

طراحی سیستم معاملات تکنیکی سهام با استفاده از مدل ترکیبی شبکه عصبی MLP و الگوریتم‌های تکاملی

علیرضا سارنج^۱

احمد رضا قاسمی^۲

اصغر ارم^۳

رضا تهرانی^۴

تاریخ پذیرش: ۹۷/۰۶/۰۶

تاریخ دریافت: ۹۷/۰۴/۱۸

چکیده

توسعه سیستم‌های معاملاتی سهام با استفاده از الگوریتم‌های تکاملی (EA) طی چند سال اخیر به موضوعی پرمخاطب در حوزه مالی مبدل شده است. در پژوهش حاضر، سیستم معاملاتی تکنیکی هوشمند با بهره‌گیری از مدلی مرکب از شبکه عصبی MLP و الگوریتم‌های تکاملی شامل الگوریتم ژنتیک (GA)، الگوریتم بهینه‌سازی مورچگان پیوسته (ACO_R) و الگوریتم بهینه‌سازی ازدحام ذرات (PSO) پیشنهاد شده است. داده‌های مربوط به ۱۵ شرکت منتخب طی سال‌های ۱۳۸۷ تا ۱۳۹۶ بر اساس دوره‌های کوتاه‌مدت و بلندمدت و همچنین روندهای بازار صعودی، نزولی و خنثی مورد بررسی قرار گرفته‌اند. جهت انتخاب متغیرهای ورودی نهایی، از مقایسه رتبه بازدهی شاخص‌های تکنیکی بر اساس قواعد معاملاتی استفاده شده است. در نهایت، آزمون مقایسه زوجی بازدهی مدل‌ها در مقایسه با استراتژی خرید و نگهداری انجام شد و بازدهی مدل‌ها با یکدیگر مقایسه شده است. نتایج تحقیق نشان می‌دهد مدل‌های ترکیبی MLP و الگوریتم‌های تکاملی عملکرد بهتر و معناداری نسبت به روش خرید و نگهداری و مدل MLP-BP داشته است و مدل MLP_PSO بازدهی بیش تری نسبت به سایر مدل‌ها کسب کرده است.

واژه‌های کلیدی: سیستم‌های معاملاتی هوشمند، الگوریتم‌های تکاملی، شبکه عصبی پرسپترون چندلایه، قواعد معاملاتی تکنیکی، استراتژی خرید و نگهداری.

۱- استادیار دانشکده مدیریت و حسابداری پردیس فارابی، دانشگاه تهران، تهران، ایران. (نویسنده مسئول) alisaranj@ut.ac.ir

۲- استادیار دانشکده مدیریت و حسابداری پردیس فارابی، دانشگاه تهران، تهران، ایران.

۳- دانشجوی دکتری مالی، دانشکده مدیریت و حسابداری پردیس فارابی، دانشگاه تهران، تهران، ایران.

۴- استاد دانشکده مدیریت دانشگاه تهران، تهران، ایران.

۱- مقدمه

پیشرفت‌های اخیر در حوزه فناوری‌های کامپیوتری، گسترش به‌کارگیری فناوری‌های معاملات الگوریتمی^۱ و خودکار، توسعه استراتژی‌های معاملاتی^۲ و به‌تبع آن سرعت بالای معاملات، منجر به افزایش پیچیدگی‌های سرمایه‌گذاری در بازار سهام شده‌اند. در این بین، موضوع کشف قواعد معاملات تکنیکی^۳ از داده‌های غیرخطی و پیچیده بازار و توسعه سیستم‌های هوشمند تصمیم‌گیری خرید و فروش سهام یکی از دغدغه‌های مهم فعالان بازار سهام است که تحقیقات زیادی در این زمینه در حال انجام است (Zhang et al, 2016).

قواعد معاملاتی مبتنی بر شاخص‌های تکنیکی به‌طور گسترده‌ای در بازار سهام مورد استفاده قرار گرفته‌اند و مطالعات گذشته شواهد تجربی مثبتی را در مورد سودآوری قواعد معاملاتی تکنیکی در توسعه مدل‌های سیستم معاملاتی نشان می‌دهند (Kim et al, 2017). بسیاری از محققان تلاش کرده‌اند تا قواعد معاملاتی تکنیکی را با مدل‌های پیش‌بینی ترکیب کنند که برخی از این تکنیک‌ها شامل شبکه‌های عصبی، سیستم‌های فازی^۴، محاسبات تکاملی^۵ و الگوریتم‌های ژنتیکی^۶ است (Qiu & Song, 2016).

از دهه ۸۰ میلادی، شبکه عصبی پرسپترون چندلایه^۷ (MPL) به‌عنوان یکی از کارآمدترین نوع شبکه عصبی بخصوص در زمینه پیش‌بینی مسائل و متغیرهای مالی و اقتصادی از قابلیت بالایی برخوردار است (اعتمادی و احمدیان، ۱۳۹۴). در کاربرد شبکه عصبی، استفاده از الگوریتم یادگیری مناسب حائز اهمیت است (منهاج، ۱۳۷۷). الگوریتم پس انتشار^۸ (BP) که بر پایه کاهش گرادیان^۹ است، رایج‌ترین الگوریتم آموزش شبکه عصبی برای پیش‌بینی‌های حوزه مالی است که یک الگوریتم کلاسیک یادگیری محسوب می‌شود؛ اما الگوریتم BP دارای دو محدودیت مهم در پیش‌بینی است. محدودیت اول افتادن در دام نقاط بهینه محلی به دلیل وجود نوپها و

پیچیدگی‌های ابعاد داده‌های بازار سهام و دوم سرعت پایین در همگرایی است (Qiu & Song, 2016). بر اساس تحقیقات گذشته، الگوریتم‌های تکاملی و مدل‌های مبتنی بر یادگیری تکاملی جهت غلبه بر محدودیت‌های فوق توسعه یافته است (Kim et al, 2017). الگوریتم‌های تکاملی دارای دو مزیت اصلی هستند. مزیت اول این است که ویژگی‌های مبتنی بر جمعیت و تصادفی بودن محاسبات تکاملی تا حد زیادی می‌تواند فضای جستجوی خود را گسترش دهد و احتمال افتادن در دام نقطه بهینه محلی را کاهش می‌دهد و دوم اینکه تکنیک‌های محاسبات تکاملی در ایجاد نتایج نزدیک به نتایج بهینه ظرف مدت زمان نسبتاً کوتاه بسیار مؤثر است (Hu et al, 2015).

پژوهش حاضر به دنبال ارائه یک سیستم معاملاتی تکنیکی با استفاده از مدلی مرکب از شبکه عصبی MLP و الگوریتم‌های تکاملی شامل الگوریتم ژنتیک (GA)، الگوریتم بهینه‌سازی مورچگان پیوسته (ACO_R) و الگوریتم بهینه‌سازی ازدحام ذرات (PSO) در راستای تقویت چرخه معاملات الگوریتمی و خودکار یعنی تجزیه و تحلیل قبل از معاملات و ایجاد سیگنال-های معاملاتی است. با توجه به نتایج آسیب‌شناسی مطالعات انجام شده بر روی کاربرد محاسبات تکاملی در پیش‌بینی حرکات آتی قیمت‌ها که توسط هیو و همکاران (۲۰۱۵) صورت گرفته است، روند بازار و هزینه معاملات به‌عنوان خلأهای پژوهشی موجود در این حوزه شناسایی شده است و بسیاری از محققین نسبت به بررسی دقیق این دو عامل کلیدی غافل بوده‌اند که منجر به نتایج نامتوازن در تحقیقات آن‌ها شده است. در این تحقیق، سعی شده است به‌منظور برطرف نمودن خلأهای موجود در تحقیقات گذشته، علاوه بر لحاظ نمودن هزینه کارمزد معاملات، روندهای صعودی، نزولی و خنثی و افق سرمایه‌گذاری کوتاه‌مدت و بلندمدت مورد بررسی دقیق قرار گیرد. همچنین در تحقیق حاضر، استفاده از مقایسه رتبه بازدهی شاخص‌های تکنیکی، انتخاب مقادیر بهینه پارامترهای اندیکاتورهای مورد استفاده و تبدیل سیگنال‌های

خروجی به استراتژی معاملاتی خرید و فروش سهام، در جهت تقویت استراتژی فعالانه سرمایه‌گذاری و بهبود دقت پیش‌بینی زمان‌بندی خرید و فروش سهام از جایگاه ویژه‌ای برخوردار می‌باشد.

۲- مبانی نظری و مروری بر پیشینه تحقیق

بررسی تغییرات قیمت آتی سهام در بورس اوراق بهادار هواره موضوع حائز اهمیتی بوده است که به فرضیه بازار کارا^۱ و اوایل دهه ۷۰ میلادی باز می‌گردد. فرضیه بازار کارا یکی از مهم‌ترین تئوری‌هایی است که در زمینه سرمایه‌گذاری مطرح شده است. فرضیه بازار کارا یا گشت تصادفی یکی از معروف‌ترین نظریه‌ها در حوزه امکان پیش‌بینی قیمت‌ها است که به طور گسترده‌ای پذیرفته شده است. این نظریه نشان می‌دهد که قیمت‌های جاری اوراق بهادار منعکس کننده تمامی اطلاعات در زمان کنونی است و کسی نمی‌تواند با استفاده از تحلیل تکنیکال و یا حتی تحلیل بنیادی سود اضافی بدست آورد (Fama & Blume, 1966; Levy, 1967; Cui & Long, 2016) و بهترین استراتژی سرمایه‌گذاری، استراتژی خرید و نگهداری^{۱۱} است. به طور خلاصه این تئوری بیان می‌کند که قیمت‌ها مسیر کاملاً تصادفی و غیرقابل پیش‌بینی داشته و احتمال بالا رفتن قیمت سهام کاملاً مساوی با احتمال پایین رفتن آن است و معتقد است داشتن عملکردی بهتر از عملکرد شاخص بورس عملاً غیرممکن است. طی چندین دهه گذشته، تحقیقات زیادی در زمینه اعتبارسنجی فرضیه بازار کارا صورت گرفته است که این مطالعات به لحاظ روش ارزیابی و انتخاب سهم عمدتاً به دو دسته تجزیه و تحلیل بنیادی و تجزیه و تحلیل تکنیکی تقسیم می‌شوند. بسیاری از مطالعات اولیه از آزمون‌های آماری سنتی برای نشان دادن عدم اعتبار استراتژی تکنیکال استفاده کردند. با این حال در دهه‌های اخیر بسیاری از دانشمندان بر این باورند که عوامل روانی و رفتاری انسانی نقش مهمی در تعیین قیمت اوراق بهادار دارد و تغییرات قیمت سهام را می‌توان تا حدودی با استفاده

از اطلاعات گذشته پیش‌بینی کرد. بنابراین تجزیه و تحلیل تکنیکی به مرور در حوزه‌های نظری و عملی مالی مورد توجه قرار گرفته است و استراتژی‌های تکنیکی در سرمایه‌گذاری مالی مدرن به خصوص با ظهور معاملات اینترنتی از اهمیت رو به رشدی برخوردار می‌باشد (Vasiliou, 2006; Cui & Long, 2016). اگر چه سودآوری واقعی تحلیل تکنیکی هنوز مورد بحث است، در حال حاضر بسیاری از استراتژی‌های معاملاتی تکنیکی به دنبال تعیین روند قیمت در آینده نزدیک و کسب سود حاصل از آن است (Covel, 2009; Cui & Long, 2016).

همچنین در پی پیشرفت‌های گسترده‌ای که در زمینه تکنولوژی‌های رایانه‌ای و هوش مصنوعی و در نتیجه موفقیت در کشف روابط آشوبی در سری‌های زمانی غیرخطی پدید آمد، فعالیت در جهت پیش‌بینی قیمت سهام بر مبنای متغیرهای تکنیکی با حجم گسترده‌ای از تحقیقات همراه شده است (بدیعی و همکاران، ۱۳۹۶). امروزه قواعد معاملاتی تکنیکی به‌طور گسترده در طراحی سیستم‌های معاملاتی جهت پیش‌بینی روند آتی قیمت یا ارائه سیگنال‌های معاملاتی خریدوفروش در بازارهای سهام، شاخص‌ها و ارز مورد استفاده قرار می‌گیرند. تحلیل تکنیکی با بهره‌گیری از الگوهای تکرارشونده، مطالعه رفتار قیمت و حجم معامله سهام و ویژگی‌های تاریخی سایر اطلاعات مالی به پیش‌بینی روند آتی می‌پردازد. ایده اصلی تحلیل تکنیکی این است که روند تغییرات قیمت سهام به‌وسیله تغییرات نگرش سرمایه‌گذاران که خود متأثر از عوامل متعددی است شکل می‌گیرد (سینایی و همکاران، ۱۳۸۴). تحلیلگران تکنیکی معتقدند، زمانی که سرمایه‌گذاران با شرایط مشابهی که در گذشته رخ داده روبرو می‌شوند، به روش پیش‌بینی‌شده‌ای رفتار می‌نمایند. به بیان دیگر، تاریخ تکرار می‌شود (راعی و پویانفر، ۱۳۸۹).

تابه حال تحقیقات زیادی در زمینه سودآوری سیستم‌های معاملاتی تکنیکی انجام گرفته است. آلن و کارجالین (۱۹۹۹) جزء اولین کسانی بودند که یک

در مطالعات داخلی، راعی و حسینی (۱۳۹۴)، بر مبنای نمونه ۵۰ شرکت فعال بورس تهران، با استفاده از روش منطق فازی و روش ترکیبی الگوریتم ژنتیک - منطق فازی مدل تصمیم‌گیری خرید و فروش سهام ارائه کردند. نتیجه این بررسی حکایت از آن دارد که روش منطق فازی و روش ترکیبی الگوریتم ژنتیک - منطق فازی نسبت به روش خرید و نگهداری بازدهی بیش‌تری داشته است. همچنین روش منطق فازی نسبت به روش ترکیبی الگوریتم ژنتیک - منطق فازی عملکرد بهتری داشته است. رضا تهرانی و وحید عباسیون (۱۳۹۴) در تحقیقی زمان‌بندی ورود به معاملات سهام با رویکرد تکنیکی را با استفاده از شبکه عصبی مورد بررسی قرار دادند. نتایج بررسی آن‌ها نشان می‌دهد که عملکرد سیستم تنها در بازارهای نزولی مناسب بوده است و در بازار صعودی تفاوت معناداری میان سیستم معاملاتی پیشنهادی روش خرید و نگهداری وجود ندارد. بدیعی و همکاران (۱۳۹۵) با استفاده از شبکه عصبی پرسپترون چندلایه به پیش‌بینی قیمت سهام پالایش نفت اصفهان پرداختند. نتایج تحقیق حکایت از آن دارد که مدل شبکه عصبی دارای خطای پایین و قدرت توضیح دهنده بالا و در نتیجه از قدرت پیش‌بینی خوبی برخوردار است. محمدی و همکاران (۱۳۹۶) در تحقیقی به طراحی سیستم هوشمند خرید و فروش بر اساس مدلی مرکب از الگوریتم ماشین بردار پشتیبان و تئوری کانال روند بر روی داده‌های شاخص کل، ۵۰ شرکت فعال، شاخص صنعت و شاخص مالی پرداخته‌اند. نتایج این پژوهش نشان داد که عملکرد سیستم هوشمند آن‌ها از عملکرد استراتژی خرید و نگهداری بهتر بوده است.

در ادامه، مدل پژوهش و الگوریتم‌های تحقیق تشریح خواهد شد و پس از آزمون‌های تجربی و توضیح یافته‌ها، در انتها به بحث و نتیجه‌گیری پرداخته خواهد شد.

مدل کشف قواعد معاملاتی با استفاده از الگوریتم ژنتیک و ترکیبی از توابع ریاضی و شاخص‌های تکنیکی استاندارد برای شاخص S&P500 توسعه دادند. پس از آن، بسیاری از محققان تلاش کرده‌اند تا مدل‌های پیش‌بینی مخصوص مدل‌های مبتنی بر الگوریتم‌های تکاملی برای یافتن قواعد معاملاتی تکنیکی در بازارهای مالی، استفاده کنند (Hu et al, 2015). دامپستر و جونز (۲۰۰۱) سیستم معاملاتی را برای یافتن قواعد معاملاتی بهینه تکنیکی با استفاده از برنامه‌نویسی ژنتیکی (GP) برای بازار ارز (FX) طراحی کردند. اخیراً محققین بر توسعه سیستم‌های معاملاتی ترکیبی هوشمند تمرکز داشته‌اند که از ترکیب تکنیک‌های مختلف و ایجاد سینرژی بهره جستند. در بین تحقیقات اخیر، دس و دس (۲۰۱۶) به طراحی یک مدل معاملاتی سهام با ترکیب متغیرهای تکنیکی و یادگیری ماشین پرداختند. آن‌ها در تحقیق خود از مدل شبکه عصبی مصنوعی بر پایه اتصال تابعی کارای محاسباتی (CEFLANN) استفاده کردند و از بازدهی دوره جهت ارزیابی عملکرد مدل‌ها استفاده نمودند. نتایج پژوهش حکایت از عملکرد بهتر مدل پیشنهادی نسبت به مدل‌های مقایسه‌ای ماشین بردار پشتیبان (SVM)، الگوریتم نزدیک ترین همسایگی (KNN) و درخت تصمیم (DT) دارد. در تحقیقی دیگر که توسط بروتیچ و همکاران (۲۰۱۶) انجام شد، به طراحی یک استراتژی معاملاتی با استفاده از مدل برنامه‌ریزی ژنتیک (GP) برای انتخاب پرتفوی الگوریتمی پرداختند. آن‌ها در تحقیق خود از تکنیک برنامه‌ریزی ژنتیک بر پایه برازش نمونه‌گیری تصادفی (RSFGP) برای یادگیری استراتژی‌های معاملاتی و از نسبت شارپ، نسبت استرلینگ و بازدهی کل برای ارزیابی مدل استفاده کرده‌اند. یافته‌های تحقیق نشان داد که مدل پیشنهادی تحقیق از مدل‌های برنامه‌ریزی ژنتیک استاندارد (SGP)، برنامه‌ریزی ژنتیک بر پایه برازش تعدیل شده با نوسانات (VAFGP) و روش خرید و نگهداری عملکرد بهتری داشته است.

۳- روش‌شناسی تحقیق

تحقیق حاضر به لحاظ هدف کاربردی و در گروه پژوهش‌های توصیفی از نوع همبستگی قرار دارد. متغیرهای این تحقیق به دو دسته کلی تقسیم می‌شوند. یک دسته متغیرهای تخمین زنده هستند که از آن‌ها برای پیش‌بینی حرکات آتی قیمت سهام شرکت‌ها استفاده می‌شود و شامل متغیرهای تکنیکی است. دسته دوم متغیرها، نتایج پیش‌بینی‌ها یعنی بازدهی سهام و سود و زیان ناشی از خریدوفروش سهام هستند که خود برای انجام آزمون مقایسه زوجی مورد استفاده قرار می‌گیرند. در تحقیق حاضر جهت گردآوری داده‌های موردنظر از نرم‌افزارهای ره‌آورد نوین و آرشیو سایت www.irbourse.com استفاده شده است. قلمرو زمانی تحقیق از تاریخ ۱۳۸۷/۰۱/۰۱ تا تاریخ ۱۳۹۶/۰۹/۲۹ است و به دو دوره کوتاه‌مدت و بلندمدت تقسیم می‌شود. در دوره کوتاه‌مدت، دو ماه معاملاتی به‌عنوان داده‌های تست و در دوره بلندمدت یک سال به‌عنوان دوره تست در نظر گرفته می‌شود. همچنین دوره‌های کوتاه‌مدت در سه روند صعودی، نزولی و خنثی مورد ارزیابی قرار گرفته‌اند. قلمرو مکانی تحقیق نیز بورس اوراق بهادار تهران است. درنهایت، برنامه‌نویسی و پیاده‌سازی الگوریتم‌های تحقیق در نرم‌افزار MATLAB انجام شده است و از نرم‌افزار SPSS به منظور انجام آزمون و تحلیل یافته‌ها استفاده شده است.

۴- مدل تجربی پژوهش

۴-۱- چارچوب مدل پیشنهادی


در این بخش، یک سیستم هوشمند تصمیم‌گیری معاملات سهام با استفاده از مدل ترکیبی شبکه عصبی و الگوریتم‌های تکاملی و مجموعه‌ای از شاخص‌های معاملاتی تکنیکی پیشنهاد شده است. معماری سیستم پیش‌بینی استفاده شده به‌منظور پیش‌بینی تغییرات جهت قیمت سهام در شکل زیر نمایش داده است.

۴-۲- پیش‌پردازش و آماده‌سازی داده‌ها

جامعه آماری تحقیق شامل شرکت‌هایی هستند که جزء ۵۰ شرکت فعال طبق رتبه‌بندی سازمان بورس (عمدتاً بر اساس معیارهای نقدشوندگی، میزان معاملات سهام، تناوب در روزهای معامله و میزان تأثیرگذاری بر بازار) است و طی دوره مورد بررسی در بورس حضور فعال داشته‌اند. روش نمونه‌گیری از نوع غیرتصادفی و قضاوتی بوده و ۱۵ شرکت با اعمال محدودیت‌های زیر انتخاب شده‌اند:

- داده‌های مربوط به قیمت و حجم آن‌ها در دوره مورد مطالعه در دسترس باشد.
- در بیش از ۷۵ درصد از روزهای معاملاتی در هر سال قابل معامله بوده‌اند.
- فراوانی بالای حضور در لیست ۵۰ شرکت فعال را نسبت به مدت زمان حضور در بورس داشته باشد.
- برای دوره طولانی متوقف نباشد.

بازه زمانی انتخاب‌شده برای دوره آموزشی و آزمایشی از ابتدای سال ۱۳۸۷ تا دی‌ماه سال ۱۳۹۶ بوده است. به‌منظور تعیین داده‌های آموزشی و تست، بر اساس تکنیک رولینگ ویندو، کل داده‌های سری زمانی قیمت هر سهم به زیرمجموعه‌های ۶۰ روزه معاملاتی تقسیم شده است که در کل دوره به‌طور متوسط تقریباً ۳۰ زیرمجموعه تشکیل شده است. جهت تعیین روند داده‌های تست، از برازش منحنی چندجمله‌ای بر پایه رگرسیون که با دستور *Polyfit* در نرم‌افزار متلب اجرا می‌شود استفاده شده است چرا که تکنیک‌های رگرسیون از مهم‌ترین روش‌ها در برازش منحنی به شمار می‌روند (بشیری و همکاران، ۱۳۹۴).



نمودار شماره (۱): چارچوب مدل پیشنهادی تحقیق

داده تست و داده های قبل از آن، به عنوان داده آموزشی در نظر گرفته می شود. به منظور تشکیل بردار ویژگی های ورودی، ۱۳ شاخص به همراه فرمول محاسبه آن ها بر اساس ادبیات تحقیق مرتبط با موضوع این تحقیق انتخاب شده است (مطابق جدول شماره ۱).

داده هایی که ضرایب منحنی آن ها بیش از ۱ باشند، دارای روند صعودی، داده هایی که ضرایب منحنی آن ها کمتر از ۱- باشند، دارای روند نزولی و داده هایی که مقدار ضرایب منحنی آن ها بین ۱ و ۱- باشند، دارای روند خنثی تلقی می شوند. همچنین برای دوره بلندمدت نیز، ۱۸۰ روز معاملاتی آخر به عنوان

جدول شماره (۱): ویژگی‌های اولیه ورودی

نام متغیر	فرمول	دوره	قواعد انتخاب	منبع
میانگین متحرک ساده (SMA)	$SMA(n) = \frac{1}{n} \sum_{i=0}^{t-n} P_i / n$	n= 3,4,5,...,50	If P>SMA, 1 Elseif P<SMA, -1 Otherwise, 0	Su & Cheng,2016
میانگین متحرک نمایی (EMA)	$SMA(n) = \frac{1}{n} \sum_{i=0}^{t-n} P_i / n$	n= 3,4,5,...,50	If P>EMA, 1 Elseif P<EMA, -1 Otherwise, 0	Shynkevich,2017
شاخص کانال کامودیتی (CCI)	$CCI(n) = \frac{M - \bar{M}(n)}{d(n) \times 0.015}$ $M = \frac{H + L + C}{3}$ $d(n) = \frac{1}{n} \sum_{i=0}^{n-1} M_{t-i} - \bar{M}_t(n) $	n= 3,4,5,...,50	If CCI<100& CCI>100, 1 Elseif CCI>-100& CCI<-100,-1 Otherwise,0	Shynkevich,2017
میانگین متحرک همگرایی/واگرایی (MACD)	$EMA(C, m) - EMA(C, n)$	m= 8,9,10,...,50 n= round(n/2)-1	If MACD>0& MACDSig>MACD,1 Elseif MACD<0& MACDSig<MACD,-1 Otherwise, 0	Lincy G & John C, 2016
شاخص قدرت نسبی (RSI)	$RSI(n) = 100 - \frac{100}{(100 - RS(n))}$ $RS(n) = \frac{\sum_{i=0}^{n-1} Up_{t-i}}{\sum_{i=0}^{n-1} Down_{t-i}}$	n= 3,4,5,...,50	If RSI>RSI _{t-1} & RSI>RSI _{t-2} , 1 Elseif RSI<RSI _{t-1} & RSI<RSI _{t-2} , -1 Otherwise, 0	Kim & Enke, 2016
نرخ تغییر (ROC)	$ROC(n) = (\frac{C}{C_{t-n}} - 1) \times 100$	n= 3,4,5,...,50	If ROC<0& ROC>0, 1 If ROC>0& ROC<0, -1 Otherwise, 0	Ye et al, 2016
شاخص جریان پول (MFI)	$MFI = 100 - \frac{100}{(100 + MR)}$ $TP = \frac{H + L + C}{3}, MF = TP \times V$ $MR = \frac{PositiveMF}{NegativeMF}$	n= 3,4,5,...,50	If MFI<20 & MFI>20, 1 Elseif MFI>80 & MFI<80, -1 Otherwise, 0	Kim et al, 2017
نوسانگر استوکاستیک (%K)	$\%K(n) = \frac{C - L_{n.min}}{H_{n.max} - L_{n.min}} \times 100$	n= 8,10,12,...,50	If SlowK<20& SlowD<20& SlowK>SlowD, 1 Elseif SlowK>80& SlowD>80& SlowK<SlowD, -1 Otherwise, 0	Shynkevich,2017
نوسانگر استوکاستیک (%D)	$\%D(n) = \sum_{i=0}^{n-1} \frac{\%K_{t-i}}{n}$	n= 8,10,12,...,50		Shynkevich,2017
شاخص ویلیامز %R	$William\%R(n) = \frac{H_{n.max} - C}{H_{n.max} - L_{n.min}} \times 100$	n= 3,4,5,...,50	If WR<-20& WR>-20, 1 If WR>-80& WR<-80, -1 Otherwise, 0	Kim et al, 2017
بولینگر باند %b	$Band\%b(n) = \frac{C - L(n)}{U(n) - L(n)}$ $U(n) = \bar{C}(n) + \left[\alpha \times \sqrt{\frac{\sum_{i=0}^{n-1} (C_{t-i} - \bar{C}(n))^2}{n}} \right]$ $L(n) = \bar{C}(n) - \left[\alpha \times \sqrt{\frac{\sum_{i=0}^{n-1} (C_{t-i} - \bar{C}(n))^2}{n}} \right]$	n= 8,10,12,...,50	If (P _t -U _b)/ P _t <0.02 , -1 Elseif (P _t -L _b)/ P _t <0.02 , -1 Otherwise, 0	Kim et al, 2017
عرض باند	$Band\ width(n) = \frac{U(n) - L(n)}{C(n)}$	n= 8,10,12,...,50		

منبع	قواعد انتخاب	دوره	فرمول	نام متغیر
Kim & Enke, 2016	If $MOM_t > 100, 1$ Elseif $MOM_t < 100, 1$ Otherwise, 0	$n = 3, 4, 5, \dots, 50$	$Momentum(n) = \frac{C}{C_{t-n}} \times 100$	مومنتوم
H: بالاترین قیمت، L: پایین ترین قیمت، C: قیمت بسته شدن، V: حجم ۱: خرید، ۰: فروش، * : نگهداری				

پارامترها با مقادیری که بهترین بازدهی را کسب کرده باشند به عنوان مقدار بهینه پارامتر اندیکاتور مورد نظر انتخاب شده و وارد مدل می شوند.

در گام بعدی، نرمال سازی داده های آموزشی و آزمایشی انجام می گیرد تا هر یک از متغیرهای ورودی، بین صفر و یک قرار گیرند و برای طراحی ساختار مدل به کار گرفته شوند. نرمال سازی داده ها با استفاده از فرمول زیر صورت گرفته است:

$$\bar{X}_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

که X_i برابر داده اولیه، $X_{\min}$ برابر داده با ارزش حداقل و $X_{\max}$ برابر داده با ارزش حداکثر است (Dash & Dash, 2016).

در تحقیق حاضر، مسیرهای حرکات آتی قیمت ها، بر اساس مطالعه شینکویچ و همکاران (۲۰۱۷) از طریق طبقه بندی آنها در سه دسته پیش بینی شده است. انتساب برچسب ها به هر نقطه از داده ها، بر اساس رفتار آینده قیمت سهم ها انجام گرفته است که در زیر نشان داده شده است.

$$Label_{2C}(t+1) = \begin{cases} 'UP' & \text{If } (P_{t+1} - P_t)/P_t > 0 \\ 'Down' & \text{If } (P_{t+1} - P_t)/P_t < 0 \end{cases}$$

در طبقه بندی دو کلاسه، برچسب 'UP' به آن نقاط از داده ها اختصاص دارد که قیمت روز بعد افزایشی و برچسب 'Down' به نقاطی اختصاص می یابد که قیمت روز بعد کاهشی باشد. استراتژی معاملاتی

پیش پردازش داده ها به منظور تبدیل داده های سری زمانی خام شامل قیمت باز، بسته شدن، بالاترین، کمترین، پایانی و حجم به مجموعه ای از شاخص های تکنیکی برای هر روز معاملاتی انجام گرفته است. در تحقیق حاضر جهت محاسبه شاخص های تکنیکی، از کتابخانه تحلیل تکنیکی^{۱۲} که در سایت www.ta-lib.org در دسترس است، استفاده شده است؛ بنابراین، هر نقطه از داده مربوط به یک روز معاملاتی مشخص و شامل ۱۳ مقدار ورودی است که هر کدام برابر یک شاخص تکنیکی است. شاخص های نهایی ورودی مدل پیش بینی، با تعیین مقدار n و بر اساس قواعد انتخاب که در فاز دوم مدل پیشنهادی تحقیق بیان شده است، مشخص می شوند.

۴-۲- ساخت و آموزش مدل پیش بینی

در این مرحله، ابتدا متغیرهای ورودی نهایی جهت مدل سازی انتخاب می شوند. در اکثر تحقیقات گذشته، مقادیر پارامترهای اندیکاتورهای تکنیکی از قبل مشخص بوده و از مقادیر رایج استفاده می شد. اما باید در نظر داشت که مقادیر پارامترهای تکنیکی رایج بسته به بازار سهام مورد مطالعه و همچنین نمونه های مورد بررسی ممکن است از کارایی یکسانی برخوردار نباشد و در نتیجه خطای ناشی از پیش بینی توسط این اندیکاتورها افزایش یابد. بدین منظور برای کلیه اندیکاتورهای تکنیکی مقادیر مختلفی برای پارامترها علاوه بر مقادیر رایج و شناخته شده در نظر گرفته شد و بر روی هر اندیکاتور با مقادیر مختلف به صورت جداگانه برای کل دوره آموزش بر اساس قواعد معاملاتی تعریف شده در جدول شماره ۱، معاملات انجام شده و بازدهی محاسبه گردید. در نهایت

کلی تحقیق جهت تبدیل خروجی‌های مدل به سه دسته سیگنال‌های خرید، نگهداری و فروش به صورت زیر تعریف شده است:

<i>IF</i>	$(P_{t+1} - P_t)/P_t > 0$	<i>OR</i>	$R_{t+1} > 0$		
<i>If</i>	پرتفوی خالی از این سهم باشد	<i>THEN</i>		$\Rightarrow$	خرید سهم
<i>Elseif</i>	این سهم در پرتفوی باشد	<i>THEN</i>		$\Rightarrow$	نگهداری سهم
<i>ELSEIF</i>	$P_{t+1} - P_t)/P_t < 0$	<i>OR</i>	$R_{t+1} < 0$		
<i>If</i>	پرتفوی خالی از این سهم باشد	<i>THEN</i>		$\Rightarrow$	نگهداری سهم
<i>Elseif</i>	این سهم در پرتفوی باشد	<i>THEN</i>		$\Rightarrow$	فروش سهم

BP آموزش می‌بینند (Principe et al., 1999). قاعده BP، خطاها را به شبکه پخش می‌کند تا لایه‌های پنهان عناصر پردازشگر خود را تعدیل کنند. درواقع MLP ها از طریق یادگیری اصلاح خطا^{۱۴} آموزش می‌بینند به این صورت که از پاسخ سیستم در عنصر پردازشگر i در تکرار n یعنی $y_i(n)$ و پاسخ مطلوب $d_i(n)$ برای یک الگوی ورودی داده شده، خطای آنی $e_i(n)$ به صورت زیر تعریف می‌شود:

$$e_i(n) = d_i(n) - y_i(n) \quad (4)$$

در واقع خطای شبکه پس انتشار با میانگین مجذور خطا^{۱۵} (MSE) بیان می‌شود که رایج‌ترین تابع خطای استفاده شده در شبکه‌های عصبی است (راعی و فلاح‌پور، ۱۳۸۳). بر مبنای نظریه یادگیری کاهش گرادین، وزن‌های شبکه از طریق اصلاح ارزش وزن‌ها متناسب با وزن‌های ورودی و خطاها به صورت زیر تعدیل می‌گردند:

$$y_{ij}(n+1) = w_{ij}(n) + \eta \delta_i(n) x_j(n) \quad (5)$$

خطای محلی $d_i(n)$ به طور مستقیم از فرمول $e_i(n)$ یا از جمع وزنی خطاها در نرون‌های داخلی محاسبه می‌شود. مقدار ثابت η اندازه رتبه است که نرخ یادگیری نامیده می‌شود.

در تحقیق حاضر، فرض بر این است که در ابتدا پرتفوی خالی از سهم است و با توجه به فرایند اجرای مدل‌های پیش‌بینی، سرمایه‌گذار اقدام به استراتژی معاملاتی خود نموده و با اولین سیگنال خرید (یعنی "up")، اقدام به خرید می‌نماید و تا زمانی که سیگنال فروش صادر نگردد، سهم در سبد نگهداری می‌شود. همچنین در مقابل، زمانی که سیگنال "Down" صادر شود، اگر سهم در پرتفوی موجود باشد، معامله فروش سهم انجام خواهد شد و در صورتی که سهم در پرتفوی موجود نباشد، هیچ اقدامی صورت نمی‌گیرد؛ بنابراین برای تمامی نقاط در داده‌های تست، سیگنال‌های خرید و فروش صادر می‌شود و با توجه به استراتژی معاملاتی تعریف شده، معاملات انجام می‌گیرد. لذا، تعداد معاملات انجام شده در دوره آزمایش برای الگوریتم‌های مختلف یادگیری، متفاوت است.

۴-۳- شبکه عصبی پرسپترون چندلایه^{۱۳}

شبکه عصبی MLP یکی از شناخته‌ترین و محبوب‌ترین معماری شبکه عصبی است که در حل مسائل طبقه‌بندی و همین‌طور رگرسیونی کاربرد دارد (Ravi et al, 2017). ساختار ساده این مدل دارای سه لایه شامل لایه ورودی، لایه پنهان یا میانی و لایه خروجی است. MLP ها به طور معمول با الگوریتم‌های

$$v_{i,n}(t+1) = w_t \cdot v_{i,n}(t) + c_1 \cdot rand_1(pbest_{i,n}(t) - x_{i,n}(t)) + c_2 \cdot rand_2(gbest_{i,n}(t) - x_{i,n}(t)) \quad (10)$$

$$x_{i,n}(t+1) = x_{i,n}(t) + v_{i,n}(t+1) \quad (11)$$

که c_1 ضریب یادگیری از تجارب فردی هر ذره و c_2 ضریب یادگیری از تجارب گروهی می‌باشند، اعداد $rand_1$ و $rand_2$ نیز اعدادی تصادفی بین ۰ و ۱ می‌باشند. این مقادیر تصادفی باعث می‌شوند یک نوع گوناگونی در جواب‌ها به وجود آید. از طرفی ضریب اینرسی w_t نیز به‌عنوان یک پارامتر کنترلی، تأثیر سرعت فعلی ذره را بر سرعت بعدی کنترل نموده و یک حالت تعادل بین توانایی الگوریتم در جستجوی محلی^{۱۷} و جستجوی سراسری^{۱۸} ایجاد می‌نماید (کندی، ۱۹۹۷؛ میزبان و همکاران، ۱۳۹۱).

۴-۵- الگوریتم کلونی مورچگان پیوسته^{۱۹}

الگوریتم کلونی مورچگان پیوسته اولین بار توسط سوشا و دوریگو (۲۰۰۸) به‌عنوان یک راه‌حل چند عامله^{۲۰} جهت حل مسائل بهینه‌یابی ارائه شد. ایده اصلی الگوریتم کلونی مورچگان پیوسته به‌کارگیری از یک توزیع احتمال پیوسته به کمک یک تابع چگالی احتمال^{۲۱}، به‌جای استفاده از یک توزیع احتمال گسسته است که از یک کرنل گوسی^{۲۲} به‌جای یک تابع گوسی متشکل از مجموع وزن‌دار از چندین تابع گوسی واحد g است تعریف کرده است که به‌صورت زیر نشان داده می‌شود:

$$G^i(x) = \sum_{l=1}^n \omega_l g_l^i(x) = \sum_{l=1}^n \omega_l \frac{1}{\sigma_l \sqrt{2\pi}} e^{-\frac{(x-\mu_l^i)^2}{2\sigma_l^2}} \quad (12)$$

که در آن ω بردار وزن تابع گوسی، μ^i بردار میانگین و σ^i واریانس تابع گوسی و n پارامترهای مؤثر در حل مسئله هستند. چنین تابع چگالی احتمالی، علیرغم اینکه امکان نمونه‌برداری ساده‌ای را

۴-۴- الگوریتم بهینه‌سازی ازدحام ذرات^{۱۶}

بهینه‌سازی ازدحام ذرات (PSO) یک الگوریتم تکاملی تصادفی مبتنی بر هوش جمعی است که ابتدا توسط کندی و ابره‌ارت (۱۹۹۵) معرفی شد. در PSO تعدادی از ذرات پس از تولید جمعیت اولیه (راه‌حل‌ها) به وجود می‌آیند و دارای موقعیت اولیه تصادفی x و سرعت v می‌باشند. کارایی هر ذره بر اساس موقعیتش ارزیابی می‌شود. هر ذره سرعت خود را بر اساس بهترین پاسخ به‌دست‌آمده در گروه ذرات (بهترین فرد گروه) و بهترین موقعیتی که تاکنون در آن قرار گرفته است تغییر می‌دهد. این سرعت با موقعیت ذره جمع شده و موقعیت جدید ذره را تعیین می‌کند. در تکرارهای بعدی، بهترین ذره به سایر ذرات کمک می‌کند و حرکت آن‌ها را اصلاح کرده و پس از تکرارهای متوالی مسئله به سمت جواب بهینه همگرا خواهد شد.

بردار موقعیت و بردار سرعت به‌صورت زیر تعریف می‌شود:

$$X_i = [x_{i,1}, x_{i,2}, \dots, x_{i,n}] \quad (6)$$

$$V_i = [v_{i,1}, v_{i,2}, \dots, v_{i,n}] \quad (7)$$

که X_i بردار موقعیت n بعدی برای ذره i ام است که یک راه‌حل ممکن برای یک مسئله بهینه‌سازی است و V_i بردار سرعت n بعدی برای ذره i ام است. در طی حرکت، بهترین موقعیتی که هر ذره بر اساس تابع هدف در طول اجرای الگوریتم کسب کند، $pbest$ و بهترین موقعیت کسب شده توسط کل ذرات برای کل جمعیت، $gbest$ نامیده می‌شود که به‌صورت بردار زیر تعریف می‌شوند:

$$pbest = [p_{b,1}, p_{b,2}, \dots, p_{b,n}] \quad (8)$$

$$gbest = [g_{b,1}, g_{b,2}, \dots, g_{b,n}] \quad (9)$$

در زمان t ، بردار موقعیت و سرعت هر یک از ذرات با استفاده از معادله زیر به‌روز می‌شوند:

انتخابی S_i تا دیگر راه‌حل‌های موجود در آرشیو در پارامتر ξ ضرب می‌شود (رابطه زیر):

$$\sigma_i^j = \xi \sum_{e=1}^n \frac{|S_e^j - S_i^j|}{n-1} \quad (16)$$

که پارامتر $\xi > 0$ برای همه ابعاد یکسان است و تأثیری مشابه نرخ تبخیر فرومون در روش کلونی مورچگان دارد و مقادیر بالای ξ سرعت همگرایی پایین الگوریتم را به همراه دارد (Socha & Dorigo, 2008).

۴-۶- الگوریتم ژنتیک

فرایند کلی یک الگوریتم ژنتیک با جمعیتی از راه‌حل‌های فردی یا کروموزوم‌ها^{۲۳} که به صورت تصادفی ایجاد شده است، آغاز می‌شود. جمعیت در زمان معلوم را نسل^{۲۴} می‌نامند. طی هر نسل، کروموزوم‌ها (راه‌حل‌ها) با استفاده از یک تابع برازش^{۲۵} که توسط کاربر تعریف می‌شود، ارزیابی می‌شوند. دو فرد به عنوان والدین بر اساس معیار تناسب انتخاب می‌شوند و این افراد یک یا چند فرزند^{۲۶} را تولید می‌کنند. فرزندان جدید با استفاده از عملگرهای بازتولید^{۲۷} یعنی عملگر تقاطع^{۲۸} و عملگر جهش^{۲۹} ایجاد می‌شوند. سپس، برازندگی فرزندان جدید ارزیابی شده و به وسیله یکی از رویه‌های انتخاب کروموزوم‌های بهتر انتخاب و به نسل بعد منتقل می‌شوند. فرایند ذکر شده تا زمانی تکرار می‌شود که یک راه‌حل مناسب پیدا شود یا به تعداد معینی از نسل‌ها برسیم به عبارتی دیگر، الگوریتم به بهترین کروموزوم همگرا می‌شود که بیانگر جواب بهینه است (Kim et al, 2017). در واقع الگوریتم با ساخت یک سری رشته به نام کروموزوم و با انجام عملیات مشخص ژنتیکی، انتخاب، ترکیب و جهش در طول حیات رشته‌ها، به سمت تکامل و بهتر شدن آن‌ها حرکت می‌کند (فلاح‌پور و همکاران، ۱۳۹۲). در تحقیق حاضر، جمعیت اولیه برابر با ۱۰۰، تعداد

فراهم می‌کند، در مقایسه با یک تابع گوسی واحد انعطاف‌پذیرتر است. مجموعه جواب‌ها در الگوریتم کلونی مورچگان پیوسته در یک آرشیو ذخیره می‌شود. در آغاز الگوریتم، با تولید n راه‌حل تصادفی، آرشیو مقداردهی می‌شود. در واقع در آرشیو بردار راه‌حل $[s_1, s_2, \dots, s_n]$ تعریف می‌شود و مجموعه جواب هر راه‌حل وارد تابع هدف شده و مقدار آن محاسبه می‌شود که بردار $[f(s_1), f(s_2), \dots, f(s_n)]$ در کنار بردار راه‌حل‌ها نگهداری می‌شوند، آنگاه جواب‌های موجود در آرشیو بر اساس کیفیت آن‌ها به صورت رابطه زیر مرتب شده و ذخیره می‌شوند:

$$f(s_1) < f(s_2) < \dots < f(s_n) \quad (13)$$

سپس برای هر راه‌حل S_i یک وزن ω تعیین می‌شود که مقدار آن با کیفیت جواب مربوط است و از رابطه زیر محاسبه می‌شود:

$$\omega_i = \frac{1}{qn\sqrt{2\pi}} e^{-\frac{(I-1)^2}{2q^2n^2}} \quad (14)$$

بر اساس رابطه فوق، مقدار وزن تابع گوسی برابر یک است. q^n واریانس و q پارامتر الگوریتم است. هر چه q کوچک‌تر باشد راه‌حل‌های با رتبه بالاتر ترجیح دارند. سپس بردار میانگین کرنل گوسی باید تعیین شود. برای هر $G^{(x)}$ مقادیر i امین متغیر از راه‌حل‌های موجود در آرشیو به عنوان بردار میانگین μ^i انتخاب می‌شود که در رابطه زیر نشان داده شده است:

$$\mu^i = \{\mu_1^i, \dots, \mu_I^i\} = \{S_1^i, \dots, S_I^i\} \quad (15)$$

بردار سوم در کرنل گوسی که باید تعیین شود، بردار واریانس $qn = \sigma_I^i$ است. بدین منظور فرض می‌شود که هر مورچه، یکی از راه‌حل‌های موجود در آرشیو را بر اساس یک فرایند احتمالی مانند چرخه رولت انتخاب می‌کند؛ بنابراین راه‌حلی که رتبه بالاتری دارد شانس بیشتری برای انتخاب شدن را خواهد داشت. به منظور محاسبه σ_I^i میانگین فاصله‌ای راه‌حل

سهام، P_{it} بیانگر ارزش خالص خرید یا سرمایه‌گذاری در زمان هر معامله، i نشان‌دهنده هر سهم و e نیز نشانگر آخرین روز از دوره سرمایه‌گذاری می‌شود. همچنین ۵٪ به عنوان کارمزد خرید و ۱٪ به عنوان کارمزد فروش لحاظ شده است.

۵- نتایج پژوهش

در این بخش، نتایج تجربی به‌دست‌آمده از سیستم معاملاتی تکنیکی توسعه‌یافته در این تحقیق بحث می‌شود. آزمایش‌ها به‌صورت جداگانه بر روی هر سهم انجام‌شده است. به‌منظور بررسی و تحلیل ارتباط بین شاخص‌های معاملاتی تکنیکی و پیش‌بینی‌های حرکات آتی سهم، عملکرد هر یک از الگوریتم‌های یادگیری، با استفاده از دو معیار دقت پیش‌بینی و بازدهی خریدوفروش سنجیده شده است.

یافته‌های عملکرد کلی مدل‌ها- جدول شماره (۲) نتایج عملکرد کلی مدل‌های ترکیبی مورد استفاده در این تحقیق را در مقایسه با روش خرید و نگهداری نشان می‌دهد.

نسل‌ها برابر ۵۰، نرخ تقاطع برابر با ۰٫۸، نرخ جهش برابر با ۰٫۱ در نظر گرفته شد. شرط توقف الگوریتم، به پایان رسیدن تعداد نسل‌ها در نظر گرفته‌شده است. بر مبنای سیستم معاملاتی طراحی‌شده در این تحقیق، دقت پیش‌بینی با استفاده از فرمول زیر محاسبه می‌شود.

$$ACC_i = \frac{(True'UP + True'Down)}{N} \quad (۱۷)$$

که در آن ACC بیانگر دقت پیش‌بینی، $True'UP$ بیانگر نقاط افزایشی که به‌درستی پیش‌بینی‌شده است، $True'Down$ بیانگر نقاط کاهشی که به‌درستی پیش‌بینی‌شده است و N بیانگر کل نقاط دوره تست است.

علاوه بر این، نرخ بازده برای هر معامله در استراتژی فعال و روش خرید و نگهداری پس از اعمال هزینه کارمزد معاملات در بورس اوراق بهادار تهران به‌صورت زیر محاسبه می‌گردد (Dash & Dash, 2016).

$$R_{it} = \sum_{n=1}^e \frac{(P_{it+s} \times 0.99 - P_{it} \times 1.005)}{P_{it} \times 1.005} \quad (۱۸)$$

که در فرمول بالا، R_{it} نشانگر بازده حاصل از هر معامله، P_{it+s} نشان‌دهنده ارزش خالص فروش در زمان فروش

جدول شماره (۲): نتایج آزمون مقایسه زوجی برای عملکرد کلی مدل‌ها

MLP_PSO	MLP_GA	MLP_ACO _R	MLP_BP	مدل	
				آماره	
۶۶٫۲٪	۶۵٫۸٪	۶۱٫۸٪	۶۳٫۱٪	دقت پیش‌بینی	روش خرید و نگهداری
۱۳٫۸۰٪	۱۱٫۵۰٪	۹٫۲۰٪	۷٫۸۰٪	میانگین بازدهی	
۱۴٫۶۰٪	۱۲٫۲۰٪	۹٫۹۰٪	۸٫۵۰٪	اختلاف بازدهی	
۶٫۰۴۹۲	۶٫۹۹۴۹	۴٫۲۷۸۹	۳٫۷۲۳۱	آماره t	
۰٫۰۰۰۰۳	۰٫۰۰۰۰۱	۰٫۰۰۰۰۷۶	۰٫۰۰۲۲۷	P-Value	

همانطور که ملاحظه می‌گردد، کلیه مدل‌های ترکیبی تحقیق حاضر، از بازدهی کلی بیش‌تری نسبت به روش خرید و نگهداری برخوردار بوده‌اند. با توجه به نتایج آزمون مقایسه زوجی، می‌توان گفت میانگین بازدهی خرید و فروش مبتنی بر مدل‌های MLP_BP،

MLP_PSO و MLP_GA با سطح اطمینان ۹۵ درصد از روش خرید و نگهداری بیش‌تر می‌باشد. همچنین یافته‌های تحقیق نشان می‌دهد که مدل MLP_PSO در روندهای مختلف بازار شامل

صعودی، نزولی و خنثی نتایج کلی بهتری را نسبت به سایر روش‌های ترکیبی کسب کرده است.

یافته‌ها در روند صعودی- نتایج حاصل از مدل‌های ترکیبی تحقیق در مقایسه با روش خرید و نگهداری در

بازار دارای روند صعودی در جدول شماره (۳) نشان داده شده است.

جدول شماره (۳): نتایج آزمون مقایسه زوجی در روند صعودی

MLP_PSO	MLP_GA	MLP_ACO _R	MLP_BP	مدل	
				آماره	
٪۶۳،۴	٪۶۲،۸	٪۶۱،۳	٪۵۸،۲	دقت پیش بینی	روش خرید و نگهداری
٪۱۷،۳۰	٪۱۴،۲۰	٪۸،۵۰	٪۱۲،۵۰	میانگین بازدهی	
٪۵،۳۰	٪۲،۲۰	-٪۳،۵۰	٪۰،۴۰	اختلاف بازدهی	
۲،۱۰۰۴	۰،۶۶۵۸	۱،۳۱۴۲	۰،۱۸۰۲	آماره t	
۰،۰۵۴۲۹	۰،۵۱۶۳۷	۰،۲۰۹۹۲	۰،۸۵۹۵۷	P-Value	

یافته‌ها حکایت از آن دارد که مدل MLP_PSO در روند صعودی عملکرد بهتری را نسبت به سایر روش‌های ترکیبی داشته است.

یافته‌ها در روند نزولی- جدول شماره (۴) نشان دهنده نتایج حاصل از عملکرد مدل‌های ترکیبی تحقیق در بازار نزولی در مقایسه با روش خرید و نگهداری می‌باشد.

یافته‌های تحقیق در بازار دارای روند صعودی نشان می‌دهد، علی‌رغم این که مدل‌های ترکیبی MLP_BP، MLP_GA و MLP_PSO در مقایسه با روش خرید و نگهداری بازدهی بیش‌تری کسب کرده‌اند اما نتایج آزمون مقایسه زوجی گویای آن است که با توجه به مقدار P که از سطح معناداری ٪۵ بیشتر بوده است، بازدهی خرید و فروش مبتنی بر این مدل‌های ترکیبی در بازار دارای روند صعودی تفاوت معناداری با روش خرید و نگهداری ندارد. همچنین

جدول شماره (۴): نتایج آزمون مقایسه زوجی در روند نزولی

MLP_PSO	MLP_GA	MLP_ACO _R	MLP_BP	مدل	
				آماره	
٪۶۸،۱	٪۶۹،۱	٪۶۴،۲	٪۶۵،۲	دقت پیش بینی	روش خرید و نگهداری
-٪۱،۷۰	-٪۱،۴۰	-٪۱،۹۰	-٪۶،۴۰	میانگین بازدهی	
٪۸،۸۰	٪۹،۱۰	٪۸،۶۰	٪۴،۱۰	اختلاف بازدهی	
۵،۶۰۹۶	۴،۱۱۳۶	۳،۹۰۸۱	۱،۵۳۰۹	آماره t	
۰،۰۰۰۰۶	۰،۰۰۱۰۵	۰،۰۰۱۵۸	۰،۱۴۸۰۶	P-Value	

است. بر اساس مقدار P در سطح معناداری ٪۵، بازدهی خرید و فروش مبتنی بر کلیه مدل‌های ترکیبی تحقیق بجز مدل MLP_BP در بازار دارای روند نزولی تفاوت معناداری با روش خرید و نگهداری

نتایج بررسی‌ها در روند نزولی نشان می‌دهد که بازده کسب‌شده توسط مدل‌های MLP_BP، MLP_ACO_R، MLP_GA و MLP_PSO به ترتیب ٪۴،۱، ٪۸،۶، ٪۹،۱ و ٪۸،۸ بیشتر از بازدهی روش خرید و نگهداری

دارد و در بین مدل های ترکیبی مورد استفاده، مدل MLP_GA عملکرد بهتری نسبت به سایر مدل ها داشته است.

یافته ها در روند خنثی - نتایج مدل های تحقیق در مقایسه با روش خرید و نگهداری در بازار دارای روند خنثی در جدول شماره (۵) نشان داده شده است.

نتایج آزمون مقایسه زوجی در بازار دارای روند خنثی (جدول شماره ۵)، نشان می دهد که بازده کسب شده توسط مدل های MLP_BP، MLP_ACOR، MLP_GA و MLP_PSO به ترتیب ۰/۲، ۰/۴، ۰/۶، ۰/۵، ۰/۹ بیشتر از بازدهی روش خرید و نگهداری

است. بر اساس مقدار P در سطح معناداری ۵٪، بازدهی خرید و فروش مبتنی بر مدل های MLP_GA و MLP_PSO در بازار دارای روند خنثی تفاوت معناداری با روش خرید و نگهداری دارد اما عملکرد روش های MLP_ACOR و MLP_BP تفاوت معناداری با روش خرید و نگهداری نداشته است. یافته های تحقیق نشان می دهد که در بازار دارای روند خنثی، استفاده از مدل ترکیبی MLP_GA نتایج بهتری را نسبت به سایر مدل های مورد استفاده در تحقیق حاضر به همراه دارد.

جدول شماره (۵): نتایج آزمون مقایسه زوجی در روند خنثی

MLP_PSO	MLP_GA	MLP_ACO _R	MLP_BP	مدل	
				آماره	
۶۸،۰٪	۶۸،۱٪	۶۴،۷٪	۶۵،۲٪	دقت پیش بینی	روش خرید و نگهداری
۴،۹۰٪	۵،۱۰٪	۳،۳۰٪	۰،۹۰٪	میانگین بازدهی	
۵،۹۰٪	۶،۲۰٪	۴،۴۰٪	۲،۰۰٪	اختلاف بازدهی	
۳،۴۵۳۶	۳،۰۳۲۴	۱،۹۶۹۲	۱،۰۸۲۳	آماره t	
۰،۰۰۳۸۸	۰،۰۰۸۹۶	۰،۰۶۹۰۴	۰،۲۹۷۴۱	P-Value	

این تحقیق را در مقایسه با روش خرید و نگهداری در دوره بلند مدت نشان می دهد.

یافته ها بر اساس افق سرمایه گذاری - جدول شماره (۶) نتایج عملکرد مدل های ترکیبی مورد استفاده در

جدول شماره (۶): نتایج آزمون مقایسه زوجی برای دوره بلندمدت

MLP_PSO	MLP_GA	MLP_ACO _R	MLP_BP	مدل	
				آماره	
۶۵،۹٪	۶۴،۹٪	۶۰،۲٪	۶۳،۴٪	دقت پیش بینی	روش خرید و نگهداری
۲۰،۹۰٪	۱۷،۰۰٪	۱۵،۱۰٪	۱۳،۳۰٪	میانگین بازدهی	
۱۱،۵۰٪	۷،۷۰٪	۵،۷۰٪	۳،۹۰٪	اختلاف بازدهی	
۲،۵۰۰۳	۱،۷۵۳۹	۰،۹۷۳۷	۰،۷۴۶۷	آماره t	
۰،۰۲۵۴۵	۰،۱۰۱۳	۰،۳۴۶۷۲	۰،۴۶۷۶	P-Value	

روش خرید و نگهداری بوده است. با توجه به نتایج آزمون مقایسه زوجی، تنها بازدهی خرید و فروش مبتنی بر مدل MLP_PSO تفاوت معناداری با روش خرید و نگهداری داشته و سایر مدل ها باوجود کسب بازدهی

همان طور که در جدول شماره (۶) مشاهده می شود، بازده کسب شده توسط مدل های MLP_BP، MLP_GA، MLP_ACO_R و MLP_PSO به ترتیب ۰/۳، ۰/۵، ۰/۷، ۰/۷، ۰/۱۱، ۰/۹ بیشتر از بازدهی کل

همچنین جدول شماره (۷) نتایج عملکرد مدل های ترکیبی مورد استفاده در این تحقیق را در مقایسه با روش خرید و نگهداری در دوره کوتاه مدت نشان می دهد.

بیش تر از استراتژی خرید و نگهداری، به لحاظ آماری تفاوت بازدهی آن ها با اهمیت و معنادار نبوده است. از میان مدل های ترکیبی تحقیق، مدل MLP_PSO توانسته است بازدهی بیش تری را در مقایسه با سایر مدل ها کسب کند.

جدول شماره (۷): نتایج آزمون مقایسه زوجی برای دوره کوتاه مدت

MLP_PSO	MLP_GA	MLP_ACO _R	MLP_BP	مدل آماره	
				دقت پیش بینی	روش خرید و نگهداری
۶۶,۵٪	۶۶,۷٪	۶۳,۴٪	۶۲,۹٪	میانگین بازدهی	
۶,۸۰٪	۶,۰۰٪	۳,۳۰٪	۲,۳۰٪	اختلاف بازدهی	
۶,۷۰٪	۵,۸۰٪	۳,۲۰٪	۲,۲۰٪	آماره t	
۸,۵۹۲۹	۴,۲۸۷۱	۳,۱۴۶۷	۱,۷۵۷۶	P-Value	
۰,۰۰۰۰۰۱	۰,۰۰۰۰۷۵	۰,۰۰۰۰۷۱۴	۰,۱۰۰۰۶۴		

همان طور که جدول شماره (۷) نشان می دهد، بازده کسب شده توسط مدل های MLP_BP، MLP_ACO_R، MLP_GA و MLP_PSO به ترتیب ۲,۲٪، ۳,۲٪، ۵,۸٪ و ۶,۷٪ بیشتر از بازدهی کل روش خرید و نگهداری بوده است. با توجه به نتایج آزمون مقایسه زوجی، بر اساس مقدار P در سطح معناداری ۵٪، بازدهی حاصل از خرید و فروش با استفاده از مدل های ترکیبی MLP_ACO_R، MLP_GA و MLP_PSO در دوره کوتاه مدت تفاوت معناداری با روش خرید و نگهداری دارد اما عملکرد مدل MLP_BP تفاوت معناداری با روش خرید و نگهداری نداشته است. همچنین یافته های تحقیق حاکی از آن است که مدل MLP_PSO در دوره کوتاه مدت عملکرد بهتری را نسبت به سایر روش های ترکیبی داشته است.

PSO) و الگوریتم بهینه سازی ازدحام ذرات (ACOR) است. بدین منظور نمونه ۱۵ شرکت موجود در لیست ۵۰ شرکت فعال طی ۹ سال (از سال ۱۳۸۷ تا ۱۳۹۶) مورد بررسی قرار گرفتند. پس از طراحی و ساخت سیستم معاملاتی سهام، بازدهی و سودآوری هر یک از مدل ها محاسبه و در مقایسه با استراتژی خرید و نگهداری مورد آزمون قرار گرفته است. یافته های تحقیق نشان می دهد که مدل های ترکیبی MLP و الگوریتم های تکاملی، در مجموع با بازدهی ۱۱,۵ درصد عملکرد بهتری نسبت به بازدهی ۰,۷- درصدی روش خرید و نگهداری و ۷,۸ درصدی مدل ترکیبی MLP و الگوریتم یادگیری BP داشته است که بیان کننده پتانسیل سودآوری کاربرد تکنیک های محاسبات تکاملی در سیستم های هوشمند معاملاتی است. علی رغم این که بازدهی کسب شده توسط مدل های تکاملی در کلیه شرایط بازار شامل روندهای صعودی، نزولی و خنثی و افق کوتاه مدت و بلندمدت حتی با در نظر گرفتن هزینه معاملات، از روش خرید و نگهداری و الگوریتم یادگیری BP بیش تر بوده است، به لحاظ آماری در کوتاه مدت و روندهای نزولی و خنثی، بازدهی کسب شده تفاوت معناداری با روش های مقایسه ای داشته اما در بلندمدت و در بازار صعودی

۶- نتیجه گیری و بحث

هدف از تحقیق حاضر، طراحی سیستم هوشمند خرید و فروش سهام، مبتنی بر مدلی مرکب از شبکه عصبی MLP و الگوریتم های تکاملی شامل الگوریتم ژنتیک (GA)، الگوریتم بهینه سازی مورچگان پیوسته

اقتصادی به عنوان اطلاعات مکمل برای متغیرهای تکنیکی در جهت بهبود تصمیم‌گیری‌ها استفاده نمایند، چراکه در استراتژی‌های سطوح کلان‌تر و با افق سرمایه‌گذاری بلندمدت اثرگذار می‌باشند. همچنین پیشنهاد می‌شود به جای وزن‌های یکسان دارایی‌ها از تکنیک‌های بهینه‌سازی توزیع وزنی استفاده شود.

فهرست منابع

- * اعتمادی، حسین، انواری رستمی، علی اصغر، احمدیان، وحید، (۱۳۹۳)، ارزیابی توان پیش بینی سود فصلی هر سهم با استفاده از مدل‌های سری زمانی و شبکه ی پرسپترون چند لایه (MLP). مهندسی مالی و مدیریت اوراق بهادار. شماره ۲۳. تابستان ۱۳۹۴.
- * بدیعی، حسین، رضازاده، روح اله، محمودی، هادی، (۱۳۹۶)، پیش بینی رفتار قیمتی سهام در بورس اوراق بهادار با استفاده از شبکه ی عصبی مصنوعی (مطالعه موردی شرکت پالایش نفت اصفهان). مهندسی مالی و مدیریت اوراق بهادار. شماره سی و یکم / تابستان ۱۳۹۶.
- * بشیری، مهدی، وکیلان، فاطمه، سوگندی، فاطمه، (۱۳۹۴)، تقریب منحنی رگرسیون اسپلاین با استفاده از الگوریتم ژنتیک. نشریه مهندسی و مدیریت کیفیت. جلد ۵- شماره ۱- بهار ۱۳۹۴
- * راعی، رضا، پویانفر، احمد، (۱۳۸۹)، مدیریت سرمایه گذاری پیشرفته. چاپ سوم. تهران: انتشارات سمت.
- * راعی، رضا، حسینی، فرهنگ، (۱۳۹۴)، مقایسه بازده خرید و فروش مبتنی بر نماگرهای تکنیکی و منطق فازی و روش ترکیبی الگوریتم ژنتیک-منطق فازی. مهندسی مالی و مدیریت اوراق بهادار. شماره بیست و چهارم / پاییز ۱۳۹۴.
- * سینایی، حسنعلی، مرتضوی، سعید...، تیموری اصل، یاسر، (۱۳۸۴)، پیش بینی شاخص بورس اوراق بهادار تهران با استفاده از شبکه های عصبی

این تفاوت معنادار نبوده است. نتیجه حاصل شده از تحقیق حاضر با نتایج تحقیقات مروری انجام شده توسط هیو و همکاران (۲۰۱۵) از بعد روند بازار و افق سرمایه‌گذاری مطابقت دارد. نتیجه این تحقیق و مروری که بر روی ۵۱ پژوهش مرتبط با موضوع سودآوری کاربرد محاسبات تکاملی در طراحی سیستم‌های معاملاتی انجام گرفته است، نشان می‌دهد که الگوریتم‌های تکاملی مورد استفاده در سیستم‌های معاملاتی عمدتاً در روندهای نزولی و بدون لحاظ هزینه معاملات عملکرد بهتری نسبت به روش خرید و نگهداری داشته‌اند و برعکس در روندهای صعودی و با لحاظ هزینه معاملات، فن‌های مورد استفاده چندان موفق عمل نکرده‌اند. همچنین عملکرد مدل‌ها در کوتاه‌مدت و بلندمدت نتایج متناقضی را در پی داشته است (Hu et al, 2015). نتایج تحقیق حاضر همچنین با یافته‌های تحقیق انجام گرفته توسط رضا تهرانی و وحید عباسیون (۱۳۸۷) مطابقت دارد. آن‌ها در تحقیق خود با استفاده از شبکه عصبی و تحلیل تکنیکی به زمان‌بندی خرید و فروش سهام پرداختند و نتایج نشان داد که عملکرد سیستم در بازارهای نزولی موفق بوده اما در بازار صعودی عملکرد بهتر و معناداری در مقایسه با روش خرید و نگهداری کسب نکرده است.

در مجموع، از بین مدل‌ها و روش‌های مورد استفاده، مدل MLP_PSO با بازده ۱۳٫۸ درصدی بهترین عملکرد را نسبت به سایر مدل‌ها داشته است. پس از آن به ترتیب مدل‌های MLP_GA، MLP_ACOR و MLP_BP با بازدهی‌های ۱۱٫۵٪، ۹٫۲٪ و ۷٫۸٪ در رتبه‌های بعدی قرار گرفته‌اند. عملکرد سیستم خرید و فروش سهام نشان می‌دهد که به کارگیری متغیرهای تکنیکی و مدل‌های یادگیری الگوریتم‌های تکاملی می‌تواند در غلبه بر پیچیدگی‌ها و بهبود در تصمیم‌گیری‌های خرید و فروش سهام در بازار سرمایه ایران سودمند باشد و رویکرد استراتژی فعالانه سرمایه‌گذاری در بازار ایران از کارایی بیش‌تری نسبت به رویکرد غیرفعال دارد. برای تحقیقات آتی پیشنهاد می‌گردد که از متغیرهای بنیادی و متغیرهای کلان

- systems: Fundamentals through simulations. New York, USA: John Wiley & Sons. 10389–10397
- * José Manuel Berutich, Francisco López, Francisco Luna, David Quintana, 2016. Robust technical trading strategies using GP for algorithmic portfolio selection. *Expert Systems With Applications* 46 (2016) 307–315
 - * Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. *Proceedings of IEEE international conference on neural networks*, Piscataway, NJ (Vol. 4, pp. 1942–1948). IEEE.
 - * Kennedy, J.(1997), The particle Swarm , Social adaptation of knowledge, p.p.303-308K.
 - * Levy, R., 1967. Random walks: Reality or myth, *Financ. Anal. J.* 23 (6) (1967) 69–77.
 - * Ling-xiao Cui, Wen Long, 2016. Trading strategy based on dynamic mode decomposition: Tested in Chinese stock market. *Physica A* 461 (2016) 498–508.
 - * Socha, M. Dorigo, Ant colony optimization for continuous domains, *European Journal of Operational Research*, Vol. 185, pp. 1155-1173, 2008.
 - * M.A.H. Dempster, C.M. Jones, A real-time adaptive trading system using genetic programming, *Quant. Financ.* 1 (2001) 397–413.
 - * M. Qiu, Y. Song. (2016). Predicting the Direction of Stock Market Index Movement Using an Optimized Artificial Neural Network Model. *PLOS ONE* | DOI:10.1371/journal.pone.0155133 May 19, 2016.
 - * Rajashree Dash, Pradipta Kishore Dash. (۲۰۱۶). A hybrid stock trading framework integrating technical analysis with machine learning techniques. *The Journal of Finance and Data Science* 2 (2016) 42-57.
 - * Rubell Marion Lincy G, Jessy John C, 2016. A multiple fuzzy inference systems framework for daily stock trading with application to NASDAQ stock exchange. *Expert Systems With Applications* 44 (2016) 13–21.
 - * Vadlamani Ravia, Dadabada Pradeepkumar, Kalyanmoy Deb. 2017. Financial time series prediction using hybrids of chaos theory, multi-layer perceptron and multi-objective evolutionary algorithms. *Swarm and Evolutionary Computation* 36 (2017) 136–149.
 - مصنوعی. بررسیهای حسابداری و حسابرسی. سال دوازدهم شماره ۴۱ پاییز ۱۳۸۴. ص ۸۳-ص ۵۹.
 - * فلاح پور، سعید، گل ارضی، غلامحسین، فتوره چیان، ناصر، (۱۳۹۲)، پیش بینی روند حرکتی قیمت سهام با استفاده از ماشین بردار پشتیبان بر پایه الگوریتم ژنتیک در بورس اوراق بهادار تهران. *تحقیقات مالی*. دوره ۱۵. شماره ۲. پاییز و زمستان ۱۳۹۲.
 - * محمدی، شاپور، موسوی سرحدی، سید علی، نوری بخش، محمد، (۱۳۹۶)، طراحی سیستم هوشمند خرید و فروش بر اساس مدلی مرکب از الگوریتم ماشین بردار پشتیبان و تئوری کانال روند. *مجله مهندسی مالی و مدیریت اوراق بهادار*. شماره سی و دوم / پائیز ۱۳۹۶.
 - * منهج، محمدباقر، (۱۳۷۷)، مبانی شبکه های عصبی، تهران: مرکز نشرپرفسور حسابی، چاپ اول.
 - * میزبان، هدیه سادات، افچنگی، زهرا، احراری، مهدی، آروین، فرشاد، سوری، علی، (۱۳۹۱). *بهینه سازی سبد سهام با استفاده از الگوریتم ازدحام ذرات در تعاریف مختلف اندازه گیری ریسک*. فصلنامه علوم اقتصادی. سال ششم. شماره ۱۹.
 - * Covell, M.W., 2009. *Trend Following (Updated Edition): Learn to Make Millions in Up or Down Markets*, Pearson Education, New Jersey, 2009
 - * Fama, E.-F., Blume, M.-E., 1966. Filter rules and stock-market trading, *J. Bus.* 39 (1) (1966) 226–241.
 - * F. Allen, R. Karjalainen, Using genetic algorithms to find technical trading rules, *J. Financ. Econ.* 51 (1999) 245–271.
 - * Furong Ye, Liming Zhang, Defu Zhang, Hamido Fujita, Zhiguo Gong, 2016.
 - * A novel forecasting method based on multi-order fuzzy time series and technical analysis. *Information Sciences* 367–368 (2016) 41–57.
 - * Chung-Ho Su, Ching-Hsue Cheng, 2016. A hybrid fuzzy time series model based on ANFIS and integrated nonlinear feature selection method for forecasting stock. *Neurocomputing* 205(2016)264–273.
 - * J.C. Principe, N.R, Euliano & W.C. Lefebvre. (1999). *Neural and adaptive*

یادداشت‌ها

- ¹ Algorithmic Trading
- ² Trading Strategy
- ³ Technical Trading Rules
- ⁴ Fuzzy Systems
- ⁵ Evolutionary Computation
- ⁶ Genetic Algorithms
- ⁷ Multi-layer perceptron Neural Network
- ⁸ Back propagation (BP) algorithm
- ⁹ Gradient Descent
- ¹⁰ Efficient Market Hypothesis
- ¹¹ Buy and Hold
- ¹² TA_Lib
- ¹³ Multi Layer Perceptron Neural Network
- ¹⁴ Error correction learning
- ¹⁵ Mean Square Error
- ¹⁶ Particle Swarm Optimization Algorithm
- ¹⁷ Local Expansion
- ¹⁸ Global Expansion
- ¹⁹ Continuous Ant Colony Algorithm
- ²⁰ Multi Agent
- ²¹ Probability Density Function
- ²² Gaussian Kernel
- ²³ Chromosomes
- ²⁴ Generation
- ²⁵ Fitness Function
- ²⁶ Offspring
- ²⁷ Reproduction Operator
- ²⁸ Crossover Operator
- ²⁹ Mutation Operator

- * Vasiliou, D., Eriotis, N., Papathanasiou, S., 2006. How rewarding is technical analysis? Evidence from Athens stock exchange, *Oper. Res.* 6 (2) (2006) 85–102.
- * Xiao-dan Zhang, Ang Li, Ran Pan, 2016. Stock trend prediction based on a new status box method and AdaBoost probabilistic support vector machine. *Applied Soft Computing* 49 (2016) 385–398
- * Yauheniya Shynkevich, T.M. McGinnity, Sonya A. Coleman, Ammar Belatreche, Yuhua Li, 2017. Forecasting price movements using technical indicators: Investigating the impact of varying input window length. *Neurocomputing* 264 (2017) 71–88
- * Youngmin Kim, Wonbin Ahn, Kyong Joo Oh, David Enke. An intelligent hybrid trading system for discovering trading rules for the futures market using rough sets and genetic algorithms. *Applied Soft Computing* 55 (2017) 127–140.
- * Yong Hu, Kang Liu, Xiangzhou Zhang, Lijun Su, E.W.T. Ngai, Mei Liu. (2015). Application of evolutionary computation for rule discovery in stock algorithmic trading: A literature review. *Applied Soft Computing*. 36, 534–551