

مقایسه کارآیی مدل‌های رگرسیون با رویکرد تحلیل مؤلفه‌های اصلی (PCA) و شبکه‌های عصبی مصنوعی در پیش‌بینی بازده غیرعادی

رضا راعی^۱، مهدی بستان‌آراء^{۲*}

۱- استاد دانشکده مدیریت دانشگاه تهران، تهران، ایران

raei@ut.ac.ir

۲- دانشجوی دکتری رشته مدیریت مالی، دانشگاه تهران، تهران، ایران

bostanara@ut.ac.ir

چکیده

بسیاری از پژوهش‌ها در علم مالی بر پیش‌بینی دقیق بازده شرکت‌ها با در نظر داشتن ریسک سرمایه‌گذاری در سهام آن‌ها تمرکز داشته‌اند. هدف این پژوهش، بررسی امکان توضیح بازده غیرعادی (تفاوت بازده مورد انتظار حاصل از مدل قیمت‌گذاری دارایی‌های سرمایه‌ای و بازده واقعی) با استفاده از نسبت‌های مالی و انتخاب ابزار بهتر برای پیش‌بینی آن از بین دو مدل رگرسیون چندگانه با رویکرد تحلیل مؤلفه‌های اصلی (PCA) و شبکه‌های عصبی مصنوعی (ANN) است. بر این اساس توانایی مدل شبکه‌های عصبی مصنوعی پیش‌خور با الگوریتم پس‌انتشار خطا (BPN) در پیش‌بینی برون‌نمونه‌ای بازده غیرعادی سهام مورد معامله در بورس اوراق بهادار تهران در سال‌های ۱۳۸۴ تا ۱۳۹۱ به طور معناداری بیشتر از توانایی رگرسیون خطی با رویکرد تحلیل مؤلفه‌های اصلی بوده است.

واژه‌های کلیدی: بازده غیرعادی سهام، شبکه‌های عصبی مصنوعی، رگرسیون خطی با تحلیل مؤلفه‌های اصلی (PCA)، پیش‌بینی برون‌نمونه‌ای.

مقدمه

می‌شوند. همان‌طور که در ادامه شرح داده خواهد شد استفاده از تحلیل مؤلفه‌های اصلی^۵ از دیگر زمینه‌های جدیدی است که در قالب این پژوهش در بازار سرمایه ایران بررسی می‌شود.

مبانی نظری

در زمینه پیش‌بینی بازده سهام، دو روش اصلی مورد استفاده در پژوهش‌های پیشین روش‌های رگرسیون حداقل مربعات معمولی و رگرسیون لجیت هستند. او و پنمن (۱۹۸۹) به وجود معنادار بازده‌های غیرعادی حاصل از استراتژی‌های سرمایه‌گذاری خاصی که بر پیش‌بینی علامت «سود هر سهم پیش‌بینی نشده» بر اساس اطلاعات صورت‌های مالی تمرکز داشتند، پی بردند. در ادامه، استراتژی سرمایه‌گذاری بر پایه اتخاذ موضع خرید در سهامی که بیشترین بازده غیرعادی مثبت برایشان پیش‌بینی می‌شد و اتخاذ موضع فروش استقراضی در سهامی با بیشترین احتمال پیش‌بینی شده بازده غیرعادی منفی، بنا نهاده شد؛ که نهایتاً به بازده سرمایه‌گذاری ۸/۳ درصد برای دوره سرمایه‌گذاری ۱۲ ماهه و ۱۴/۵ درصد برای دوره ۲۴ ماهه، بیشتر از بازده بازار در سال‌های ۱۹۷۳ تا ۱۹۸۳ منجر شد. بر این اساس می‌توان نتیجه گرفت که «صورت‌های مالی منعکس‌کننده اطلاعاتی هستند که لزوماً در قیمت‌های پیشین منعکس نیستند». این مطالعه بر این فرض کلی بنا نهاده شده که قیمت بازار معیاری کافی برای تعیین ارزش شرکت‌هاست و بنابراین معیاری کافی برای سنجش میزان «محتوای اطلاعاتی»^۶ صورت‌های مالی محسوب می‌شود [۳۱].

هالتاوزن و لارکر (۱۹۹۲) به امکان ایجاد یک استراتژی سرمایه‌گذاری سودآور به وسیله پیش‌بینی

پیش‌بینی دقیق بازده شرکت‌ها با در نظر داشتن ریسک سرمایه‌گذاری در سهام آن‌ها هدف نهایی بسیاری از تلاش‌ها در علم مالی است، به عنوان مثال «مدل قیمت‌گذاری دارایی‌های سرمایه‌ای»^۱ با استفاده از رابطه بین نوسان‌های بازده دارایی‌ها و نوسان‌های بازده بازار، بازده مورد انتظار^۲ از آن دارایی را تبیین می‌نماید. بر این اساس، دسته‌ای از پژوهشگران با مشاهده رواج گسترده این مدل و تفاوتی که بین بازده مورد انتظار حاصل از آن و بازده محقق شده وجود دارد، در صدد تبیین این فاصله برآمده‌اند. از سوی دیگر، استفاده از اطلاعات نسبت‌های مالی برای تحلیل وضعیت شرکت‌ها و بازده آتی آن‌ها همواره زمینه‌ای تخصصی و در حال گسترش بوده است. در این راستا، این پژوهش در ادامه پژوهش‌های انجام شده در این دو حوزه، سعی در یافتن مدلی دقیق‌تر در این خصوص دارد.

هدف این پژوهش، در گام اول سنجش این مسأله است که آیا بازده مورد انتظار حاصل از مدل قیمت‌گذاری دارایی‌های سرمایه‌ای، برابر با بازده آتی واقعی هست یا خیر؛ و اگر نیست آیا می‌توان با استفاده از نسبت‌های مالی این فاصله که «بازده غیرعادی»^۳ نامیده می‌شود را توضیح داد.

در این راستا، رابطه بین نسبت‌های مالی و بازده غیرعادی سهام یک بار برای ایجاد مدل رگرسیون و یک بار برای به دست آوردن یک شبکه عصبی مصنوعی استفاده می‌شود، سپس توان پیش‌بینی برون‌نمونه‌ای^۴ مدل رگرسیون خطی و شبکه عصبی به دست آمده برای دسته دیگری از اطلاعات مقایسه

1. Capital Assets Pricing Model
2. Expected Return
3. Abnormal Return
4. Out-of-Sample Forecasting

جنس بازده محقق شده است، نه بازده مورد انتظار. بنا بر مدل قیمت‌گذاری دارایی‌های سرمایه‌ای، از دو دارایی با بتای برابر، بازده برابری انتظار می‌رود، اما بدیهی است که بازده‌های محقق شده دو دارایی می‌توانند با هم متفاوت باشند. در این مطالعه، وجود صرف ریسک‌هایی که با بتا توضیح داده نشده باشند، آزمون شده‌اند. در واقع، از آنجایی که بر اساس این مدل، بتای سبد دارایی بازار برابر با یک است، می‌توان تفاوت بازده سبد دارایی بازار با سبد دارایی دیگر با بتایی نزدیک به یک را بازده غیرعادی دانست که می‌تواند در دوره‌های زمانی مختلف مثبت یا منفی باشد و در صورت برقراری صد درصدی مدل قیمت‌گذاری دارایی‌های سرمایه‌ای باید؛ صرف نظر از روش انتخاب سبد دارایی مورد نظر، به سمت صفر میل کند. بر این اساس، از سال‌های ۱۹۶۲ تا ۱۹۷۵، اطلاعات قیمت و بازده شرکت‌هایی که اطلاعات آن‌ها در دسترس پژوهشگر بوده است (از ۷۰۰ شرکت در آغاز، تا حدود ۱۲۰۰ شرکت در انتها) استفاده شده‌اند. ابتدا شرکت‌های مورد نظر در هر سال، بر اساس اندازه رتبه‌بندی شده‌اند. سپس پژوهشگر شرکت‌های موجود در هر طبقه را یک سبد دارایی در نظر گرفته و با در دست داشتن بازده هر شرکت و بازده بازار در طول دوره یک‌ساله گذشته بتای هر شرکت را محاسبه کرده است. طبق محاسبات به عمل آمده، بتای همه سبدهای دارایی مذکور حدوداً برابر با یک بوده است. در سال اول (اولین سال پس از محاسبه بتا) بازده سبد دارایی متشکل از کوچک‌ترین شرکت‌ها بیست درصد از بازده سبد دارایی متشکل از بزرگ‌ترین شرکت‌ها، بیشتر بوده است. این رابطه برای دومین سال پس از

مستقیم علامت بازده مازاد (با سه سنج مختلف) در یک سال آتی با استفاده از نسبت‌های مالی گوناگون پی بردند. این پژوهش، در پاسخ به او و پنمن (۱۹۸۹) بر این رویکرد بنا نهاده شده است که «از آنجا که میزان موفقیت آمیز بودن یک استراتژی معاملاتی، به وسیله میزان بازده مازاد آن قضاوت می‌شود، منطقی است که به جای پیش‌بینی درآمد هر سهم پیش‌بینی نشده، مستقیماً همین معیار [یعنی بازه مازاد] پیش‌بینی شود؛ به ویژه که بنا بر پژوهش‌های پیشین، درآمد هر سهم پیش‌بینی نشده، همبستگی ضعیفی با بازده دارد». بر این اساس، در دوره ۱۹۷۸ تا ۱۹۸۸ میزان بازده مازاد حاصل از استراتژی معاملاتی به دست آمده سالانه بین ۴/۳ درصد تا ۹/۵ درصد؛ بر حسب سال مورد بررسی، سنج مورد استفاده برای بازده مازاد و اوزان مورد استفاده برای تشکیل سبد سرمایه، متفاوت بوده است [۲۱].

رینگانم (۱۹۸۱) با استفاده از بررسی بازده غیرعادی به آزمون مدل قیمت‌گذاری دارایی‌های سرمایه‌ای پرداخته است. بر این اساس، چنان چه امید ریاضی بازده غیرعادی را محاسبه کنیم، خواهیم داشت:

(۱)

$$E(AR_i) = E[E(\bar{R}_i) - R_i] = E(R_i) - E(R_i) = 0$$

به عبارت دیگر، در بلندمدت بازده غیرعادی سهام به طور میانگین در حوالی بازده مورد انتظار قرار می‌گیرد و به همین دلیل میانگین بازده غیرعادی برابر با صفر بوده، قابل توضیح نیست. اما در اصل این رابطه صحیح نیست، زیرا بازده مورد انتظار از دارایی مورد انتظار (\bar{R}_i) دربرگیرنده تمام عوامل برای تعیین بازده دارایی در آینده نیست و اصلاً به همین دلیل است که به آن بازده مورد انتظار خطاب می‌شود. از سوی دیگر، میانگین بازده واقعی سهام در طول دوره ($E(R_i)$) از

تشکیل بتا، و برای تمام سال‌های بعد برقرار بوده است^۱ [۳۳].

اوکانر (۱۹۷۳)، وانسلی و همکاران (۱۹۸۳) و رینگانم (۱۹۸۸) نیز به بررسی امکان کسب بازده مازاد با استفاده از نسبت‌های مالی پرداخته‌اند [۲۸، ۳۸، ۳۴]. همچنین، در بین مطالعات داخلی در این زمینه می‌توان به پژوهش‌های شجر (۱۳۸۸) با بررسی رابطه بین برخی متغیرهای مالی بنیادی و بازده غیرعادی سهام و ارایه مدلی برای پیش‌بینی بازده غیرعادی سهام، سرابندی (۱۳۸۹) در خصوص استفاده از متغیرهای سود هر سهم پیش‌بینی شده، نسبت قیمت به سود هر سهم (P/E)، نسبت گردش حجم معاملات و معاملات عمده برای توضیح بازده مازاد سهام در بورس اوراق بهادار تهران و دستگیر و یوسفی گورتی (۱۳۹۳) در تأیید تأثیر افزایش سود یا زیان شناسایی نشده ناشی از تورم، در افزایش جریان‌های نقد آتی حاصل از فروش دارایی‌ها و در نتیجه کاهش جریان‌های نقد عملیاتی آینده و بازده غیرعادی حاصل از سبدهای سرمایه‌گذاری طبقه‌بندی شده اشاره کرد [۲، ۳، ۴].

پیشینه پژوهش

در زمینه مقایسه توان پیش‌بینی الگوریتم شبکه‌های عصبی مصنوعی با دیگر روش‌ها، اکثر پژوهش‌های پیشین حاکی از برتری شبکه‌های عصبی مصنوعی بر تکنیک‌های پیش‌بینی متداول همچون رگرسیون حداقل

مربعات معمولی، رگرسیون لجیت و تحلیل جداکننده^۲ هستند. ریفتز و همکاران (۱۹۹۳) در حوزه رتبه‌بندی سهام به مقایسه برآزش حاصل از شبکه‌های عصبی مصنوعی با رگرسیون چندگانه پرداخته‌اند و کارآیی بیشتر را برای شبکه‌های عصبی مصنوعی ذکر کرده‌اند [۳۲]. همچنین کوتز و فنت (۱۹۹۳) به پیش‌بینی درماندگی مالی^۳ با استفاده از الگوریتم همبستگی آبخاری^۴ و مقایسه پیش‌بینی تحلیل جداکننده با الگوریتم شبکه‌های عصبی مصنوعی پرداخته‌اند. نتیجه این مطالعه حاکی از برتری شبکه‌های عصبی مصنوعی در نمونه‌های متشکل از درصدی بالا از شرکت‌های دچار درماندگی مالی و عدم برقراری این برتری در نمونه‌هایی با سهم برابر برای هر یک از دو دسته، بوده است [۱۹].

آلسن و ماسمن (۲۰۰۳) امکان پیش‌بینی بازده یک سال آتی سهام ۲۳۵۲ شرکت مورد معامله در بازار سهام کانادا توسط روش‌های رگرسیون حداقل مربعات معمولی، رگرسیون لجیت و شبکه‌های عصبی مصنوعی را مقایسه کرده‌اند. بر اساس نتایج این مطالعه، الگوریتم شبکه‌های عصبی پس‌انتشار خطا که روابط بین متغیرهای ورودی و خروجی را غیر خطی در نظر می‌گیرد، چه در تخمین نقطه‌ای و چه در تفکیک شرکت‌ها به دو دسته پربازده و کم‌بازده بهتر از رگرسیون عمل می‌کند. این برتری به وسیله ایجاد استراتژی‌های معاملاتی و کسب سود بالاتر بر اساس پیش‌بینی‌های حاصل از هر یک از روش‌های مذکور قابل‌نشان‌دادن است [۳۰]. در پژوهش دیگری، کاو و همکاران (۲۰۱۱) به مقایسه پیش‌بینی‌های حاصل از مدل‌های قیمت‌گذاری دارایی‌های سرمایه‌ای و

۱. شایان ذکر است که مقدار بتا برای همه سبدهای دارایی کاملاً برابر نبوده است، بلکه برای سبد دارایی شرکت‌های بزرگ کمی کمتر از یک و برای سبد دارایی شرکت‌های کوچک، کمی بیشتر از یک بوده است. اما این تفاوت در بتا نمی‌توانسته دلیلی برای تفاوت در بازدهی باشد، زیرا برای این که این مقدار تفاوت در بتا، بتواند این مقدار تفاوت در بازده را ایجاد کند، باید نرخ بازده بدون ریسک ۱۱۰ درصد بوده باشد!

2. Discriminant Analysis

3. Financial Distress

4. Cascade Correlation Algorithm

- پیش‌بینی سلامت مالی: سنت جان و بالا کریشن (۲۰۰۰) و مخاطب رفیعی و همکاران (۲۰۱۱) [۳۱، ۳۵].
- پیش‌بینی ورشکستگی: لی و چویی (۲۰۱۳) [۲۴].
- امتیازبندی اعتباری: وست (۲۰۰۰) و لانگ و رودیز (۲۰۰۰) [۲۳، ۳۹].
- ارزیابی ریسک: لونگ و همکاران (۲۰۰۰) [۲۵].
- طبقه‌بندی روند قیمت سهام: کاو و پری (۲۰۰۹) و مصطفی (۲۰۱۰) [۱۵، ۲۷].
- ریسک اعتباری: آنجلینی و همکاران (۲۰۰۸) [۱۰].

برخی از مطالعات احتمال بزرگ‌نمایی کارآیی شبکه‌های عصبی مصنوعی را مطرح کرده‌اند و کارآیی استراتژی‌های معاملاتی مبتنی بر الگوریتم شبکه‌های عصبی مصنوعی را از برخی از ساده‌ترین استراتژی‌ها نظیر انتخاب تصادفی سهام، یا خرید و نگهداری سهم هم کمتر دانسته‌اند. برای مثال، کالن و همکاران (۱۹۹۶)، از شبکه‌های عصبی مصنوعی برای پیش‌بینی درآمد حسابداری نمونه‌ای شامل ۲۹۶ شرکت در بورس سهام نیویورک بهره برده‌اند. بر این اساس، میزان خطا در پیش‌بینی مدل شبکه عصبی مصنوعی به طور معناداری از پیش‌بینی مدل‌های خطی سری زمانی پارسیمونس^۱ براون-روزلف^۲ و گریفین-واتس^۳ بیشتر بوده است. از این رو می‌توان الگوریتم شبکه‌های عصبی مصنوعی را «وابسته به چارچوب»^۴ دانست که الزاماً برتر از مدل‌های خطی سری زمانی نیست؛ حتی زمانی که اطلاعات حاوی روابط غیر خطی باشند [۱۴].

در خصوص پژوهش‌های پیشین انجام شده در بازار سرمایه ایران می‌توان به پژوهش فامیلیان و یزدانی

سه‌عاملی فاما-فرنچ در صورت استفاده از مدل‌های رگرسیون خطی معمولی در قیاس با زمانی که از شبکه‌های عصبی مصنوعی (با همان داده‌ها) استفاده شود؛ پرداخته‌اند و در هر دو حالت بر برتری روش دوم صحنه گذاشته‌اند [۱۶]. بنا بر پژوهش سورشکومار و الانگو (۲۰۱۲) شبکه‌های عصبی پیش‌خور با الگوریتم پس‌انتشار خطا توان پیش‌بینی برون‌نمونه‌ای و دورون‌نمونه‌ای بیشتری در مقایسه با دیگر شبکه‌های عصبی مصنوعی در پیش‌بینی قیمت سهام داشته‌اند [۳۶]. در پژوهش اولیویرا و همکاران (۲۰۱۳) ضمن استفاده از دامنه گسترده‌ای از اطلاعات مورد استفاده در تحلیل‌های بنیادی و تکنیکال برای توسعه شبکه عصبی مصنوعی، به جستجو در خصوص مناسب‌ترین دامنه زمانی یا اصطلاحاً «پنجره» برای افزایش توانایی پیش‌بینی قیمت سهام پرداخته شده است [۲۹]. همچنین در پژوهش باسو و آشوود (۲۰۱۴)، از معیارهای تحلیل‌های بنیادی و تکنیکال برای پیش‌بینی قیمت سهام پنجاه شرکت با بیشترین ارزش بازار شناور در بازار بورس استرالیا و تشکیل سبد دارایی برای یک دوره ده‌ساله استفاده شده است. بر اساس یافته‌های این پژوهش، شبکه‌های عصبی مصنوعی عموماً در پیش‌بینی برای تغییر قیمت سهام موفق عمل می‌کنند و شبکه‌هایی با دقتی در حد میانه شبکه‌های ایجاد شده، توانایی ایجاد آلفای مثبت (بازده غیرعادی) برای بازه‌های ده ساله را داشته‌اند و مهمتر از همه این که احتمال این که سبدهای دارایی که ساختار آن به طور تصادفی انتخاب شده است، آلفای منفی معناداری به دست دهد؛ تقریباً صفر است، اما با احتمال ۲۷ درصد با آلفای معنادار مثبت همراه خواهد بود [۱۲]. برخی دیگر از کاربردهای شبکه‌های عصبی مصنوعی در پژوهش‌های مالی عبارتند از:

۱. یک مدل رگرسیون پارسیمونس مدلی است که ضمن برخورداری از قدرت توضیح‌دهندگی بالا، دارای حداقل تعداد متغیرهای مستقل باشد.

2. Broun-Rozelf
3. Griffin- Watts
4. Context Sensitive

واقعی و پیش‌بینی شده، رگرسیون خطی دارای برتری بوده است [۵]. در پژوهش تقی‌زاده مهرجردی، فاضل یزدی و محبی (۱۳۹۲)، از مدل‌های شبکه عصبی مصنوعی، شبکه عصبی فازی و الگوریتم ژنتیک برای مدل‌سازی و پیش‌بینی کارآیی بانک‌های دولتی و خصوصی ایران استفاده شده است [۸]. نهایتاً در پژوهش نیکوآقبال، گندلی علیخانی و نادری (۱۳۹۳) به منظور پیش‌بینی بازدهی شاخص قیمت و بازده نقدی بورس اوراق بهادار تهران از مدل‌های شبکه عصبی اتورگرسیو پویا، ایستای فازی و ایستای چندلایه پیش‌خور استفاده شده است که طبق نتایج به دست آمده مدل شبکه عصبی فازی عملکرد بهتری در پیش‌بینی متغیرهای بررسی شده داشته است [۹].

فرضیه پژوهش

بر اساس نتایج حاصل از پژوهش‌های مشابه پیشین، انتظار می‌رود الگوریتم شبکه‌های عصبی مصنوعی عملکرد بهتری در پیش‌بینی برون‌نمونه‌ای بازده غیرعادی داشته باشد. بر این اساس، فرضیه پژوهش عبارتست از: «الگوریتم شبکه‌های عصبی مصنوعی در پیش‌بینی برون‌نمونه‌ای بازده غیرعادی بهتر از رگرسیون چندگانه عمل می‌کند».

روش پژوهش

متغیرهای مورد مطالعه و مدل رگرسیون خطی چندگانه مورد برازش

متغیر وابسته برای هر دو مدل، بازده غیرعادی است که تعریف عملیاتی آن عبارت است از تفاوت بازده مورد انتظار حاصل از مدل قیمت‌گذاری دارایی‌های سرمایه‌ای در ابتدای دوره مالی و بازده محقق شده در انتهای دوره مالی. برای محاسبه بازده مورد انتظار در

(۱۳۹۳) اشاره کرد که در آن با استفاده از عوامل مختلف ساختاری، به بررسی روش‌های مختلف یادگیری شبکه‌های عصبی و انتخاب و کاربرد مناسب داده‌ها در فرآیند پیش‌بینی پرداخته شده است و مقایسه نتایج با مدل‌های ساختاری و سری زمانی مانند اتورگرسیون برداری در پیش‌بینی شاخص قیمت و بازده نقدی بورس اوراق بهادار تهران بین سال‌های ۱۳۸۵ تا ۱۳۹۰، حاکی از برتری مدل‌های شبکه عصبی بوده است [۶]. همچنین، بارزمان (۱۳۸۹) از شبکه‌های عصبی مصنوعی برای ارزیابی مدل بهینه ساختار سرمایه در صنایع مختلف بورس اوراق بهادار تهران بهره برده است. متغیرهای مستقل پژوهش، نسبت بدهی، نسبت بدهی به حقوق صاحبان سهام؛ و متغیرهای وابسته، هزینه سرمایه، بازده حقوق صاحبان سهام و بازده دارایی‌ها در نظر گرفته شده‌اند و از دو مدل مختلف شبکه عصبی مصنوعی و یک مدل رگرسیون برای مقایسه استفاده شده است. بنا بر نتایج این پژوهش می‌توان با استفاده از مدل شبکه عصبی، ساختار سرمایه بهینه را برای هر یک از صنایع بورس اوراق بهادار تعیین کرد [۱]. در همین زمینه، عبادی (۱۳۸۸) به پیش‌بینی شاخص قیمت کل سهام در بورس تهران با استفاده از شبکه‌های عصبی مصنوعی و مقایسه آن با مدل رگرسیون خطی پرداخته است. برای پیش‌بینی شاخص قیمت سهام در بازار بورس تهران از متغیرهای قیمت طلا و نفت ایران و نرخ ارز (دلار) استفاده شده است و متغیرهای شاخص قیمت سهام و قیمت طلا به صورت باوقفه در مدل ظاهر شده‌اند. بر اساس نتایج به دست آمده، سه معیار از چهار معیار بکار گرفته شده نشان از برتری نسبی روش شبکه عصبی داشته‌اند، اما یک معیار به دلیل افزایش جمله خطا، در روش رگرسیون خطی کمتر بوده است. همچنین از نظر اختلاف بین داده‌های

تحلیل مؤلفه‌های اصلی

در صورت وجود هم‌خطی چندگانه بین متغیرهای مستقل می‌توان از رگرسیون با تحلیل مؤلفه‌های اصلی استفاده کرد. از تحلیل مؤلفه‌های اصلی در شرایطی که بین متغیرهای مستقل رابطه نزدیکی وجود داشته باشد، مانند شرایط هم‌خطی چندگانه، استفاده می‌شود. چنانچه یک مدل رگرسیون از k متغیر مستقل تشکیل شده باشد، با این روش، این متغیرها به k متغیر یا اصطلاحاً «مؤلفه اصلی» ناهمبسته تجزیه می‌شوند. به عبارت دیگر، اگر متغیرهای مستقل اصلی مدل X_1, X_2, \dots و X_k و مؤلفه‌های اصلی p_1 و p_2 و p_k باشند، این مؤلفه‌های اصلی ترکیبات خطی مستقلی از متغیرهای اصلی خواهند بود:

(۳)

$$\begin{aligned} p_1 &= \alpha_{11}X_1 + \alpha_{12}X_2 + \dots + \alpha_{1k}X_k \\ p_2 &= \alpha_{21}X_1 + \alpha_{22}X_2 + \dots + \alpha_{2k}X_k \\ p_k &= \alpha_{k1}X_1 + \alpha_{k2}X_2 + \dots + \alpha_{kk}X_k \end{aligned}$$

در این رابطه α_{ij} ها ضرایبی هستند که در جریان تحلیل مؤلفه‌های اصلی به دست می‌آیند و نشان‌دهنده ضریب متغیر مستقل j ام در مؤلفه اصلی i ام هستند و اگر T مشاهده برای هر متغیر توضیحی وجود داشته است، برای هر مؤلفه اصلی نیز T مشاهده وجود خواهد داشت. همچنین، میزان مجموع مربعات ضرایب هر مؤلفه اصلی برابر با ۱ خواهد بود:

(۴)

$$\begin{aligned} \alpha_{11}^2 + \alpha_{12}^2 + \dots + \alpha_{1k}^2 &= 1 \\ \alpha_{k1}^2 + \alpha_{k2}^2 + \dots + \alpha_{kk}^2 &= 1 \end{aligned}$$

نحوه محاسبه مؤلفه‌های اصلی یک فرآیند صرفاً محاسباتی است و فرض آماری خاصی درباره ساختار یا توزیع آنها مطرح نیست. مؤلفه‌های اصلی به ترتیب میزان اهمیت، یعنی نقششان در توضیح تغییرات متغیر وابسته محاسبه می‌شوند. به همین دلیل، هر چند تعداد

مدل قیمت‌گذاری دارایی‌های سرمایه‌ای از بازده‌های ماهانه سهام شرکت‌های معامله شده در بورس اوراق بهادار تهران در پنج سال گذشته برای محاسبه ضریب بتا استفاده می‌شود.

مدل رگرسیون چندگانه مورد برآزش عبارت خواهد بود از:

(۲)

$$AR_i = \beta_0 + \beta_1 OM_i + \beta_2 WctA_i + \beta_3 ROE_i + \beta_4 CR_i + \beta_5 DtE_i + \beta_6 ROA_i + \beta_7 OPTA_i + \beta_8 Dum_i + \varepsilon_i$$

متغیرهای مستقل مورد استفاده عبارتند از حاشیه سود عملیاتی (OM_i)، نسبت سرمایه در گردش به دارایی‌ها ($WctA_i$)، بازده سرمایه (ROE_i)، نسبت جاری، نسبت بدهی به ارزش ویژه (DtE_i)، بازده دارایی‌ها (ROA_i)، سود عملیاتی به دارایی‌ها ($OPTA_i$) و متغیر مجازی برای خنثی کردن اثر داده‌های پرت (Dum_i). شایان ذکر است گزینش متغیرهای مستقل بر اساس پارامترهای تأیید شده در پژوهش‌های پیشین در زمینه هر دو مدل پیش‌بینی مورد بررسی (برای مثال، او و پنمن (۱۹۸۹) و آلسن و ماسمن (۲۰۰۳)) بوده است.

در مدل رگرسیون به دست آمده، از آزمون t برای بررسی معناداری هر یک از ضرایب رگرسیون، از آزمون F برای بررسی معناداری کلی رگرسیون، از آزمون وایت^۱ برای بررسی همسانی واریانس اجزای خطا^۲ و از آزمون عامل تورم واریانس^۳ برای بررسی عدم وجود هم‌خطی چندگانه^۴ که هر دو از مفروض‌های لازم برای استفاده از رگرسیون خطی هستند، استفاده می‌شود.

1. White
2. Homoscedasticity
3. Variance Inflation Factor
4. Multicollinearity

با این کار، بخش اعظم اطلاعات نهفته در متغیرهای توضیحی توسط مؤلفه‌های اصلی منعکس خواهد شد، اما دیگر هم‌خطی بین آنها وجود نخواهد داشت [۱۳].

شبکه‌های عصبی مصنوعی

الگوریتم شبکه‌های عصبی مصنوعی یک تکنیک پردازش اطلاعات است که در سال‌های اخیر، در زمینه‌هایی چون تعیین الگو، طبقه‌بندی و پیش‌بینی سری‌های زمانی در علم مالی به طور قابل توجهی کاربرد یافته است. مزیت اصلی شبکه‌های عصبی مصنوعی نسبت به سایر تکنیک‌های اقتصادسنجی رایج، در توانایی آن در مدل کردن فرآیندهای پیچیده و احتمالاً غیرخطی؛ بدون در دست داشتن اطلاع قبلی از فرآیندهای ایجاد داده در آنهاست [۱۱، ۳۷]. رابطه غیرخطی بررسی شده ممکن است به صورت یک رابطه غیرخطی پیچیده بین متغیرهای مستقل و وابسته، حدود بالا و پایین برای اثرگذاری متغیرهای مستقل و یا تفاوت بین پیش‌بینی‌ها از تغییرات رو به بالا یا پایین متغیر وابسته باشد. این ساختار انعطاف‌پذیر، شبکه‌های عصبی مصنوعی را برای کاربرد در مالی به ویژه برای زمانی که درباره وجود روابط غیرخطی یقین وجود دارد، اما از ساختار آنها اطلاعات کافی در دست نیست؛ مناسب می‌سازد. به این دلیل، پژوهشگر نیازی به دانستن رابطه غیرخطی بین متغیرهای وابسته و مستقل ندارد [۱۸].

مراحل طراحی یک شبکه عصبی مصنوعی پس‌انتشار خطا برای پیش‌بینی اطلاعات مالی عبارتند از انتخاب متغیرها، جمع‌آوری داده‌ها، پیش‌پردازش داده‌ها^۲، انتخاب مجموعه‌های آموزش، آزمون و تأیید^۳، تعیین پارادایم‌های شبکه عصبی مصنوعی،

مؤلفه‌های اصلی با تعداد متغیرهای مستقل (k) برابر است، اما در صورت وجود هم‌خطی بین این متغیرها ممکن است برخی از مؤلفه‌های اصلی آخر، یعنی بی‌اهمیت‌ترین‌ها قابل حذف باشند. به عبارت دیگر، هر چه میزان هم‌خطی افزایش یابد، آن قدر میزان توان توضیحی مؤلفه‌های اصلی اول، افزایش و توان توضیحی مؤلفه‌های رتبه‌های بعد، کاهش می‌یابد که می‌توان از آخرین مؤلفه‌های اصلی چشم‌پوشی کرد. از سوی دیگر هر چه میزان هم‌خطی کاهش یابد، توان توضیح‌دهندگی بیشتر بین همه مؤلفه‌های اصلی تقسیم می‌شود، به نحوی که هیچ یک قابل حذف نباشند.

در تحلیل مؤلفه‌های اصلی از مقادیر ویژه^۱ ماتریس مشاهده‌ها ($X'X$) استفاده می‌شود. بنا بر این تعداد مقادیر ویژه برابر با تعداد متغیرهای مستقل (k) خواهد بود. اگر مقادیر ویژه به دست آمده را به ترتیب با ($i = 1, \dots, k$) λ_i نشان دهیم، نسبت زیر نشان‌دهنده مجموع پراکندگی در متغیرهای اصلی است که توسط مؤلفه اصلی i ام توضیح داده می‌شود:

(۵)

$$\phi_i = \frac{\lambda_i}{\sum_{i=1}^k \lambda_i}$$

چنان چه تنها r مؤلفه اصلی اول ($0 < r \leq k$) برای توضیح پراکندگی در ماتریس مشاهده‌های کافی در نظر گرفته شوند و باقی مؤلفه‌های اصلی حذف شوند، در رگرسیون که نهایتاً برای پیش‌بینی استفاده خواهد شد، به جای k متغیر مستقل، از r مؤلفه اصلی به دست آمده استفاده خواهد شد:

(۶)

$$Y_t = \gamma_0 + \gamma_1 P_{1t} + \dots + \gamma_r P_{rt} + u_t$$

تعداد نرون‌ها در هر لایه و تعداد و نوع اتصال‌های بین آن‌ها گفته می‌شود.

تعداد نرون‌های لایه ورودی به تعداد متغیرهای مستقل خواهد بود، اما انتخاب تعداد لایه پنهان و نرون‌های آن‌ها و همچنین توابع تبدیل نیازمند انتخاب‌هایی مستقل است.

لایه‌های پنهان، به شبکه عصبی مصنوعی توانایی تعمیم ساختارها را می‌دهند. معمولاً تعداد لایه‌های پنهان، یک یا دو لایه در نظر گرفته می‌شود. در نظر گرفتن تعداد لایه‌های بیشتر و ثابت نگه داشتن تعداد مشاهده‌های ممکن است به توانایی تخمین درون‌نمونه‌ای مدل کمک کند، اما از دقت تخمین برون‌نمونه‌ای خواهد کاست، زیرا در واقع با این کار، شبکه به جای شناسایی الگوی اطلاعات به حفظ آن‌ها می‌پردازد. به این حالت «بیش‌برازش»^۵ گفته می‌شود.

در تعیین تعداد لایه‌های پنهان و نرون‌های لایه‌های پنهان، قاعده و قانون جامعی وجود ندارد. از این رو برای این کار، از شبکه‌های مختلف برای یافتن بهترین تعداد نرون لایه پنهان استفاده خواهد شد و نهایتاً شبکه دارای کمترین میانگین مربعات خطا^۶ در پیش‌بینی درون‌نمونه‌ای برای پیش‌بینی برون‌نمونه‌ای انتخاب می‌شود. همچنین، تابع تبدیل استفاده شده در رگرسیون، تانژانت هیپربولیک خواهد بود [۲۲].

انتخاب مدل پیش‌بینی کارآتر

در این پژوهش برای مقایسه توان پیش‌بینی دو مدل پیش‌بینی به کار رفته از آزمون مقایسه زوج‌ها استفاده می‌شود. از آزمون مقایسه زوج‌ها^۷ برای مقایسه نمونه‌های مربوط به دو جامعه غیرمستقل استفاده

انتخاب معیارهای ارزیابی^۱، آموزش شبکه عصبی مصنوعی و اجرا. شبکه عصبی مصنوعی مورد استفاده در این پژوهش یک شبکه عصبی پیش‌خور با الگوریتم پس انتشار خطا است که در آن از الگوریتم یادگیری لمبریگ-مارکوات^۲ استفاده می‌شود. در این شبکه عصبی مصنوعی از یادگیری نظارت شده استفاده می‌شود. متغیرهای مستقل استفاده شده در این پژوهش از جنس نرخ هستند و عموماً در بازه ۰ تا ۱ قرار می‌گیرند، از این رو پیش‌پردازش خاصی روی اطلاعات اعمال نمی‌گردد.

رابطه ریاضی شبکه عصبی مصنوعی مذکور بدین صورت خواهد بود:

(۷)

$$AR_i = \alpha + \sum_{h=1}^H \phi_h F(\gamma_h + \sum_{j=1}^n \beta_{hj} V_{jy-1}) + \varepsilon_i$$

در این رابطه، H تعداد نرون‌های لایه پنهان و β_{hj} ماتریس وزن‌های پارامترهای مالی در هر نرون، ϕ_h ‌ها اوزان متصل‌کننده نرون‌های لایه پنهان به لایه خروجی و F تابع تبدیل است.

راه‌های متعددی برای تعیین ساختار یک شبکه عصبی مصنوعی وجود دارد. «پویایی عصبی»^۳ و «معماری»^۴ دو اصطلاح استفاده شده برای توصیف نحوه سازماندهی شبکه‌های عصبی مصنوعی هستند که با هم تعریف «پارادایم» شبکه عصبی مصنوعی را تشکیل می‌دهند. پویایی عصبی به توصیف مختصات یک نرون، مثلاً تابع تبدیل و نحوه ترکیب ورودی‌های آن اشاره دارد و معماری شبکه به ساختار شبکه، مثلاً

5. Overfitting
6. Mean Squared Error (MSE)
7. Pairs Test

1. Evaluation Criteria
2. Levenberg-Marquardt Algorithm
3. Neurodynamics
4. Architecture

ضرایب بتای به دست آمده باید از نظر معناداری آماری بررسی شوند. بدین ترتیب، ضرایب بتایی که از نظر آماری معنادار نباشند، برابر با صفر در نظر گرفته می‌شوند. با صفر در نظر گرفتن میزان بتا، در واقع میزان بازده مورد انتظار از سهم، برابر با بازده بدون ریسک در نظر گرفته می‌شود.

با قرار دادن ضرایب بتای به دست آمده در رابطه مدل قیمت‌گذاری دارایی‌های سرمایه‌ای، میزان بازده مورد انتظار از هر سهم (برای سال ششم) به دست می‌آید. با کم کردن این مقدار از بازده محقق شده هر سهم (در انتهای سال ششم)، بازده غیرعادی آن سهم (متغیر وابسته پژوهش) به دست خواهد آمد. سپس از بازده‌های غیرعادی حاصله در کنار نسبت‌های مالی شرکت‌های مورد مطالعه (بر اساس اطلاعات در دسترس در ابتدای سال، استخراج شده با استفاده از نرم‌افزار ره‌آورد نوین و پس از حذف داده‌های پرت با استفاده از اصل چیبی‌شف) برای برآزش مدل رگرسیون و انتخاب شبکه عصبی بهینه و یادگیری آن استفاده می‌شود. نهایتاً، با وارد کردن نسبت‌های مالی شرکت‌ها (در ابتدای سال هفتم) به مدل‌های رگرسیون و شبکه عصبی به دست آمده، بازده غیرعادی برای پایان این سال پیش‌بینی می‌گردد و با مقادیر واقعی مقایسه می‌شود.

یافته‌ها

برای تحلیل آماری داده‌ها و ایجاد مدل رگرسیون در این پژوهش از نرم‌افزار 7 Eviews استفاده شده است. نتایج حاصل از تحلیل آمار توصیفی اطلاعات پژوهش که ۶۶ شرکت مورد معامله در بورس اوراق بهادار تهران را در بر می‌گیرد، عبارت است از:

می‌شود. اگر اعضای نمونه اول را با X_i و اعضای نمونه دوم را با Y_i و تفاضل آنها را با $d_i = Y_i - X_i$ نمایش دهیم، آزمون این فرض که تفاوت میانگین d_i ها با صفر معنادارست یا نه برای بررسی وجود یا عدم وجود تفاوت معنادار بین X_i ها و Y_i ها به کار می‌رود. البته از این آزمون تنها در شرایطی می‌توان استفاده کرد که هر زوج X_i و Y_i از هم مستقل باشند و توزیع آماره میانگین تفاوت‌ها نرمال باشد [۷].

در این پژوهش نیز در حقیقت دو نمونه از خطاهای پیش‌بینی وجود دارد که یک نمونه حاوی تفاوت مقادیر واقعی و مقادیر پیش‌بینی شده توسط رگرسیون و یک نمونه حاوی تفاوت مقادیر واقعی و مقادیر پیش‌بینی شده توسط الگوریتم شبکه‌های عصبی مصنوعی است. مربع اعداد هر دو مجموعه معیار مجذور مربعات خطا را به دست خواهد داد و از تفاضل آن‌ها مجموعه مورد آزمون d_i ها را تشکیل خواهد شد:

(۸)

$$d_i = \text{MSE}_{i\text{reg}} - \text{MSE}_{i\text{ANN}}$$

جامعه و نمونه آماری و نحوه پردازش داده‌ها

برای انجام این پژوهش، ابتدا از میان شرکت‌هایی که سهامشان از ابتدای سال ۱۳۸۴ تا پایان سال ۱۳۹۱ در بورس اوراق بهادار تهران معامله شده است، شرکت‌هایی که به میزان حداقل صد روز معاملاتی در هر سال معامله شده‌اند و در صنعت واسطه‌گری پولی و مالی (بانک‌ها، شرکت‌های سرمایه‌گذاری، لیزینگ‌ها و غیره) قرار ندارند، انتخاب شده‌اند و برای هر یک بازده‌های تعدیل شده، در دوره‌های ماهانه در پنج سال نخست استخراج شده‌اند. سپس میزان بازده ماهانه شاخص کل بورس اوراق بهادار تهران برای همان مدت محاسبه و برای استخراج ضریب بتا در مدل قیمت‌گذاری دارایی‌های سرمایه‌ای استفاده می‌شوند.

جدول (۱)

بازده دارایی‌ها	سرمایه در گردش به دارایی‌ها	نسبت بدهی به ارزش ویژه	سود عملیاتی به دارایی‌ها	نسبت جاری	بازدهی سرمایه	حاشیه سود عملیاتی	بازده غیرعادی	
۰/۱۳۸	۰/۰۰۳	۰/۰۱۸	۰/۱۵۸	۰/۰۱۳	۰/۳۹۹	۰/۳۹۸	۰/۱۱۱	میانگین
۰/۱۲۰	۰/۰۰۱	۰/۰۱۲	۰/۱۴۴	۰/۰۱۲	۰/۳۲۵	۰/۲۳۴	۰/۱۰۱	میانه
۰/۵۱۷	۰/۱۰۵	۰/۰۶۸	۰/۵۲۶	۰/۰۳۲	۰/۷۱۱	۱/۰۰۲	۱/۳۱۶	بیشینه
-۰/۱۳۴	-۰/۰۰۳	۰/۰۰۲	-۰/۰۴۵	۰/۰۰۲	-۰/۶۵۱	-۰/۵۰۲	-۰/۵۱۰	کمینه
۰/۷۶۹	۷/۸۲۹	۱/۹۱۱	۰/۸۷۷	۱/۱۹۷	-۱/۵۱۲	۰/۷۲۳	۰/۷۲۱	چولگی
۲/۱۴۴	۶۲/۷۷۰	۳/۴۰۹	۰/۸۹۷	۱/۶۵۰	۴/۸۹۷	۰/۹۷۲	۰/۴۸۹	کشیدگی

برازش و پیش‌بینی با مدل رگرسیون خطی چندگانه و تحلیل مؤلفه‌های اصلی

جدول (۲) برازش مدل رگرسیون خطی

متغیر وابسته: ARI				
روش: حداقل مربعات				
تعداد مشاهدات: ۶۶				
متغیر مستقل	ضریب	خطای استاندارد	آماره t	احتمال
C	-۰/۰۵۳۲۳۷	۰/۱۹۲۲۷۴	-۰/۲۷۶۸۸۳	۰/۷۸۲۹
OM	-۰/۱۹۲۳۴۸	۰/۱۸۸۷۱۴	-۱/۰۱۹۲۵۵	۰/۳۱۲۴
ROA	۳/۵۴۱۴	۱/۲۰۲۳۴۱	۲/۹۴۵۴۲۱	۰/۰۰۴۷
CR	-۷/۵۳۹۸۱۵	۱۰/۱۷۷۵	-۰/۷۴۰۸۳۲	۰/۴۶۱۸
DTE	۱۲/۱۱۹۳۴	۴/۱۶۹۰۶۶	۲/۹۰۶۹۶۷	۰/۰۰۵۲
WCTA	۱/۲۵۲۶۹۹	۳/۳۵۷۰۱۴	۰/۳۷۳۱۵۹	۰/۷۱۰۴
OPTA	۰/۲۲۴۹۷۲	۰/۵۰۶۶۵۸	۰/۴۴۴۰۳	۰/۶۵۸۷
ROE	-۱/۳۹۰۹۱۶	۰/۴۳۸۳۳۵	-۳/۱۷۳۱۸۴	۰/۰۰۲۴
DUMMY	-۰/۰۷۸۷۶۴	۰/۱۷۳۳۶۹	-۰/۴۵۴۳۱۶	۰/۶۵۱۳
۰/۱۱۱۱۳۴	میانگین متغیر وابسته	۰/۲۴۳۱۳۴	R^2	
۰/۴۰۷۱۶۲	انحراف معیار متغیر وابسته	۰/۱۳۶۹۰۷	R^2 تعدیل شده	
۲/۲۸۸۸۱۶	آماره F	۰/۳۷۸۲۶۵	انحراف معیار رگرسیون	
۰/۰۳۳۵۸۳	احتمال آماره F	۸/۱۵۵۸۲۳	جمع مربعات باقیمانده‌ها	

هم‌خطی تا حدی بین متغیرها وجود دارد. از این رو مؤلفه‌های اصلی استخراج می‌شوند و در تشکیل مدل رگرسیون با استفاده از تحلیل مؤلفه‌های اصلی استفاده می‌شوند. میزان پراکندگی مورد توضیح بدین شرح بین مؤلفه‌های اصلی به دست آمده تقسیم شده است:

مدل رگرسیون خطی برازش شده عبارت است از: همان‌طور که در جدول فوق دیده می‌شود مدل برازش شده از معناداری کلی برخوردار است. آزمون وایت حاکی از برقراری فرض همسانی واریانس اجزای اخلاص بوده است، اما طبق آزمون عامل تورم واریانس،

جدول (۳) میزان پراکندگی توضیح داده شده توسط هر مؤلفه اصلی

مؤلفه	میزان پراکندگی مورد توضیح
۱	۳۹ درصد
۲	۱۶ درصد
۳	۱۳ درصد
۴	۱۰ درصد
۵	۸ درصد
۶	۷ درصد
۷	۶ درصد
۸	۱ درصد

به جهت رعایت اختصار از ذکر محاسبات
مؤلفه‌های اصلی صرف نظر می‌گردد. همچنین، به علت
عدم تمرکز بالای میزان توضیح‌دهندگی در چند مؤلفه
اصلی نخست، از همگی آن‌ها استفاده می‌شود.

جدول (۴) رگرسیون با تحلیل مؤلفه‌های اصلی

متغیر وابسته: ARI روش: حداقل مربعات تعداد مشاهدات: ۶۶				
متغیر مستقل	ضریب	خطای استاندارد	آماره t	احتمال
C	۰/۱۱۱۱۳۴	۰/۰۴۶۵۶۱	۲/۳۸۶۸۳۱	۰/۰۲۰۳
PC۱	-۰/۰۳۴۷۳۹	۰/۰۲۶۴۶	-۱/۳۱۲۹۲۵	۰/۱۹۴۵
PC۲	۰/۰۲۳۳۲۸	۰/۰۴۰۴۷۲	۰/۵۷۶۴۱	۰/۵۶۶۶
PC۳	۰/۰۵۶۱۸۶	۰/۰۴۵۹۵۶	۱/۲۲۲۶۰۵	۰/۲۲۶۵
PC۴	-۰/۰۴۹۱۹۳	۰/۰۵۱۴۴۱	-۰/۹۵۶۳۰۲	۰/۳۴۳
PC۵	۰/۰۷۵۶۵۶	۰/۰۵۸۹۰۸	۱/۲۸۴۳۰۸	۰/۲۰۴۲
PC۶	-۰/۰۸۶۳۸۴	۰/۰۶۲۵۵	-۱/۳۸۱۰۴۶	۰/۱۷۲۷
PC۷	۰/۰۴۵۱۲۹	۰/۰۶۷۹۳	۰/۶۶۴۳۳۸	۰/۵۰۹۲
PC۸	۰/۵۰۰۹۷	۰/۱۵۹۳۶۷	۳/۱۳۸۰۱۷	۰/۰۰۲۷
۰/۱۱۱۱۳۴	میانگین متغیر وابسته	۰/۲۴۳۱۳۴	R^2	
۰/۴۰۷۱۶۲	انحراف معیار متغیر وابسته	۰/۱۳۶۹۰۷	R^2 تعدیل شده	
۲/۲۸۸۸۱۶	آماره F	۰/۳۷۸۲۶۵	انحراف معیار رگرسیون	
۰/۰۳۳۵۸۳	احتمال آماره F	۸/۱۵۵۸۲۳	جمع مربعات باقیمانده‌ها	

مدل رگرسیون برازش شده با استفاده از مؤلفه‌های
اصلی عبارت است از:
پیش‌بینی برون‌نمونه‌ای بازده غیرعادی سهام شرکت‌ها
استفاده می‌شود.

از ضرایب استخراج شده برای هر متغیر مستقل در
هر مؤلفه اصلی؛ و از ضرایب استخراج شده برای هر
مؤلفه اصلی در مدل رگرسیون برازش شده، برای

طراحی مدل و پیش‌بینی با شبکه عصبی مصنوعی

در این پژوهش از نرم‌افزار MATLAB برای آموزش و شبیه‌سازی (پیش‌بینی) با استفاده از شبکه‌های عصبی استفاده می‌شود. بدین ترتیب با ایجاد حلقه‌ای از محاسبات، بهترین مقادیر برای تعداد لایه‌های پنهان و نرون‌های آن‌ها بر اساس پیش‌بینی درون‌نمونه‌ای انتخاب می‌شود. برای این کار ابتدا، مقادیر ممکن برای تعداد لایه‌های پنهان، ۱ و ۲؛ تعداد نرون در لایه اول، از ۵ تا ۲۰ و تعداد نرون در لایه دوم (در صورت وجود لایه دوم) از ۱ تا ۵ تعیین شده است و نمونه مورد نظر، به دو قسمت آموزش و آزمون تقسیم می‌شود، به نحوی که از بخش اول شامل ۶۰ شرکت، برای آموزش شبکه و پیش‌بینی درون‌نمونه‌ای و مقایسه با مقادیر واقعی و محاسبه میانگین مربعات خطا و از ۶ شرکت بعدی، برای مقایسه میانگین مربعات خطای شبکه‌های به دست آمده و انتخاب بهترین شبکه استفاده خواهد شد. لازم به ذکر است در انتخاب شش شرکت مورد استفاده برای انتخاب بهترین شبکه در سال تشکیل مدل، از شرکت‌های شش صنعت گوناگون استفاده شده است، تا قابلیت تعمیم‌پذیری مدل حداکثر گردد.

بدین ترتیب، اولین شبکه عصبی با یک لایه پنهان و پنج نرون ایجاد می‌شود و با استفاده از اطلاعات ۶۰ شرکت ایجاد می‌شود و با آن، بازده غیرعادی شش شرکت بعد پیش‌بینی می‌شود. سپس مقادیر پیش‌بینی شده برای این شش شرکت با مقادیر واقعی مقایسه می‌شوند و میانگین مربعات خطا به دست می‌آید. چنان

چه این مقدار از یک عدد بزرگ، مثلاً عدد صد هزار کوچک‌تر باشد، شبکه به دست آمده، فعلاً به عنوان «بهترین شبکه» انتخاب می‌شود. سپس، محاسبات برای شبکه بعدی با یک لایه پنهان و شش نرون تکرار می‌شود، اگر میزان حداقل مربعات خطا کاهش یابد، شبکه جدید، جایگزین انتخاب قبلی برای بهترین شبکه خواهد شد. این محاسبات برای تمام حالات ممکن، (جمعاً ۹۰ حالت) تکرار می‌شود، و شبکه‌ای که کمترین میانگین مربعات خطا را به دست دهد، به عنوان بهترین شبکه برگزیده خواهد شد. بنا بر نتیجه محاسبات مذکور در نرم‌افزار MATLAB بهترین شبکه عصبی مصنوعی، شبکه‌ای با دو لایه پنهان، هفت نرون در لایه اول و یک نرون در لایه دوم بوده است.

آزمون فرضیه پژوهش

نهایتاً، اطلاعات همه ۶۶ شرکت برای گرفتن پیش‌بینی برون‌نمونه‌ای به بهترین شبکه داده شده و از خطاهای پیش‌بینی آن برای آزمون فرضیه پژوهش استفاده می‌شود.

همان‌طور که پیشتر توضیح داده شد، برای مقایسه توان پیش‌بینی دو مدل، برای هر یک مجموعه‌ای از مجذور مربعات خطا به دست می‌آید که تفاضل آن‌ها در آزمون مقایسه زوجی استفاده می‌شود. با استخراج میانگین و انحراف معیار مقادیر به دست آمده می‌توان آزمون مقایسه‌های زوجی را به شکل زیر اجرا نمود:

جدول (۵) آزمون مقایسه‌های زوجی

\bar{d}_i	$S_{\bar{d}}$	۲/۲۷۴۲	آماره آزمون
۰/۰۴۹۶	۰/۰۲۱۸	۰/۰۱۳۱	مقدار احتمال

هدف دوم و فرضیه پژوهش، بررسی وجود برتری الگوریتم شبکه‌های عصبی مصنوعی نسبت به مدل رگرسیون حداقل مربعات معمولی در پیش‌بینی برون‌نمونه‌ای بازده غیرعادی با استفاده از نسبت‌های مالی است. برای این کار نسبت‌های مالی و بازده غیرعادی سهام یک بار برای ایجاد مدل رگرسیون و یک بار برای به دست آوردن یک شبکه عصبی مصنوعی مورد استفاده قرار گرفتند. سپس توان پیش‌بینی مدل و شبکه عصبی به دست آمده برای دسته دیگری از اطلاعات مقایسه شد. بر اساس نتیجه حاصل از آزمون فرضیه این پژوهش، با استفاده از شواهد موجود در سطح معناداری پنج درصد نمی‌توان فرضیه پژوهش مبنی بر کارایی بالاتر الگوریتم شبکه‌های عصبی مصنوعی نسبت به رگرسیون خطی در پیش‌بینی برون‌نمونه‌ای بازده غیرعادی سهام با استفاده از نسبت‌های مالی را رد کرد؛ حتی زمانی که در ایجاد مدل رگرسیون خطی چندگانه از تحلیل مؤلفه‌های اصلی استفاده گردد.

لازم به ذکر است، نتایج فوق با نتایج به دست آمده توسط ریفتز و همکاران (۱۹۹۳)، کوتز و فنت (۱۹۹۳)، آلسن و ماسمن (۲۰۰۳)، کائو و همکاران (۲۰۱۱) و باسو و آشود (۲۰۱۴) مطابقت دارد.

- به سرمایه‌گذارانی که قصد دارند از مدل قیمت‌گذاری دارایی‌های سرمایه‌ای برای پیش‌بینی بازده مورد انتظار از سهام استفاده کنند توصیه می‌شود، از اطلاعات صورت‌های مالی برای پیش‌بینی بخشی از

از آنجا که هر \bar{d}_i به صورت میانگین مجذور مربعات خطای مدل رگرسیون خطی منهای میانگین مجذور مربعات خطای مدل شبکه عصبی مصنوعی تعریف شد، مثبت بودن آن به معنی بیشتر بودن خطای مدل رگرسیون خطی است. بر این اساس، طبق مقدار احتمال به دست آمده تفاوت مشاهده شده بین توان پیش‌بینی برون‌نمونه‌ای دو مدل تا سطح معناداری قریب به یک درصد معنادار است. بر این اساس، آماره آزمون در سطح معناداری ۵ درصد کاملاً معنادار است و این به معنی ناممکن بودن رد فرضیه پژوهش، مبنی بر توانایی بالاتر الگوریتم شبکه‌های عصبی مصنوعی نسبت به رگرسیون خطی در پیش‌بینی برون‌نمونه‌ای بازده غیرعادی با استفاده از نسبت‌های مالی استفاده شده در پژوهش؛ در سطح معناداری ۵ درصد است؛ حتی در زمانی که اثر مخرب هم‌خطی چندگانه بر مدل رگرسیون خطی به وسیله استفاده از تحلیل مؤلفه‌های اصلی خنثی شده باشد.

نتیجه‌گیری و پیشنهادها

هدف نخست این پژوهش، بررسی امکان به دست آوردن بازده غیرعادی با استفاده از نسبت‌های مالی است. بر این اساس، وجود رابطه‌ای معنادار بین بازده غیرعادی و پارامترهای مالی مذکور به معنی امکان استفاده از این معیارها برای شناسایی سهامی دارای بازده مازاد بر بازده مورد انتظار حاصل از مدل قیمت‌گذاری دارایی‌های سرمایه‌ای است.

مدل‌های معرفی شده توسط فاما-فرنج یا کارهارت (۱۹۹۷) استفاده کرد [۲۰ و ۱۷]. البته قبل از انجام این کار، باید از وجود توجیه‌های نظری و تجربی لازم در ادبیات موضوع، اطمینان حاصل شود؛ کما این که طبق پژوهش باسو و آشود (۲۰۱۴)، صرفاً با دادن پارامترهای تحلیل بنیادی و تکنیکال به مدل شبکه‌های عصبی مصنوعی می‌توان به استراتژی‌های سرمایه‌گذاری سودآوری دست یافت [۱۲].

- می‌توان قدرت پیش‌بینی مدل‌ها را در گروه‌هایی جداگانه از شرکت‌ها (مثلاً برای شرکت‌های بزرگ و کوچک یا شرکت‌های ارزشی و رشدی، طبق مدل فاما-فرنج) سنجید تا نسبت‌های مالی شرکت‌های شبیه‌تری به مدل‌ها ارایه شده باشند.

- با توجه به محدودیت زمانی انجام این پژوهش و اثر آن بر تعداد شرکت‌ها، مسلماً تکرار آن در آینده با توجه به افزایش تعداد شرکت‌ها، حجم معاملات و عمق بازار، با نتایج قابل اتکاتری همراه خواهد بود.

- شرکت‌های صنعت واسطه‌گری پولی و مالی به علت ماهیت کلی فعالیت‌هایشان و تفاوت عمده نسبت‌های مالی‌شان با دیگر صنایع از این پژوهش کنار گذاشته شدند. انجام پژوهشی که به طور خاص بر این صنعت تمرکز داشته باشد می‌تواند در یافتن راه‌هایی برای پیش‌بینی بازده غیرعادی سهام شرکت‌های این صنعت مؤثر باشد.

منابع و مآخذ

[۱] بارزمان، منصور. (۱۳۸۹). ارایه مدل بهینه ساختار سرمایه در صنایع مختلف بورس اوراق بهادار تهران با استفاده از شبکه عصبی مصنوعی، پایان‌نامه کارشناسی ارشد، دانشکده علوم اجتماعی و اقتصادی، دانشگاه شیراز.

بازده که توسط این مدل توضیح داده نمی‌شود، استفاده کنند. برای این کار باید نسبت‌های مالی و همچنین مدل پیش‌بینی به نحو مناسبی انتخاب شوند.

- با توجه به نتیجه این پژوهش و دیگر پژوهش‌ها چون کاو و همکاران (۲۰۱۶) که حاکی از برتری مدل شبکه‌های عصبی مصنوعی بر رگرسیون خطی (حتی پس از استفاده از رویکرد تحلیل عوامل اصلی) در پیش‌بینی بازده غیرعادی است؛ به سرمایه‌گذاران توصیه می‌شود حداقل در کنار استفاده از مدل‌های رگرسیونی، استفاده از مدل شبکه‌های عصبی مصنوعی را در نظر داشته باشند.

- باید توجه داشت که استفاده از مدل شبکه‌های عصبی مصنوعی نیازمند یافتن ساختار شبکه بهینه (معماری و پویایی عصبی) است. این روش توان شناسایی و بهره‌مندی از روابط غیرخطی بین متغیرهای مستقل و وابسته را نیز داراست.

با توجه به محدودیت‌های این پژوهش، موارد زیر برای پژوهش‌های آتی پیشنهاد می‌شوند:

- می‌توان با استفاده از رگرسیون مرحله‌ای^۱ بهترین پارامترهای پیش‌بینی‌کننده به وسیله این مدل را یافت و سپس توان پیش‌بینی شبکه‌های عصبی با همان داده‌ها را بررسی کرد و سپس همین کار را برای مدل شبکه‌های عصبی مصنوعی نیز تکرار کرد (انتخاب مناسب‌ترین داده‌ها و سپس بررسی عملکرد مدل دیگر با همان داده‌ها). هدف از این کار کشف ویژگی‌های نهفته در داده‌هاست به نحوی که بتوان از آن در انتخاب مناسب‌ترین مدل بهره برد.

- با توجه به تمرکز مبانی نظری و پیشینه این پژوهش، بر مدل قیمت‌گذاری دارایی‌های سرمایه‌ای؛ می‌توان در پژوهش‌های آتی به جای مدل مذکور از

- [۲] دستگیر، محسن؛ یوسفی گورتی، وجیهه. (۱۳۹۳). بررسی ارتباط بین سود یا زیان شناسایی نشده ناشی از تورم، جریان‌های نقد آتی و بازده غیرعادی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران. *فصلنامه علمی-پژوهشی مدیریت دارایی و تأمین مالی*، ۲ (۴): ۷۵-۹۸.
- [۳] سرابندی، نریمان. (۱۳۸۹). بررسی رابطه بین بازده مازاد سهام با سود هر سهم پیش‌بینی شده، نسبت قیمت به درآمد هر سهم، نسبت گردش حجم معاملات و معاملات عمده در بورس اوراق بهادار، *پایان‌نامه کارشناسی ارشد*. دانشکده علوم اقتصادی، دانشکده علوم اقتصادی.
- [۴] شجر، مهدی. (۱۳۸۸). بررسی متغیرهای بنیادی حسابداری و بازده غیرعادی سهام، *پایان‌نامه کارشناسی ارشد*، دانشکده حسابداری و مدیریت، دانشگاه آزاد اسلامی واحد مرودشت.
- [۵] عبادی، امید. (۱۳۸۸). پیش‌بینی شاخص کل قیمت سهام در بازار بورس تهران با استفاده از شبکه‌های عصبی مصنوعی، *پایان‌نامه کارشناسی ارشد*، دانشکده اقتصاد و علوم اجتماعی، دانشگاه بوعلی سینا.
- [۶] فامیلیان، مولود؛ یزدانی، سیما. (۱۳۹۳). مقایسه عملکرد مدل‌های شبکه عصبی مصنوعی و اتورگرسیون برداری در پیش‌بینی شاخص قیمت و بازده نقدی. *تحقیقات حسابداری و حسابرسی*، ۲۱.
- [۷] مؤمنی، منصور؛ آذر، عادل. (۱۳۸۶). آمار و کاربرد آن در مدیریت. تهران: سازمان مطالعه و تدوین کتب علوم انسانی.
- [۸] تقی‌زاده مهرجردی، روح‌الله؛ فاضل‌یزدی، علی؛ محبی، رضا. (۱۳۹۲). مدل‌سازی و پیش‌بینی کارآیی بانک‌های دولتی و خصوصی ایران با استفاده از مدل‌های شبکه عصبی مصنوعی، *شبکه عصبی فازی و الگوریتم ژنتیک فصلنامه علمی-پژوهشی مدیریت دارایی و تأمین مالی*، ۱ (۲): ۱۰۳-۱۲۶.
- [۹] نیکواقبال، اکبر؛ گندلی علیخانی، نادیا؛ نادری، اسماعیل. (۱۳۹۳). ارزیابی مدل‌های شبکه عصبی مصنوعی ایستا و پویا در پیش‌بینی قیمت سهام. *فصلنامه علمی پژوهشی دانش مالی تحلیل اوراق بهادار*، ۷ (۲۲): ۷۷ تا ۹۱.
- [10] Angelini, E., Tollo, G. di, Roli, A., (2008). A Neural Network Approach for Credit Risk Evaluation. *The Quarterly Review of Economics and Finance*, 48(4): 733-755.
- [11] Balkin, S. D., & Ord, J. K. (2000). Automatic Neural Network Modeling for Univariate Time Series, *International Journal of Forecasting*, 16: 509-515.
- [12] Basu, Anup K. & Ashwood, Andrew J.. (2014) The Quest for Alpha: Can Artificial Neural Networks Help? *JASSA*, (1): 13-18.
- [13] Brooks, C. (2002). *Introductory Econometrics for Finance*. Cambridge, Cambridge University Press.
- [14] Callen, J. L., Kwan, C., Yip, P., & Yuan, Y. (1996). Neural Network Forecasting of Quarterly Accounting Earnings, *International Journal of Forecasting*, 12: 475-482.
- [15] Cao, Q., Parry, M. E.. (2009). Neural Network Earnings Per Share Forecasting Models: A Comparison of Backward Propagation and the Genetic Algorithm. *Decision Support Systems*, 47(1): 32-41.
- [16] Cao, Qing, Parry, Mark E., Leggio, Karyl B. (2011). The Three-Factor Model and Artificial Neural Networks: Predicting Stock Price Movement in China. *Annals of Operations Research*, May 2011, 185, (1): 25-44.
- [17] Carhart, Mark. (1997). On Persistence in Mutual Fund Performance, *Journal of Finance*. (52): 661-692.
- [18] Caudill, M. (1992). The view from now. *AI Expert*, (June 1992) 24-31.

- Applying Artificial Neural Networks to prediction of stock price and improvement of the directional prediction index – Case study of PETR4, Petrobras, Brazil. *Expert Systems with Applications*, 40 (18): 7596–7606.
- [30] Olson, D. Mossman, C. (2003). Neural Network Forecasts of Canadian stock Returns Using Accounting Ratios, *International Journal of Forecasting*, 1-13.
- [31] Ou, J. A., & Penman, S. H. (1989). Financial Statement Analysis and the Prediction of Stock Returns. *Journal of Accounting and Economics*, (11): 295–329.
- [32] Refenes, A. N., Azema-Barac, M. and Zapranis, A. D. (1993). Stock Ranking: Neural Networks vs Multiple Linear Regression. *IEEE International Conference on Neural Networks*, 141-1426.
- [33] Reinganum, M. R. (1981). Abnormal Returns in Small Firm Portfolios. *Financial Analysts Journal*, 52-56.
- [34] Reinganum, M. R. (1988). The Anatomy of a Stock Market Winner. *Financial Analysts Journal*, (39): 16-28.
- [35] St. John, C.H., Balakrishnan, N., Fiet, J. O. (2000). Modeling the Relationship between Corporate Strategy and Wealth Creation using Neural Networks. *Computers and Operations Research*, (27): 1077-1092.
- [36] Sureshkumar, K. K., Elango, N. M.. (2012). Performance Analysis of Stock Price Prediction using Artificial Neural Networks. *Global Journal of Computer Science and Technology*, Volume 12 Issue 1, pp.19-25.
- [37] Tkacz, G. (2001). Neural Network Forecasting of Canadian GDP Growth. *International Journal of Forecasting*, (17): 57–69.
- [38] Wansley, J., Roenfeldt, R., Cooley, P. (1983), Abnormal Returns from Merger Profiles, *Journal of Financial and Quantitative Analysis*, (18): 149-162.
- [39] West, D. (2000). Neural Network Credit Scoring Models. *Computers and Operations Research*, 27 (11): 1131-1152.
- [19] Coats, P.K., Fant, L.F. (1993). Recognizing Financial Distress Patterns Using a Neural Network Tool, *Financial Management*, 22 (3): 142-155.
- [20] Fama, E., French, K. (1993). Common Risk Factors in the Returns on Stocks and Bonds. *Journal of Financial Economics*. (33): 3–56.
- [21] Holthausen, R. W., & Larcker, D. F. (1992). The Prediction of Stock Returns Using Financial Statement Information. *Journal of Accounting and Economics*, (15): 373– 411.
- [22] Kaastra, I. Boyd, M. (1996). Designing a Neural Network for Forecasting Financial and Economic Time Series, *Neurocomputing*, (10): 215-236.
- [23] Long, J.A., Raudys, A.. (2000). Modelling Company Credit Ratings Using a Number of Classification Techniques. In Fifteenth European Meeting on Cybernetics and Systems Research.
- [24] Lee, Sangjae, Ch, Wu Sung. (2013). A Multi-Industry Bankruptcy Prediction Model Using Back-Propagation Neural Network and Multivariate Discriminant Analysis. *Expert Systems with Applications*, 40 (8): 2941–2946.
- [25] Leung, M. T., Chen A. S., Daouk, H.. (2000). Forecasting Exchange Rates Using General Regression Neural Networks. *Computers and Operations Research*. 27 (11): 1093-1110.
- [26] Mokhatab R., F., S.M. Manzari, S. Bostanian. (2011). Financial Health Prediction Models Using Artificial Neural Networks, Genetic Algorithm and Multivariate Discriminant Analysis: Iranian Evidence. *Expert Systems with Applications*, 38 (8): 10210-10217.
- [27] Mostafa, M. M., (2010). Forecasting Stock Exchange Movements Using Neural Networks: Empirical Evidence from Kuwait. *Expert Systems with Applications*, 37(9): 6302-6309.
- [28] O’Conner, M. (1973). On the Usefulness of Financial Statement Analysis and the Prediction of Stock Return, *Accounting Review*, (48): 339-352.
- [29] Oliveira, Fagner A. de, Nobre, Cristiane N., Zárata, Luis E. (2013).

