌کند. در جدول ۲، متوسط دقت پیش‌بینی‌کننده، برای هر یک از مقدار k آورده شده است.

جدول ۲. مقایسه دقت نتایج برای مقادیر مختلف K

دقت طبقه‌بندی کننده		
تست (%)	آموزش (%)	تعداد ویژگی‌ها
% ۷۳/۵۲	% ۷۴/۵۰	$k = \left\lfloor \frac{ F }{4} \right\rfloor = ۲$
% ۷۱/۵۹	% ۷۳/۸۰	$k = \left\lfloor \frac{2* F }{4} \right\rfloor = ۴$
% ۶۹/۹۱	% ۶۶/۲۰	$K = F = ۶$

این جدول نشان می‌دهد که با افزایش تعداد ویژگی‌ها، دقت طبقه‌بندی کننده کاهش می‌یابد. همان‌طور که در جدول ۳ خواهیم دید امتیاز فیشر برای شاخص‌های آماری بازده و انحراف استاندارد کمترین مقدار را دارد، که این مساله با این واقعیت که بازده و انحراف استاندارد توانایی چندانی در پیش‌بینی قیمت ندارند، هم‌خوانی دارد. همچنین یادآوری می‌شود که، مدل ماشین بردار پشتیبان به کاررفته، با استفاده از حجم‌های روزانه معاملات تعدیل یافته است، در نتیجه انتظار می‌رود که شاخص حجم جاری معاملات توانایی خوبی در پیش‌بینی قیمت داشته باشد، که این مورد هم با توجه به امتیاز فیشر به دست آمده برای این شاخص، تایید می‌شود.

جدول ۳. نتایج امتیازات انتخاب ویژگی فیشر و دقت متوسط طبقه‌بندی با اضافه شدن هر ویژگی

ردیف	ویژگی	دقت متوسط (%)	امتیاز فیشر
۱	OBV	.۰۸۲۷	%۷۳/۵
۲	ATR	.۰۰۵۴	%۷۳/۵۴
۳	%R	.۰۰۲۷	%۷۰/۸۲
۴	RSI	.۰۰۰۴	%۶۹/۵۰
۵	R	.۰۰۰۳	%۶۸/۹۰
۶	σ	.۰۰۰۱	%۶۹/۲۰

طبق نتایج جدول ۱، انتخاب $K=2$ منجر به بیشترین دقت می‌شود و علاوه بر این، پس از انجام فرآیند جست‌وجوی ترتیبی پیشرو پشتیبانی شده، دیده می‌شود که استفاده از دو ویژگی حجم جاری معاملات و دامنه متوسط واقعی منجر به بهترین نتایج می‌شود. نتایج امتیازات فیشر برای هر ویژگی و متوسط دقت پیش‌بینی با اضافه شدن هر ویژگی طبق فرآیند جست‌وجوی ترتیبی پیشروی پشتیبانی شده، به زیرمجموعه ویژگی‌ها در جدول ۲ آورده شده است.

مقایسه دقت پیش‌بینی با استفاده از مدل پیشنهادی و روش‌های رقیب. مقایسه دقت متوسط، بین طبقه‌بندی کننده‌های ماشین بردار پشتیبان وزن دهی شده با حجم معاملات و ماشین بردار پشتیبان ساده، همراه با ۴ حالت مختلف برای انتخاب ویژگی، در پیش‌بینی قیمت سهام، در جداول ۴ و ۵ آورده شده است. همان‌طور که مشاهده می‌شود، برای تمام روش‌های انتخاب ویژگی، ماشین بردار پشتیبان وزن دهی شده با حجم معاملات عملکرد بهتری نسبت به ماشین بردار پشتیبان ساده دارد.

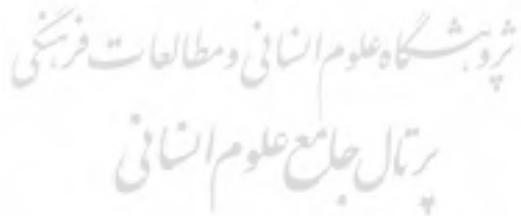
جدول ۴. عملکرد ماشین بردار پشتیبان وزن دهی شده با ۴ حالت مختلف برای انتخاب ویژگی

طبقه‌بندی کننده + روش انتخاب ویژگی	متوسط دقت پیش‌بینی
ماشین بردار پشتیبان وزن دهی شده	%۶۹/۹
ماشین بردار پشتیبان وزن دهی شده + پهله اطلاعات	%۷۱/۴
ماشین بردار پشتیبان وزن دهی شده + عدم قطعیت متقان	%۷۰/۶۸
ماشین بردار پشتیبان وزن دهی شده + انتخاب ویژگی برایه همبستگی	%۷۱/۳۱
ماشین بردار پشتیبان وزن دهی شده + انتخاب ویژگی هیبرید	%۷۳/۵

جدول ۵. عملکرد ماشین بردار پشتیبان وزن دهی شده با ۴ حالت مختلف برای انتخاب ویژگی

متوسط دقت پیش‌بینی	طبقه‌بندی کننده + روش انتخاب ویژگی
%۶۸/۳	ماشین بردار پشتیبان
%۶۵/۱۲	ماشین بردار پشتیبان + بهره اطلاعات
%۶۵/۱۲	ماشین بردار پشتیبان + عدم قطعیت متقاضان
%۵۳/۷	ماشین بردار پشتیبان + انتخاب ویژگی برپایه همیستگی
%۷۰/۲۳	ماشین بردار پشتیبان + انتخاب ویژگی هیرید

با توجه به اعداد موجود در جداول، می‌توان به برتری روش انتخاب ویژگی هیرید نسبت به سایر روش‌ها پی‌برد. در ادامه به منظور تایید و اثبات برتری عملکرد مدل برپایه ماشین بردار پشتیبان وزن دهی شده نسبت به مدل ماشین بردار پشتیبان ساده، اقدام اجرای آزمون‌های فرض تی-زوجی^۱ و همچنین آزمون فرض ناپارامتریک من-ویتنی^۲ نموده‌ایم. علت استفاده از آزمون من-ویتنی این است که آزمون تی-زوجی فرض می‌کند که توزیع داده‌ها نرمال است؛ در حالی که ممکن است داده‌های ما نرمال نباشند. آزمون من ویتنی دو آزمون نمونه‌ای رتبه‌ای را، برای تفاوت بین میانه‌های دو جمعیت انجام می‌دهد. طبق جدول ۶ نتایج مربوط به آزمون من-ویتنی، برای تمامی روش‌های انتخاب ویژگی، تفاوت قابل توجهی را بین دقت پیش‌بینی با ماشین بردار پشتیبان ساده و ماشین بردار پشتیبان تعديل‌یافته، نشان می‌دهد. این به این معنی است که با وجود اینکه ماشین بردار پشتیبان ساده هم نتایج نسبتاً خوبی را ارائه کرده است، ماشین بردار پشتیبان تعديل‌یافته، در مورد تمامی روش‌های پیش‌بینی نتایج خوبی را ارائه کرده است. با توجه به نتایج ارائه شده، واضح است که برای نمونه داده‌های مورد استفاده ما، عملکرد ماشین بردار پشتیبان تعديل‌یافته، برتری قابل توجهی نسبت به عملکرد ماشین بردار پشتیبان ساده دارد.



1. Paired t-test
2. Mann-Whitney nonparametric test

جدول عر آزمون تی-زوجی و من-ویتنی، به منظور مقایسه بین دقت‌های ماشین بردار پشتیبان تعديل یافته و ماشین بردار پشتیبان ساده

روش انتخاب ویژگی	طبقه‌بندی کننده	دقت (%)	آزمون تی-زوجی آماره t	آزمون تی-زوجی آماره Z	آزمون نایارامتریک من-ویتنی p-value
روش هیبرید FSSFS	ماشین بردار پشتیبان تعديل یافته ماشین بردار پشتیبان ساده	%۷۳/۵ %۷۰/۲۳	۱۳/۱۷۶	-۲/۲۶۹	.۰/۰۱
بهره اطلاعات IG	ماشین بردار پشتیبان تعديل یافته ماشین بردار پشتیبان ساده	%۷۱/۴ %۶۵/۱۲	۴/۸۱۵	-۲/۰۴۶	.۰/۰۲
عدم قطعیت SU متقارن	ماشین بردار پشتیبان تعديل یافته ماشین بردار پشتیبان ساده	%۷۰/۶۸ %۶۵/۱۲	۵/۵۵۶	-۱/۹۴۵	.۰/۰۱
انتخاب ویژگی برپایه همبستگی CFS	ماشین بردار پشتیبان تعديل یافته ماشین بردار پشتیبان ساده	%۷۱/۳۱ %۶۳/۷	۱۳/۴۰۴	-۱/۶۰۲	.۰/۰۳

۵. بحث و نتیجه‌گیری

در این پژوهش مدل ترکیبی جدید از ماشین بردار پشتیبان وزن‌دهی شده با حجم معاملات واقعی و انتخاب ویژگی هیبرید، ارائه شد. همچنین به منظور اثبات توانایی و قابلیت مدل پیشنهادی در پیش‌بینی درست و قابل اطمینان روندهای کوتاه‌مدت، نتایج این مدل با انتخاب ویژگی‌های مختلف و همین‌طور با نتایج طبقه‌بندی کننده ماشین بردار پشتیبان ساده مقایسه شد. همان‌طور که دیدیم برای هر دو طبقه‌بندی کننده، دقت پیش‌بینی روش انتخاب ویژگی هیبرید پیشنهادی از سایر تکنیک‌های انتخاب ویژگی بیشتر است. همچنین برای اثبات برتری ماشین بردار پشتیبان وزن‌دهی شده نسبت به ماشین بردار پشتیبان ساده، اقدام به ارائه استراتژی معاملاتی بر پایه هر دو روش نمودیم. همان‌طور که با توجه به جداول و شکل‌ها دیده می‌شود، نتایج روش پیشنهادی در این مورد هم به میزان قابل توجهی بهتر بود. همچنین لازم به یادآوری است که در این پژوهش از معتبرسازی مقطعی استفاده شده است و در هربار اجرای الگوریتم از ۸۰ درصد از داده‌ها برای آموزش و ۲۰ درصد برای آزمون استفاده شده و استراتژی معاملاتی بر روی داده‌های ۲ سال آخر پیاده‌سازی شده است؛ بنابراین می‌توان ادعا کرد که دقت‌های ارائه شده برای پیش‌بینی روش‌های مختلف که در جداول ارائه شده‌اند و همچنین نتایج استراتژی،

قابل اطمینان می‌باشد.

علاوه براین، نتایج نشان می‌دهد که شاخص‌های حجم جاری معاملات و دامنه متوسط واقعی با دقت قابل قبولی توانایی پیش‌بینی قیمت سهم را دارند. که این مورد با وزن‌دهی شده بودن ماشین بردار پشتیبان با حجم معاملات هم‌خوانی دارد.

۶. پیشنهادها

از جمله مواردی که با توجه به نتایج این پژوهش، می‌تواند محل مطالعه و بررسی واقع شود، تابع وزن‌دهی به تابع جریمه در مدل طبقه‌بندی کننده ماشین بردار پشتیبان می‌باشد. باید بررسی شود که آیا روش بهتری برای این وزن‌دهی وجود دارد یا خیر. خصوصاً وارد کردن نوسانات به این وزن‌دهی، به عنوان عامل پیش‌بینی کننده، می‌تواند موجب بهبود مدل ارائه شده در این پژوهش شود. همچنین بررسی سایر روش‌های انتخاب ویژگی، به منظور افزایش دقت پیش‌بینی، می‌تواند محل مطالعات بیشتر واقع شود. علاوه براین، گسترش مجموعه داده‌های آموزش، به‌طوری که علاوه بر شاخص‌های تحلیل تکنیکال، شامل عواملی از اقتصاد کلان محیط نیز بشود، می‌تواند حوزه جالبی برای بهبود مدل و عملکرد آن باشد.



منابع

1. Abu-Mostafa, Y. S., & Atiya, A. F. (1996). Introduction to financial forecasting. *Applied Intelligence*, 6(3), 205° 213.
2. Badri, Dawaloo & Dori Nokarani (1395). Studying macroeconomic factors on stock market performance, *Journal of financial management perspective*. 13: (9-35).
3. Chavarnakul, Thira, and David Enke (2008). Intelligent technical analysis based equidolume charting for stock trading using neural networks. *Expert Systems with Applications* 34.2: 1004-1017.
4. Chen, Y.-W., & Lin, C.-J., (2005). Combining SVMs with various feature selection strategies. Available from:
[<http://www.csie.ntu.edu.tw/~cjlin/papers/features.pdf>](http://www.csie.ntu.edu.tw/~cjlin/papers/features.pdf).
5. Choudry, R. & Grag, K. (2008). A Hybrid Machine Learning System for Stock Market Forecasting. *World Academy of Science, Engineering and Technology*, 39.
6. Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20, 273° 297.
7. Cristianini, N., & Shawe-Taylor, J. (2000). An introduction to support vector machines.Cambridge: Cambridge University Press.
8. Dash, M. et al., (2002). Feature selection for clustering ° a filter solution. In Proceedings of the second international conference on data mining :115° 122.
9. Ebadi, Forcasting Stock index price in Tehran stock exchange using artificial network, Thesis for master degree, Bu Ali Sina University, Faculty of economy and social science.
10. Eslami Bidgoli (1393). Shabanoorfar, Relevency of trading volume and return case study in Tehran stock exchange considering intraday volume and excluding the U effect, *Journal of Financial Management Perspective*, 6: 45-63.
11. Fallahpour, Golarzi, Fatoorechian, Stock Price Movement Prediction Using Support Vector Machine Based on Genetic Algorithm in Tehran Stock Exchange Market. *Journal of financial research*. 15(2), 269-288.
12. Huang, C.-L., Chen, M.-C., & Wang, C.-J. (2007). Credit scoring with a data mining approach based on support vector machines. *Expert Systems with Applications*, 33(4), 847° 856.
13. Huang, C.-J., Dian-Xiu & Chuang, Y.-T. (2007). Application of wrapper approach and composite classifier to the stock trend prediction. *Expert Systems with Applications*, 34(4), 2870° 2878.
14. Hashemi, Analysis of behavioral factors effect on forcasting stock price using regression feedforward artificial neural network, Thesis for master degree, University of Science and Culture.
15. Kohavi, Ron, and George H. John (1997). Wrappers for feature subset selection. *Artificial intelligence* 97.1: 273-324.
16. Lawrence, S., Giles, C. L., & Tsoi, A.-C. (1997). Lessons in neural network training: Over fitting may be harder than expected. In Proceedings of the fourteenth national conference on artificial intelligence, AAAI-97: 540° 545.
17. Lee, Ming-Chi (2009). Using support vector machine with a hybrid feature selection method to the stock trend prediction. *Expert Systems with Applications* 36.8: 10896-10904.
18. Leung, M. T., Daouk, H., & Chen, A. S. (2000). Forecasting stock indices: A

- comparison of classification and level estimation models. *International Journal of Forecasting*, 16, 173° 190.
19. Min, J. H., & Lee, Y.-C. (2005). Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters. *Expert Systems with Applications*, 28(4), 603° 614.
20. Monajemi, Ebrazi, Rayati, (1388). Stock price prediction in Tehran stock exchange using artificial neural network. *Journal of financial economy*, 6(3), 1-26.
21. Tan, T. Z., Quek, C., & See, Ng. G. (2007). Biological brain-inspired genetic complementary learning for stock market and bank failure prediction. *Computational Intelligence*, 23(2), 236° 261.
22. Theodoridis, S., & Koutroumbas, K. (2008). Pattern Recognition. Academic Press.
23. Yu, L., & Liu, H., (2003). Feature selection for high-dimensional data: A fast correlation-based filter solution. In Proceedings of the 20th international conference on machine learning: 856° 863.
24. bikowski, Kamil. (2014). Using volume weighted support vector machines with walk forward testing and feature selection for the purpose of creating stock trading strategy. *Expert Systems with Applications*. 10.001.
25. Zhang, Xiangzhou, et al (2014). A causal feature selection algorithm for stock prediction modeling. *Neurocomputing*, 142: 48-59.

