

طراحی مدل برای آربیتراژ آماری سهام با استفاده از شبکه‌های عصبی عمیق، جنگل‌های تصادفی و درخت‌های با شیب تقویت‌شده

فروزان کمری¹، علیرضا سارنج^{2*}، رضا تهرانی³، میثم شهبازی²

- 1- دانشجوی دکتری، گروه مدیریت صنعتی و مالی، دانشکده مدیریت و حسابداری، پردیس فارابی، دانشگاه تهران، قم، ایران.
- 2- استادیار، گروه مدیریت صنعتی و مالی، دانشکده مدیریت و حسابداری، پردیس فارابی، دانشگاه تهران، قم، ایران.
- 3- استاد دانشکده مدیریت، دانشگاه تهران، تهران، ایران

پذیرش: 98/4/19

دریافت: 97/11/13

چکیده

آربیتراژ آماری، استراتژی رایج سرمایه‌گذاری در بازارهای ناکاراست که نسبت به بازار خنثی بوده و بدون نیاز به سرمایه اولیه از هر دو جهت بازار کسب سود می‌کند. این تحقیق بر آن است تا ضمن طراحی مدل‌های مناسب برای آربیتراژ آماری سهام با استفاده از الگوریتم شبکه‌های عصبی عمیق، جنگل‌های تصادفی، درخت با شیب تقویت‌شده و ترکیب ساده این مدل‌ها، به تحلیل و بررسی بازده و ریسک مدل‌های طراحی شده بپردازد. بدین منظور از اطلاعات همه شرکت‌های عضو بورس اوراق بهادار تهران از 1385 تا 1396 برای ایجاد سیگنال‌های معاملاتی استفاده شده است. طراحی مدل‌های تحقیق و کدنویسی‌های مربوطه و همچنین آزمون فرضیات تحقیق که با t-test مورد تحلیل قرار گرفته در نرم‌افزار R انجام شده است. یافته‌های تحقیق نشان‌دهنده آن است که بیشترین مقدار بازده 4/24 درصد در هر روز برای $k=5$ است (بدون هزینه معاملات) که متعلق به مدل ترکیبی ساده (ENS) است. همچنین کمترین میزان ارزش در معرض ریسک (4/45-%) و کمترین مقدار ریزش

مورد انتظار (5/57%-) برای $k=20$ متعلق به مدل شبکه عصبی عمیق (DNN) و بالاترین مقدار نسبت بازده به انحراف معیار 1/072 است که متعلق به مدل RAF به ازای $k=20$ می‌باشد. علاوه بر آن نتایج تحقیق نشان می‌دهند بازده‌های اخیر سهم قدرت پیش‌بینی‌کنندگی بالاتری در مقایسه با بازده‌های قبل‌تر دارند.

واژگان کلیدی: آربیتراژ آماری، یادگیری عمیق، جنگل‌های تصادفی، درخت‌های با شیب تقویت‌شده، یادگیری ترکیبی.

1- مقدمه

در هر تصمیم‌گیری برای سرمایه‌گذاری دو عامل از اهمیت بسزایی برخوردار است. این دو عامل ریسک و بازده نام دارند. منظور از بازده مزایایی است که در طول دوره سرمایه‌گذاری به سرمایه‌گذار تعلق می‌گیرد [1] و منظور از ریسک طبق تعریف سازمان بین‌المللی استاندارد اثر عدم قطعیت بر اهداف یا زیان بالقوه یک سرمایه‌گذاری می‌باشد [2]. با توجه به اینکه هدف اصلی بیشتر سرمایه‌گذاران کسب حداکثر بازده و رسیدن به بالاترین درجه مطلوبیت می‌باشد، از این رو انتخاب روش درست سرمایه‌گذاری که تحت چتر استراتژی سرمایه‌گذاری قابل بررسی است و اثری مستقیم بر بازدهی و مطلوبیت دارد از اهمیت بالایی برخوردار است [1]. کارایی بازار یکی از مهم‌ترین عوامل اثرگذار در انتخاب استراتژی سرمایه‌گذاری مناسب می‌باشد. نتیجه طبیعی اعتقاد به کارایی بازار، استفاده از استراتژی منفعلانه برای تملک و مدیریت سهام عادی است. برعکس در یک بازار غیرکارا، تمام اطلاعات پیرامون سهام اثر خود را بر قیمت نگذاشته است، بنابراین می‌توان اطلاعاتی را پیدا کرد که دیگران به آن دست نیافته‌اند. به عبارت دیگر در یک بازار غیرکارا، سهام زیر قیمت وجود دارد و می‌توان بازدهی بیشتری از بازده بازار به دست آورد. بنابراین در چنین بازاری باید بیشتر فعال بود [3]. آربیتراژ آماری یک استراتژی رایج و سودآور در بازارهای مالی ناکاراست. آربیتراژ آماری اصطلاحی است که در برگیرنده تمامی استراتژی‌های معاملاتی کمی است که عمدتاً در سطح وسیعی توسط نهادها و مؤسسات سرمایه‌گذاری مختلف به ویژه صندوق‌های پوششی یا میزهای معاملاتی اختصاصی انجام می‌شود [4]. آربیتراژ آماری دربردارنده استراتژی‌هایی است که

ویژگی‌های زیر را دارا است: (1) سیگنال‌های معاملاتی، سیستماتیک یا قاعده‌مند هستند به طوری که دقیقاً در مقابل عوامل بنیادی قرار می‌گیرند، (2) حساب معاملاتی نسبت به بازار خنثی است، به این صورت که با بازار بتای صفر دارد، (3) مکانیسم ایجاد اضافه بازدهها آماری است [5]. آربیتراژ آماری تعداد زیادی از اوراق بهادار (صدها تا هزاران، بسته به مقدار ریسک سرمایه)، دوره نگهداری خیلی کوتاه (برحسب روز تا ثانیه) و زیرساخت‌های محاسباتی، معاملاتی و فناوری اطلاعات (IT) را در برمی‌گیرد. نظر به آنکه استراتژی مذکور از هر دو جهت بازار (صعودی و نزولی) کسب سود می‌نماید و خود تامین‌مالی‌شونده¹ است بسیار مورد توجه فعالان بازار سرمایه می‌باشد. آربیتراژ آماری مدت زمان مدیدی است که توسط سرمایه‌گذاران حرفه‌ای بورس‌های دنیا مورد استفاده قرار می‌گیرد، اما به دلیل آنکه بخشی از اسرار تجاری آنان محسوب می‌شود تمایل چندانی برای افشای مدل‌های آن در قالب متون علمی وجود ندارد [6]. رویکردهای شناسایی فرصت‌های آربیتراژ آماری از معاملات زوجی تا مدل‌های غیرخطی پیچیده رتبه‌بندی می‌شوند. اخیراً محققان به دنبال توسعه متدهای «جعبه سیاه» برای کسب سود هستند [7].

نظر به اینکه ناکارایی اطلاعاتی بازار سرمایه ایران در تحقیقات مختلف به اثبات رسیده است [8 و 9] و همچنین با توجه به اینکه یکی از استراتژی‌های کارآمد در بازار غیرکارا، آربیتراژ آماری است این تحقیق برآن است تا با طراحی مدل‌های مناسب با استفاده از الگوریتم‌های شبکه عصبی عمیق، درخت با شیب تقویت‌شده، جنگل‌های تصادفی و ترکیب ساده این الگوریتم‌ها گامی در جهت توسعه رویکردها و تکنیک‌های پیچیده آماری که لازمه استفاده از استراتژی مذکور می‌باشد بردارد. علاوه بر بحث تنظیم بهینه پارامترها برای دستیابی به مدل‌های مناسب آربیتراژ سهام، چندین هدف دیگر نیز بطور موازی در این پژوهش محقق می‌شود. تحلیل‌های بیشتر که به منظور بررسی کارایی مدل‌های طراحی شده و مقایسه نتایج حاصله با شاخص بازار و همچنین مقایسه نتایج بین مدل‌های طراحی شده بر مبنای الگوریتم‌های مختلف و درنهایت ارائه شواهد قوی در تأیید ناکارایی بازار سرمایه ایران انجام می‌گیرد از جمله دستاوردهای دیگر این تحقیق می‌باشند.

1. Self-financing

برای طراحی مدل‌ها از اطلاعات همه سهام فهرست‌شده در بورس اوراق بهادار تهران استفاده شده است. این مدل‌ها با بازده‌های وقفه‌دار همه سهام بورس اوراق بهادار تهران آموزش داده می‌شوند و احتمال هر سهم برای داشتن عملکرد بالاتر از کل بازار پیش‌بینی می‌شود. برای هر روز از ابتدای 1385 تا پایان شهریور 1396، همه سهام برطبق احتمال پیش‌بینی خارج از نمونه به صورت نزولی رتبه‌بندی می‌شوند. k سهم بالای رتبه خریداری و k سهم پایین رتبه فروخته می‌شوند. این مقاله به صورت زیر سازماندهی شده است: در بخش‌های 2 و 3 مبانی نظری و پیشینه تحقیق آورده شده است. در بخش 4 روش‌شناسی تحقیق و مراحل مختلف آن تشریح گردیده است. آزمون فرضیات پژوهش و نتایج مدل‌های طراحی شده در بخش 5 ذکر شده است. در بخش 6 تحلیل ریسک مدل‌ها و اهمیت متغیرها و در بخش آخر نیز پیشنهادات و نتیجه‌گیری تحقیق آورده شده است.

2- مبانی نظری

در حوزه مالی، آربیتراژ آماری طبقه‌ای از استراتژی‌های معاملاتی کوتاه‌مدت است که از مدل‌های برگشت به میانگین برای تشکیل پرتفوی‌های متنوع اوراق بهادار در سطح وسیعی استفاده کرده و برای دوره‌های زمانی کوتاه‌مدت نگهداری می‌شوند. این استراتژی‌ها به وسیله پلتفرم‌های معاملاتی، کامپیوتری و ریاضی پشتیبانی می‌شوند [4]. ویژگی متمایز چنین استراتژی‌هایی آن است که سودها می‌توانند از طریق کشف قیمت‌گذاری نادرست آماری یک یا بیشتر از یک دارایی براساس ارزش مورد انتظار این دارایی‌ها ایجاد شود [5]. مدل‌های آربیتراژ آماری عموماً خودکار و با مداخله خیلی کم سرمایه‌گذار هستند. مدل، معاملات را ایجاد کرده و آنها را با هدف کسب صدها یا هزاران سود خیلی کم طی یک چارچوب زمانی مفروض اجرا می‌کند. مزایای این نوع از معاملات آن است که احساسات و هیجانات انسانی را از معاملات حذف می‌کند. عقیده بر این است که احساسات اغلب به شکست یک سیستم موفق منجر می‌شود [10]. در استراتژی آربیتراژ آماری وقتی اختلاف قیمت دو سهم زیاد شد، سهام گران‌تر فروش استقراری و سهام ارزان‌تر خریداری می‌شود و بنابراین هیچ سرمایه‌ی اولیه‌ای هزینه نمی‌شود. سپس، با گذشت زمان که اختلاف قیمت دو سهم نزدیک صفر شود با فروش سهام موجود در سبد، سهامی که قرض شده بود پس داده می‌شود و اختلاف قیمت این دو

سهام برای سرمایه‌گذار باقی می‌ماند. مزایای آربیتراژ آماری برای کسب سود باعث شده است که این رویکرد به سرعت توسعه یافته و طیف وسیعی از مطالعات بازار از سال 2009 تاکنون را نیز تحت تأثیر قرار دهد [11].

3- پیشینه تحقیق

در جدول 1 مهم‌ترین مطالعات داخلی و خارجی انجام شده در حوزه آربیتراژ آماری آورده شده است [4 و 12 و 6 و 13 و 14 و 15 و 16 و 17 و 7].

جدول 1 خلاصه تحقیقات داخلی و خارجی انجام شده

نویسندگان و سال انتشار	عنوان مقاله	روش تحقیق	نتیجه
فروش باستانی و قاسمی (1391)	رویکرد کنترل تصادفی برای معاملات جفتی بهینه	استفاده تفاضل لگاریتم قیمت‌های جفت با یک فرایند تصادفی پایا	تأیید امکان اجرای آربیتراژ آماری موفق در ایران
عسگری و ابو (1391)	بررسی اثربخشی استراتژی معاملات جفتی بر روی قراردادهای آتی سکه	ترکیب رویکردهای تصادفی و هم‌انباشتی	تأیید مناسب بودن آربیتراژ آماری قراردادهای آتی سکه
احمدزاده و همکاران (1393)	آزمون آربیتراژ آماری در بورس اوراق بهادار تهران	معاملات گشتاوری	تأیید مناسب بودن آربیتراژ آماری در بازار سرمایه ایران
جلیلیان و عسگری (1394)	طراحی و اجرای نرم‌افزار استراتژی معاملات جفتی برای استفاده در بازار سرمایه	کدنویسی در محیط ++C برای اجرای آربیتراژ براساس خاصیت برگشت به میانگین و ضریب همبستگی	تأیید مناسب بودن آربیتراژ آماری در بازار سرمایه ایران
پاکیزه و حبیبی (1395)	مقایسه سودآوری استراتژی معاملات جفتی بین طبقات مختلف دارایی	استفاده از روش‌های کمترین فاصله، روش آزمون دیکی فولر تعمیم‌یافته و آزمون علیت گرنجری و روش بر پایه رگرسیون خطی	تأیید نظریه ایجاد بازده بالاتر از بازده بازار به هنگام استفاده از طبقات مختلف دارایی
تاکتوچی و لی (2013)	بکارگیری یادگیری عمیق برای ارتقاء استراتژی معاملات مومنتوم سهام	استفاده از شبکه‌های عصبی عمیق و ماشین محدود شده بولتنزمن (RBM)	کسب بازده‌های سالانه 45/93 درصد
موریتز و زیمرمن (2014)	طبقات پرتفوی شرقی عمیق: رابطه بین بازده‌های گذشته و آتی سهام	استفاده از جنگل‌های تصادفی	ایجاد میانگین اضافه بازده تعدیل شده در برابر ریسک
دیکسون و همکاران (2015)	استقرار شبکه‌های عصبی عمیق برای پیش بینی بازار مالی	استقرار و پیاده‌سازی کارای الگوریتم شیب‌دار نزولی تصادفی	پیش بینی روند و قیمت آتی سهام
کراثوس و همکاران (2017)	شبکه‌های عصبی عمیق، جنگل‌های تصادفی و درخت با شیب تقویت شده: آربیتراژ آماری روی شاخص S&P 500	استفاده از شبکه‌های عصبی عمیق، درخت با شیب تقویت شده و جنگل‌های تصادفی	تأیید مناسب بودن آربیتراژ آماری در بازار سهام آمریکا

4- روش‌شناسی پژوهش

این تحقیق با استفاده از روش کمی که نتیجه رویکرد خردگرایانه است، انجام می‌شود. همچنین روش و نوع انجام این پژوهش، تحلیلی در برابر توصیفی، کاربردی در مقابل بنیادی و تجربی در مقابل مفهومی است. روش‌شناسی تحقیق از جمله تحقیقات زمینه‌ای پس‌رویدادی است. بنابراین در این تحقیق از اطلاعات آماری مربوط به گذشته برای مدلسازی و آزمون فرضیه‌ها استفاده شده است. برای انجام این تحقیق ابتدا اطلاعات مربوط به کلیه سهم‌های عضو بورس اوراق بهادار تهران (320 شرکت) طی دوره مطالعه (ابتدای 1385 تا پایان شهریور 1396) استخراج می‌شود. سپس، کل داده‌ها به دو دوره مطالعه شامل مجموعه‌های آموزشی و معاملاتی تقسیم می‌شوند. مجموعه‌های آموزشی برای آموزش مدل‌های معین در نمونه¹ و مجموعه‌های معاملاتی برای شواهد خارج از نمونه² مورد نیاز هستند. در این تحقیق «دوره مطالعه» شامل یک دوره آموزشی 750 روزه (تقریباً 3 سال) و 250 روز بعد آن (تقریباً 1 سال) دوره معاملاتی تعریف می‌شود. کل مجموعه داده‌ها از سال 1385 تا 1396 در 9 دوره مطالعه قرار می‌گیرند به طوری که دوره‌های معاملاتی با هم همپوشانی نداشته باشند. در مرحله بعد، برای هر یک از این دوره‌های مطالعه فضای ویژگی لازم برای ایجاد پیش‌بینی‌ها ساخته می‌شود. برای هر دوره مطالعه، فضای ویژگی (ورودی) ایجاد می‌شود و متغیر پاسخ (خروجی) به صورت زیر است:

$$P^s = (p_t^s)_{t \in T} \quad (1)$$

فرایند قیمت سهم s است $s \in \{1, 2, \dots, n\}$ سپس بازده ساده $R_{t,m}^s$ برای هر سهم s طی دوره m به صورت زیر است:

$$R_{t,m}^s = \frac{P_t^s}{P_{t-m}^s} - 1 \quad (2)$$

در این تحقیق برای داده‌های روزانه، $m \in \{\{1, 2, \dots, 20\} \cup \{4, 60, \dots, 240\}\}$ مورد بررسی قرار می‌گیرد. در این تحقیق یک متغیر پاسخ باینری $Y_{t+1}^s \in \{0, 1\}$

1. In-sample
2. Out of sample

برای هر سهم s ایجاد می‌شود. Y_{t+1}^s برابر با یک (طبقه 1) است اگر بازده یک دوره $R_{t+1,1}^s$ سهم s بزرگتر از بازده میانه مقطعی محاسبه شده کل سهام باشد و در غیر این صورت برابر با صفر (طبقه 0) می‌شود. بنابراین هر دوره مطالعه در ابتدا شامل 1000 روز است که 240 روز اول هر دوره مطالعه به خاطر ایجاد ویژگی از دست می‌رود و دوره آموزش به 510 مشاهده کاهش می‌یابد و دوره معاملاتی با 250 مشاهده باقی می‌ماند. با فرض اینکه n_i برای همه دوره‌های مطالعه حدود 320 سهم است، مجموعه‌های آموزشی در تحقیق تقریباً شامل ماتریس‌های 163200×32 و مجموعه‌های معاملاتی شامل ماتریس‌های 80000×32 می‌باشد. سپس، شبکه‌های عصبی عمیق، جنگل‌های تصادفی و درخت‌های با شیب تقویت شده روی هر یک از مجموعه‌های آموزش، آموزش داده می‌شوند.

روش‌های هوش مصنوعی علاوه بر توانایی رویارویی با شاخصه‌های نادقیق و بررسی روابط پیچیده و غیرخطی میان آنها از قابلیت پیش‌بینی نیز برخوردار هستند. کاربردهای متنوع شبکه عصبی در مطالعات مختلف به اثبات رسیده است [18]. یک شبکه عصبی عمیق از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل می‌شود که توپولوژی شبکه‌ای ایجاد می‌کنند. لایه ورودی منطبق بر فضای ویژگی است به طوری که تعداد نورون‌های ورودی با تعداد متغیرهای پیش‌بینی‌کننده برابر است. لایه خروجی می‌تواند یک لایه رگرسیونی یا یک لایه طبقه‌بندی برای تطابق فضای خروجی باشد. همه لایه‌ها از نورون تشکیل می‌شوند که واحد اصلی این شبکه‌ها می‌باشد. در این تحقیق کد توپولوژی شبکه عصبی عمیق به صورت $I - H_1 - H_2 - H_3 - O$ در نظر گرفته می‌شود که در آن I تعداد نورون‌های ورودی، H_1 ، H_2 ، و H_3 تعداد نورون‌های مخفی در لایه‌های پنهان 1، 2، 3 و O تعداد نورون‌های خروجی است. در این رابطه معماری 2-5-10-31-31 انتخاب می‌شود. لایه ورودی متناظر با فضای ورودی است که در بردارنده 31 ویژگی است. لایه خروجی متناظر با فضای خروجی باینری (0 و 1) است. از نسبت خروج پنهان 0/5 و از نسبت ورودی به خروجی 0/1 استفاده می‌شود [19]. همچنین، تنظیم L_1 با پارامتر

انقباض¹ خیلی جزئی $\lambda_{DNN} = 0/00001$ انجام می‌گیرد. تعداد دفعات عبور از روی مجموعه آموزشی که با epochs نمایش داده می‌شود برابر با 400 انتخاب می‌شود و دانه (بذر) روی 1 تنظیم می‌شود و مابقی پارامترهای تنظیمی روی مقادیر پیش فرض H_2O قرار داده می‌شوند [20]. شیب تقویت شده تصادفی توسط فریدمن² [21] (2002) معرفی شده است، که در آن زیر مجموعه‌ای از داده‌های آموزشی بر روی هر تکرار برای مناسبت با یادگیرنده پایه به عنوان نمونه انتخاب می‌شوند. در این پژوهش ویژگی‌ها M_{GBT} به صورت تصادفی از p ویژگی بر روی هر بخش انتخاب می‌شوند. چهار پارامتر برای تنظیم وجود دارد: تعداد درختان یا تکرار تقویت شده M_{GBT} ، عمق درخت J_{GBT} ، نرخ یادگیری λ_{GBT} و زیر مجموعه‌ای از ویژگی‌ها برای استفاده در هر تقسیم که تعداد تکرارها روی 200 تنظیم می‌شود. عمق درخت $J_{GBT} = 3$ انتخاب می‌شود و مطابق رویه هاستی و همکاران³ (2009) در این تحقیق λ_{GBT} روی 0/1 قرار می‌گیرد. برای M_{GBT} ، از 15، یعنی نیمی از فضای مورد نظر استفاده می‌شود بقیه پارامترهای تنظیمی روی مقادیر پیش فرض خود هستند [20] و بذر⁴ (دانه) روی یک ثابت است. جنگل‌های تصادفی توسط بریمن⁵ [22] (2001) معرفی شده‌اند. در این الگوریتم برای هر یک از درختان B_{RAF} در جنگل تصادفی، ابتدا یک زیرمجموعه تصادفی از داده‌های آموزشی اصلی تهیه می‌شود. سپس، یک درخت تصمیم‌گیری اصلاح شده برای این نمونه رشد داده می‌شود، به این ترتیب ویژگی‌های M_{RAF} به صورت تصادفی از p ویژگی بر اساس هر تقسیم انتخاب می‌شوند. درخت به حداکثر عمق J_{RAF} می‌رسد. تولید نهایی، مجموعه‌ای از درختان جنگل تصادفی B_{RAF} است، به طوری که طبقه‌بندی را می‌توان از طریق رای اکثریت انجام داد. نمونه‌گیری فرعی بطور قابل ملاحظه‌ای واریانس درختان (اریب کم) را کاهش می‌دهد و انتخاب تصادفی ویژگی‌ها آنها را مستقل می‌کند. در این الگوریتم سه پارامتر تنظیمی وجود دارد شامل: تعداد درختان B_{RAF} ،

1. Shrinkage parameter
 2. Friedman
 3. Hastie et al
 4. Seed
 5. Breiman

حداکثر عمق J_{RAF} آنها، و تعداد ویژگی‌های انتخاب تصادفی M_{RAF} . در این تحقیق B_{RAF} روی 2000 درخت و حداکثر عمق J_{RAF} در 20 و $\sqrt{p} = M_{RAF}$ انتخاب می‌شود. مشابه الگوریتم‌های قبلی، دانه روی یک تنظیم می‌شود و سایر پارامترها روی مقادیر پیش فرض قرار می‌گیرند. علاوه بر آن در این تحقیق به منظور کاهش خطای یادگیرنده‌های پایه و افزایش صحت پیش‌بینی از مدل ترکیبی ساده نیز استفاده شده است که با استفاده از رابطه زیر محاسبه می‌شود:

$$\mathcal{P}_{t+1|t}^{s,ENS} = \frac{1}{3} \left(\mathcal{P}_{t+1|t}^{s,DNN} + \mathcal{P}_{t+1|t}^{s,GBT} + \mathcal{P}_{t+1|t}^{s,RAF} \right) \quad (3)$$

در مرحله آخر، این مدل‌ها و ترکیب ساده آنها برای ایجاد پیش‌بینی‌های خارج از نمونه روی مجموعه‌های معاملاتی متناظر مورد استفاده قرار می‌گیرند. سهم‌ها بر طبق این پیش‌بینی‌ها رتبه‌بندی شده و معامله می‌شوند. به این صورت که K سهم بالای هر رتبه‌بندی در موقعیت خرید و K سهم پایین آن در موقعیت فروش قرار می‌گیرند.

5- آزمون فرضیه‌های پژوهش

برای ارزیابی آماری مدل‌های طراحی شده معیارهای مختلفی شامل MSE, RMSE, AUC و Gini مدنظر قرار گرفته شده است. که در بین آنها نرخ صحت (AUC) که مهم‌ترین مبنای مقایسه برای استراتژی خنثی نسبت به دلار باید بزرگتر از 50 درصد باشد تا مدل مناسب تلقی شود. در این تحقیق، تمامی مدل‌های طراحی شده دارای AUC بزرگتر از 68 درصد می‌باشند که بسیار جالب توجه می‌باشد. در جدول زیر میانگین معیارهای آماری ارزیابی عملکرد مدل‌ها آورده شده است:

جدول 2 معیارهای آماری ارزیابی عملکرد مدل‌ها

مدل معیار	شبکه‌های عصبی عمیق (DNN)	درخت‌باشیب تقویت شده (GBT)	جنگل‌های تصادفی (RAF)
MSE	0/1972	0/1770	0/1667
RMSE	0/4421	0/4190	0/4188
LogLoss	0/5797	0/5256	0/5236
Mean per-class error	0/3226	0/2932	0/3028
Accuracy	0/6822	0/7689	0/7683
Gini Index	0/3645	0/5377	0/5366

فاکتورهای شاخص جینی (Gini Index) و نرخ صحت (Accuracy) هر قدر بیشتر باشند مناسب‌تر مدل را نشان می‌دهند. از جدول فوق مشخص است که بیشترین مقدار شاخص جینی 0/5377 و بالاترین نرخ صحت 0/7689 است که هر دو متعلق به مدل GBT است. سایر شاخص‌های آماری جدول نشان‌دهنده خطای مدل‌ها می‌باشند در نتیجه هر قدر کمتر باشند مناسب‌تر خواهد بود. کمترین مقدار MSE، LogLoss، RMSE متعلق به مدل RAF است و به این معنی است که در مقایسه با سایر مدل‌ها، تعداد پیش‌بینی‌های صحیح آن بیشتر می‌باشد. در مورد معیار آماری میانگین خطای هر طبقه، مدل GBT بهتر عمل کرده است. بنابراین انتظار می‌رود که با ترکیب این مدل‌ها نتایج بهتری به دست آید.

برای ارزیابی عملکرد پرتفوی‌های متشکل از k سهم ($k = 5, 10, 20$) حاصل از هر یک از مدل‌های شبکه عصبی عمیق، جنگل‌های تصادفی و درخت‌باشیب تقویت شده و همچنین مقایسه عملکرد این مدل‌ها با یکدیگر از چند جهت مورد بررسی قرار گرفته‌اند. این پرتفوی‌ها بر حسب بازده روزانه بدون هزینه معاملات، ارزش در معرض ریسک و ریزش مورد انتظار مورد تحلیل و مقایسه قرار گرفته‌اند. ابتدا پرتفوی‌های متشکل از K سهم بالای رتبه‌بندی و K سهم پایین رتبه‌بندی (مثلاً به ازاء

5, k = 5 سهم بالایی رتبه‌بندی در موقعیت خرید و 5 سهم پایینی رتبه در موقعیت فروش قرار می‌گیرند) از نظر بازده روزانه با هم مقایسه شده‌اند. جدول 3 این نتایج را نشان می‌دهد:

جدول 3 بازده‌های روزانه پرتفوی‌های K سهمی بدون هزینه معاملات برای مدل‌های DNN, GBT, RAF, ENS

میانگین	1396	1395	1394	1393	1392	1391	1390	1389	1388	سال	
3/24	4/75	3/52	2/73	3/94	1/77	2/69	2/85	3/01	3/95	DNN	k = 5
4/20	7/63	5/55	2/25	3/39	7/74	0/44	4/51	4/05	2/49	GBT	
3/72	5/55	2/93	2/87	3/86	4/88	2/76	4/11	4/13	2/36	RAF	
4/24	6/10	5/47	2/66	3/73	5/54	2/53	3/91	4/51	3/62	ENS	
2/52	7/04	2/73	2/16	1/85	0/90	1/65	1/20	1/92	3/26	DNN	k = 10
3/65	6/15	4/28	1/97	2/99	5/93	0/13	4/33	4/03	2/60	GBT	
3/38	5/14	2/24	1/83	3/49	4/78	1/95	4/02	3/76	2/47	RAF	
3/71	5/11	4/06	2/57	2/66	5/32	1/98	4/11	3/81	2/79	ENS	
2/23	3/14	2/52	1/62	1/64	1/94	2/37	1/51	1/67	2/86	DNN	k = 20
3/27	4/58	3/56	1/81	2/67	5/14	0/53	4/42	3/54	2/38	GBT	
2/98	4/45	1/07	1/95	2/79	4/19	1/86	4/02	3/62	2/34	RAF	
2/97	4/35	3/76	1/93	2/17	4/37	1/79	3/84	3/30	1/27	ENS	
0/279	-0/14	-0/12	0/31	-0/20	0/50	0/28	0/67	0/65	0/32	بازده شاخص	

* تمامی مقادیر جدول فوق برحسب درصد می‌باشند.

همانطور که در جدول بالا مشاهده می‌شود برای $k = 5$ بالاترین میانگین بازده روزانه طی دوره مطالعه 4/24 درصد در هر روز برای ENS می‌باشد و کمترین میزان بازده 3/24 درصد در هر روز است که متعلق به مدل DNN می‌باشد. برای $k = 10$ بالاترین بازده 3/71 درصد در هر روز بدون هزینه معاملات است که مربوط به مدل ترکیبی ساده (ENS) می‌باشد. برای آنکه یک مدل ترکیبی به صحت بالاتری از یادگیرنده‌های پایه دست یابد: اول، یادگیرنده‌های پایه نیاز دارند به خوبی متنوع شوند و دوم آنکه، آنها نیازمند آن هستند که درست و صحیح باشند. منظور از متنوع‌سازی آن است که خطای مدل‌ها همبستگی کمتری نشان دهد. می‌توان ادعا کرد که همه یادگیرنده‌ها درست و صحیح هستند چون صحت جهت¹ آنها بیشتر از 68 درصد است. ترکیب سه نرخ صحت یادگیرنده‌های پایه را متنوع می‌سازد که منجر به ایجاد نتایج برتر در شواهد تجربی می‌گردد. برای $k = 20$ بطور میانگین بازده روزانه طی دوره تحقیق برای مدل GBT برابر با 3/27 درصد در هر روز بدون هزینه معاملات می‌باشد. برای مدل ENS بازده روزانه برابر با 2/97 درصد و 2/98 درصد در هر روز برای مدل RAF است که می‌توان گفت تفاوت قابل توجهی در بازده‌های این دو مدل وجود ندارد و تقریباً یکسانند. صرف‌نظر از تعداد سهام موجود در سبد و فقط با توجه به میزان متوسط بازده روزانه چنین نتیجه‌گیری می‌شود که بالاترین بازده 4/24 درصد برای هر روز و کمترین میزان بازده 2/23 درصد می‌باشد. با توجه به نتایج تحقیق که در جدول بالا خلاصه آورده شده ملاحظه می‌شود که میانگین بازده‌ها برای هر یک از مدل‌ها با افزایش تعداد سهام در سبد تقریباً کاهش یافته است. مثلاً بازده مدل DNN برای $k = 5$ ، 3/24 درصد و برای $k = 10$ مقدار بازده 2/47 درصد و برای $k = 20$ میزان بازده برابر با 2/23 درصد است. برای سایر مدل‌ها نیز همین قضیه صادق است. آنچه از جدول بالا نتیجه‌گیری می‌شود آن است که تمامی مدل‌های طراحی شده موفق عمل کرده‌اند و سبدهای تشکیل شده براساس پیش‌بینی مدل‌ها بازدهی فراتر از بازده شاخص داشته‌اند.

به منظور انجام تحلیل بیشتر و آزمون فرضیات تحقیق، بازده سبدهای حاصل از مدل‌های برگرفته از الگوریتم‌های یادگیری ماشین با متوسط بازده شاخص مقایسه

1. Directional accuracy

شده‌اند. برای مقایسه میانگین‌های دو جامعه بسته به نوع جامعه (مستقل یا وابسته)، نوع متغیرها (کمی یا کیفی) و وضعیت نرمالیتی آزمون‌های مختلفی وجود دارد. ابتدا نرمالیتی داده‌ها آزمون شده است. برای ارزیابی نرمالیتی از آزمون شاپیرو-ویلک¹ که در نرم‌افزار R اجرا می‌شود استفاده شده است. فرضیات آماری نرمالیتی داده‌ها بصورت زیر بیان می‌شوند:

H_0 : داده‌ها از توزیع نرمال پیروی می‌کنند.

H_1 : داده‌ها از توزیع نرمال پیروی نمی‌کنند.

اگر سطح معناداری آزمون (p-value) بیشتر از 0/05 باشد، فرض صفر مبنی بر نرمال بودن متغیر با اطمینان 95 درصد رد نخواهد شد. نتایج آزمون شاپیرو-ویلک برای متغیرهای پژوهش در جدول زیر آورده شده است:

جدول 4 نتایج آزمون نرمالیتی (شاپیرو-ویلک)

نتیجه	P-value	مقدار آماره شاپیرو-ویلک	
تأیید	0/1589	0/9882	بازده شاخص کل
تأیید	0/3353	0/9908	بازده‌های مدل DNN
تأیید	0/7962	0/9947	بازده‌های مدل GBT
تأیید	0/7660	0/9945	بازده‌های مدل RAF
تأیید	0/1525	0/9870	بازده‌های مدل ترکیبی ENS

همانطور که در جدول 4 مشاهده می‌شود با توجه به سطح معناداری آزمون شاپیرو-ویلک و اینکه مقادیر آن از 0/05 بیشتر است نتیجه‌گیری می‌شود که متغیرها از توزیع نرمال پیروی می‌کنند و همچنین با توجه به آنکه دو جامعه مستقل هستند و

1. Shapiro-wilk test

متغیرها کمی می‌باشند بنابراین از روش پارامتریک برای آزمون فرضیات استفاده می‌شود. آزمونی که برای مقایسه میانگین‌های دو جامعه مستقل مورد استفاده قرار می‌گیرد آزمون تی¹ می‌باشد.

نظر به آنکه در این تحقیق 4 مدل و برای هر مدل پرتفوی‌های تشکیل شده در دسته‌های 10 سهمی، 20 سهمی و 40 سهمی قرار گرفته‌اند بنابراین می‌توان برای هر مدل یک فرضیه اصلی و 3 فرضیه فرعی به صورت زیر تعریف نمود:

- فرضیات مدل شبکه‌های عصبی عمیق (DNN)

فرضیه اصلی 1- بین بازده پرتفوی حاصل از مدل الگوریتم شبکه‌های عصبی عمیق و بازده شاخص تفاوت معناداری وجود دارد.

فرضیه فرعی 1-1: بین بازده پرتفوی 10 سهمی مدل الگوریتم شبکه‌های عصبی عمیق و بازده شاخص تفاوت معناداری وجود دارد.

فرضیه فرعی 1-2: بین بازده پرتفوی 20 سهمی مدل الگوریتم شبکه‌های عصبی عمیق و بازده شاخص تفاوت معناداری وجود دارد.

فرضیه فرعی 1-3: بین بازده پرتفوی 40 سهمی مدل الگوریتم شبکه‌های عصبی عمیق و بازده شاخص تفاوت معناداری وجود دارد.

- فرضیات مدل درخت با شیب تقویت شده (GBT)

فرضیه اصلی 2- بین بازده پرتفوی مدل حاصل از مدل الگوریتم درخت با شیب تقویت شده و بازده شاخص تفاوت معناداری وجود دارد.

فرضیه فرعی 2-1: بین بازده پرتفوی 10 سهمی مدل الگوریتم درخت با شیب تقویت شده و بازده شاخص تفاوت معناداری وجود دارد.

فرضیه فرعی 2-2: بین بازده پرتفوی 20 سهمی مدل الگوریتم درخت با شیب تقویت شده و بازده شاخص تفاوت معناداری وجود دارد.

فرضیه فرعی 2-3: بین بازده پرتفوی 40 سهمی مدل الگوریتم درخت با شیب تقویت شده و بازده شاخص تفاوت معناداری وجود دارد.

1. t-test

- فرضیات مدل جنگل‌های تصادفی (RAF)

فرضیه اصلی 3- بین بازده پرتفوی حاصل از مدل الگوریتم جنگل‌های تصادفی و بازده شاخص تفاوت معناداری وجود دارد.

فرضیه فرعی 3-1: بین بازده پرتفوی 10 سهمی مدل الگوریتم جنگل‌های تصادفی و بازده شاخص تفاوت معناداری وجود دارد.

فرضیه فرعی 3-2: بین بازده پرتفوی 20 سهمی مدل الگوریتم جنگل‌های تصادفی و بازده شاخص تفاوت معناداری وجود دارد.

فرضیه فرعی 3-3: بین بازده پرتفوی 40 سهمی مدل الگوریتم جنگل‌های تصادفی و بازده شاخص تفاوت معناداری وجود دارد.

- فرضیات مدل ترکیبی موزون (ENS)

فرضیه اصلی 4- بین بازده پرتفوی مدل حاصل از مدل الگوریتم ترکیبی ساده و بازده شاخص تفاوت معناداری وجود دارد.

فرضیه فرعی 4-1: بین بازده پرتفوی 10 سهمی مدل الگوریتم ترکیبی ساده و بازده شاخص تفاوت معناداری وجود دارد.

فرضیه فرعی 4-2: بین بازده پرتفوی 20 سهمی مدل الگوریتم ترکیبی ساده و بازده شاخص تفاوت معناداری وجود دارد.

فرضیه فرعی 4-3: بین بازده پرتفوی 40 سهمی مدل الگوریتم ترکیبی ساده و بازده شاخص تفاوت معناداری وجود دارد.

برای انجام آزمون آماری ابتدا باید فرضیات به صورت آماری تبدیل بیان گردند. این فرضیات به صورت زیر تعریف می‌شوند:

H_0 : بین بازده مدل و بازده بازار تفاوت معناداری وجود ندارد.

H_1 : بین بازده مدل و بازده بازار تفاوت معناداری وجود دارد.

برای انجام آزمون t که در نرم افزار R انجام می‌گیرد سطح اطمینان 95% برای تمامی فرضیات در نظر گرفته شده است. بنابراین چنانچه مقدار آماره t بین $-1/645$ تا $+1/645$ باشد فرض صفر به قوت خود باقی خواهد بود و اگر مقدار آماره آزمون بزرگتر از $1/645$ یا کوچکتر از $-1/645$ باشد فرض صفر به نفع فرض مخالف رد می‌شود.

نتایج آزمون t مبنی بر وجود یا عدم وجود تفاوت معنادار بین میانگین‌های جوامع مورد بررسی در جدول 5 آورده شده است:

جدول 5 نتایج t-test برای ارزیابی وجود یا عدم وجود تفاوت معنادار بین میانگین‌های دو جامعه

نتیجه	میانگین روزانه بازده مدل‌ها	میانگین روزانه بازده شاخص	p-value	مقدار آماره t	فرضیات تحقیق
تأیید	0/0324	0/002796	0/0000022	9/478	فرضیه فرعی 1-1
تأیید	0/0252	0/002796	0/0058830	2/643	فرضیه فرعی 2-1
تأیید	0/0223	0/002796	0/0000021	8/229	فرضیه فرعی 3-1
تأیید	0/0420	0/002796	0/0011651	4/836	فرضیه فرعی 1-2
تأیید	0/0365	0/002796	0/0006960	5/181	فرضیه فرعی 2-2
تأیید	0/0327	0/002796	0/000277	5/807	فرضیه فرعی 3-2
تأیید	0/0372	0/002796	0/0000044	9/272	فرضیه فرعی 1-3
تأیید	0/0338	0/002796	0/0000481	7/157	فرضیه فرعی 2-3
تأیید	0/0298	0/002796	0/000107	6/433	فرضیه فرعی 3-3
تأیید	0/0424	0/002796	0/0000073	9/083	فرضیه فرعی 1-4
تأیید	0/0371	0/002796	0/0000142	8/245	فرضیه فرعی 2-4
تأیید	0/0297	0/002796	0/0000870	6/600	فرضیه فرعی 3-4

همانطور که در جدول فوق مشاهده می‌شود مقدار p-value برای تمامی فرضیات کوچکتر از 0/05 می‌باشد و این نشان‌دهنده آن است که فرض جایگزین مبنی بر وجود تفاوت معنادار بین بازده‌ها تأیید می‌گردد. علاوه بر آن چون در آزمون t در این تحقیق برای تمام فرضیات شاخص کل به عنوان جامعه دوم در نظر گرفته شده که مقدار کمتری از جامعه دیگر داشته آماره t مقداری مثبت پیدا کرده که حاکی از بزرگتر بودن مقدار میانگین بازده پرتفوی‌ها نسبت به میانگین بازار می‌باشد.

6- بررسی اهمیت متغیرها و ریسک پرتفوی‌ها

6-1- اهمیت متغیرها (فضای ویژگی‌ها)

در این تحقیق 31 متغیر پیش‌بینی‌کننده وجود دارد که قدرت پیش‌بینی‌کنندگی همه ویژگی‌ها با هم برابر نیست. علاوه بر آنکه اهمیت نسبی متغیرها در هر یک از الگوریتم‌ها متفاوت از بقیه است در مورد یک الگوریتم مشخص نیز از دوره‌ای به دوره دیگر تغییر می‌کند. به منظور تعیین ترتیب اهمیت متغیرها در هر الگوریتم، تمامی داده‌های آموزش یعنی از سال 1386 تا 1396 برای هر یک از مدل‌ها مورد استفاده قرار گرفته است. بطور کلی می‌توان گفت که متغیرهای R_1, R_2, R_3, R_4, R_5 در همه مدل‌ها از بالاترین درجه اهمیت برخوردارند که همان بازده‌های اخیر می‌باشند. علاوه بر آن می‌توان گفت که بازده‌های مربوط به گذشته در مدل‌های DNN و GBT تاثیر ناچیزی در پیش‌بینی بازده روز آتی سهم دارند اما در مورد مدل RAF تمامی متغیرها تقریباً قابلیت پیش‌بینی قیمت روز آتی سهم را دارا می‌باشند هرچند که از اطلاعات 20 روز اخیر سهم کمتر است.

6-2- ریسک مدل‌ها

برای ارزیابی ریسک پرتفوی‌ها در این تحقیق از دو معیار ارزش در معرض ریسک (1VaR) و ریزش مورد انتظار (2ES) استفاده شده است. از رویکرد واریانس-کواریانس که رویکردی پارامتریک می‌باشد در سطح اطمینان 95% برای محاسبه ریسک (VaR, ES) استفاده شده است. میانگین معیارهای ریسک برای پرتفوی‌های

1. Value at risk
2. Expected shortfall

برای مدل‌های مختلف الگوریتم یادگیری ماشین در جدول زیر آورده شده است: $K = 5, 10, 20$

جدول 6 مقادیر انحراف معیار، ارزش در معرض ریسک و ریزش مورد انتظار و نسبت بازده به انحراف معیار پرتفوی‌ها

نسبت بازده به انحراف معیار	ریزش مورد انتظار (ES)	ارزش در معرض ریسک (VaR)	انحراف معیار (σ)	مدل	تعداد سهام در پرتفوی
0/5870	-0/1142	-0/0911	0/0552	DNN	K = 5
0/6192	-0/1426	-0/1143	0/0678	GBT	
0/7522	-0/1023	-0/0816	0/0494	RAF	
0/7736	-0/1131	-0/0901	0/0548	ENS	
0/6605	-0/0792	-0/0632	0/0381	DNN	K = 10
0/7704	-0/0987	-0/0789	0/0473	GBT	
0/8955	-0/0783	-0/0625	0/0377	RAF	
0/9224	-0/0841	-0/0672	0/0402	ENS	
0/8297	-0/0557	-0/0445	0/0268	DNN	K = 20
1/044	-0/0664	-0/0533	0/0313	GBT	
1/072	-0/0586	-0/0470	0/0278	RAF	
0/9938	-0/0636	-0/0511	0/0298	ENS	

بیشترین مقدار ارزش در معرض ریسک در بین پرتفوی‌های 5 سهمی -0/1143 است که مربوط به پرتفوی مبتنی بر درخت با شیب تقویت شده می‌باشد و کمترین آن -0/0816 است که مربوط به مدل جنگل‌های تصادفی است. در بین سبدهای 20

سهمی بیشترین مقدار ارزش در معرض ریسک را مدل DNN و کمترین مقدار را ENS داراست. در مورد پرتفوی‌های 40 سهمی همانطور که در جدول فوق ملاحظه می‌شود بالاترین مقدار ارزش در معرض ریسک 0/0533- و متعلق به مدل GBT و کمترین مقدار 0/0445- و مربوط به مدل DNN است. نتیجه‌گیری می‌شود که مدل GBT صرفنظر از تعداد سهام موجود در سبد بالاترین میزان ارزش در معرض ریسک و مدل DNN هم کمترین مقدار را در بین سایر مدل‌های طراحی شده داراست. در مورد معیار ریسک ریزش مورد انتظار نیز شرایط مشابه ارزش در معرض ریسک است. بیشترین مقدار ES، 0/1426- برای $k = 5$ سهمی مدل GBT است و کمترین میزان ریزش مورد انتظار 0/0557- است برای $k = 20$ که متعلق به مدل DNN می‌باشد. بطور کلی می‌توان گفت که برای هر یک از مدل‌ها با افزایش تعداد سهام در سبد مقدار ریسک (VaR, ES) بطور چشمگیری کاهش می‌یابد که منطبق با تئوری کلاسیک پرتفوی و تنوع‌سازی به منظور کاهش ریسک است. به منظور انجام تحلیل بیشتر ریسک سبدها، از نسبت بازده به انحراف معیار استفاده شده است که معیاری برای بازده تعدیل شده در برابر ریسک می‌باشد. بیشترین مقدار آن 1/072 است که برای RAF و $k = 20$ می‌باشد و کمترین مقدار هم 0/05870 است که برای DNN با $k = 5$ می‌باشد.

7- نتیجه‌گیری

طراحی مدل آربیتراژ آماری نیازمند بکارگیری روش‌های پیچیده ریاضی و کامپیوتری است. تحقیق حاضر به منظور طراحی مدل آربیتراژ آماری از الگوریتم‌های یادگیری ماشین و به طور ویژه شبکه‌های عصبی عمیق، درخت با شیب تقویت شده، جنگل‌های تصادفی و مدل ترکیبی بهره گرفته است. بررسی عملکرد پرتفوی‌های حاصل از مدل‌های مستخرج نشان می‌دهد که ترکیب پیش‌بینی‌های یادگیرنده‌های پایه - شبکه‌های عصبی عمیق، درخت‌های کم‌عمق تقویت شده و درخت‌های مستقل با عمق زیاد- در یک مدل ترکیبی با وزن‌های برابر (ENS) عملکردی بالاتر از شبکه‌های عصبی عمیق، جنگل‌های تصادفی و درخت با شیب تقویت شده دارد. درخت‌های کم‌عمق تقویت شده (GBT) در جایگاه دوم و با اختلاف

کمی از مدل ترکیبی از نظر عملکردی قرار می‌گیرد. نتایج ارزیابی ریسک پرتفوی‌ها نشان داد که کمترین مقدار ریسک دنباله (CVaR) مربوط به مدل DNN می‌باشد. در مقایسه با تحقیق انجام شده توسط کرائوس و همکاران (2017) که همه شرکت‌های S&P500 را بررسی کردند می‌توان گفت که تفاوت چشمگیری در مقدار بازده‌های گزارش شده وجود دارد. بیشترین مقدار بازده در تحقیق آنها 0/45 درصد در هر روز می‌باشد در حالیکه با تغییر پارامترها و بهینه‌یابی آنها، در بورس اوراق بهادار ایران می‌توان بازده 4/24 درصد در هر روز با استفاده از مدل‌های طراحی شده به دست آورد. بطور کلی بازده‌های آربیتراژ آماری با استفاده از الگوریتم‌های یادگیری ماشین در ایران چندین برابر بازده‌های گزارش شده در S&P500 می‌باشد که نشان از اختلاف بسیار زیاد در سطح کارایی اطلاعاتی این بازارها دارد زیرا کارایی اطلاعاتی ضعیف‌تر می‌تواند منجر به ایجاد فرصت‌های آربیتراژی بیشتر شود. مشابه با تحقیق کرائوس و همکاران، بیشترین مقدار بازده در هر دو بازار برای مدل ENS (متشکل از یک شبکه عصبی عمیق، یک درخت با شیب تقویت شده و یک جنگل تصادفی) می‌باشد که می‌تواند تأییدی بر قدرت مدل‌های ترکیبی باشد که توسط دیتریچ (2000)، تیمرمن (2006) و جنر و همکاران (2013) [23 و 24 و 25] مطرح شده و به اثبات رسیده است. همچنین به منظور دستیابی به مدل با بالاترین نرخ صحت، در این تحقیق تغییرات زیادی در پارامترها ایجاد شد و پیش‌بینی‌ها مورد بررسی قرار گرفت. مثلاً با افزایش تعداد درختان در مدل RAF به 2000 و همچنین در مدل GBM به 200 درخت نتایج بهتری در بازار ایران به دست آمد. اما می‌توان گفت که در نهایت مدل‌های برتر با اعمال تغییرات مختصر بر تنظیمات کرائوس و همکاران به دست آمدند که این امر می‌تواند قدرت بالای مدل‌های یادگیری ماشین و حساسیت کم آنها به تغییر در ورودی‌های مدل را نشان دهد. نظر به اینکه تاکنون تحقیقی مشابه پژوهش حاضر در حوزه آربیتراژ آماری در ایران انجام نشده است می‌توان آن را تحقیقی پیشگام دانست که دستاوردهای قابل توجهی برای سرمایه‌گذاران و پژوهشگران دانشگاهی دارد زیرا ضمن ارائه نتایج نویدبخش با برداشتن موانع اجرایی، زمینه انجام مطالعات بیشتر در این حوزه را فراهم ساخته است. از جمله موضوعات جذاب برای تحقیقات آتی می‌توان به این موارد اشاره کرد؛ با تنظیم و بهینه‌سازی هایپارامترها این امکان وجود دارد که بتوان عملکرد سایر مدل‌ها را نیز بهبود

بخشید که خود می‌تواند موضوعی برای تحقیقات آتی باشد. برای ساخت مدل ترکیبی متنوع تر می‌توان یادگیرنده‌های بیشتری را به مدل ترکیبی اضافه نمود و یا از سایر روش‌های یادگیری گروهی (ترکیب برمبنای عملکرد و ترکیب برمبنای رتبه) استفاده نمود که می‌تواند موضوعی برای تحقیقات بیشتر باشد. پتانسیل کاهش ریسک پرتفوی هنوز وجود دارد. بعنوان مثال می‌توان ریسک سبد را با بهینه‌سازی براساس ES کاهش داد که خود موضوعی برای تحقیقات آتی می‌باشد. علاوه بر آن، تحلیل اهمیت متغیرها نشان داد که تقریباً 5 روز معاملاتی قبل ارزش تشریح‌کنندگی بالاتری برای بازده روز بعد را دارند بنابراین تحلیل‌ها حاکی از آنند که ممکن است الگوهای سودآوری برمبنای بازده‌ها و داده‌های اخیر روزانه وجود داشته باشد (مثلاً به جای استفاده از بازده‌های 240 روز می‌توان از بازده‌های 10 روز قبل که ارزش تشریح‌کنندگی بالاتری برای بازده روز بعد دارند استفاده نمود) که کشف نشده‌اند و می‌تواند موضوعی برای تحقیق بیشتر باشد.

8- منابع

- [1] GoodarziM, YakidehK, MahfooziG (1395). "Stock portfolio optimization by integrating data envelopment analysis and Horwitz decision making", *Medern research in decision making*, Volume 1, No. 4.(in persian)
- [2] ZamaniA, KhanzadiM, AmeliM, SarhadiM (1396)." The Framework for Using Risk Management in Fuzzy Environment for Implementation of Engineering Value Development Projects". *Management research in Iran*, Volume 21, No. 3.(in persian)
- [3] TehraniR, NoorbakhshA (1390). "Investment Management", *Publisher: knowledge look*. (In Persian)
- [4] ForooshbastaniA, GhasemiA (1391). "Random control approach to optimize paired trading", *3th conference of financial mathematics and applications*, *Semnan University*. (In Persian)
- [5] Avellaneda, M, Lee, J (2008). Statistical Arbitrage in the U.S. *Equities Market*. *Quantitative Finance*, 10(7), 761–782.

- [6] AhmadzahehA, YavariK, SalehabadiA, EsiayitafreshiM (1393). "Statistical Arbitrage test in Tehran stock exchange", *Quarterly journal of Economic policies and researches*, No. 70. (In Persian)
- [7] Krauss, C, Anh Do, Xuan, H, N. (2017). Deep neural networks, gradient-boosted trees, random forests: Statistical arbitrage on the S&P 500. *European Journal of Operational Research* 689–702. Elsevier.
- [8] AbbasianA, ZoolfaghariM (1392). "Dynamic Analysis of weak Level Efficiency in Tehran Stock Exchange by Kalman Filter", *Quarterly journal of Economic policies and researches*. No.65, pp. 231-254. (in persian)
- [9] RasekhiS, KhanalipoorA (1388). "Empirical analysis of fluctuations and stock market efficiency (Case study: Tehran stock exchange)". *Quarterly journal of Iranian Economic Research*, pp. 29-75.(in persian)
- [10] Hastie, T., Tibshirani, R., & Friedman, J. H. (2009). The elements of statistical learning: Data mining, inference, and prediction. *Springer series in statistics* (2nd). New York: Springer.
- [11] AfsarA, HalilF (1396). "Stock portfolio optimization by the combined approach of Thecnical analysis and data mining. *Medern research in decision making*, Volume 2, No. 2.(in persian)
- [12] AsgariM, AbooZ (1391). "Evaluating the Effectiveness of paired Trading Strategy on Coin Future Contracts Using Combination of co-integration and Random Approaches". *3th conference of financial mathematics and applications. Semnan University*. (in persian)
- [13] JalilianG, AsgriM (1394). "Design and implementation of pairs trading strategy software for using in the capital market". *Financial management strategy*, No. 11, pp.111-127. (in persian)
- [14] [14] PakizehK, HabibiS (1395). "Comparison of Profitability of Paired trading Strategy between different classes of assets". *Asset management and financing*, Volume 5, No. 4, pp. 69-88. (in persian)
- [15] Takeuchi, L., & Lee, Y.-Y. A. (2013). "Applying deeplearningtoenhancemomentum trading strategies in stocks". *Stanford University. Working paper*.

- [16] Moritz, B., & Zimmermann, T. (2014). "Deep conditional portfolio sorts: The relation between past and future stock returns". *Working paper, Ludwig Maximilian University Munich and Harvard University*.
- [17] Dixon, M, Klabjan, D, & Bang, J. H. (2015). "Implementing deep neural networks for financial market prediction on the Intel Xeon Phi". *In Proceedings of the eighth workshop on high performance computational finance* (pp. 1–6 Elsevier.
- [18] ValipoorKH, SafiieA, AkbarzadehZ, GhasemniaN (1395). "Assessing and predicting sustainable production using the approach Multi-Degree Fuzzy Compound and Artificial Neural Network". *Management research in Iran*, Volume 20, No. 1.(in persian)
- [19] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R (2014). Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15(1), 1929–1958.
- [20] H2O (2016). H2O documentation. <http://h2o-release.s3.amazonaws.com/h2o/rel-tibshirani/3/docs-website/h2o-docs/index.html> and <http://docs.h2o.ai>.
- [21] Friedman, J. H. (2002). Stochastic gradient boosting. *Computational Statistics & Data Analysis*, 38(4), 367–378.
- [22] Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.
- [23] Dietterich, T. G. (2000). Ensemble methods in machine learning. *In Multiple classifier systems* (pp. 1–15). Springer.
- [24] Timmermann, A. (2006). Chapter 4 forecast combinations. In G. Elliott, C. W. J. Granger, & A. Timmermann (Eds.), *Handbook of economic forecasting: vol. 1* (pp. 135–196). Elsevier. doi:10.1016/S1574-0706(05)01004-9.
- [25] Genre, V., Kenny, G., Meyler, A., & Timmermann, A. (2013). Combining expert forecasts: Can anything beat the simple average? *International Journal of Forecasting*.–121-108(1) 29.