



ارزیابی توان پیش‌بینی سود فصلی هر سهم با استفاده از مدل‌های سری زمانی و شبکه‌ی پرسپترون چند لایه (MLP)

حسین اعتمادی^۱

علی اصغر انواری رستمی^۲

وحید احمدیان^۳

تاریخ پذیرش: ۹۳/۱۲/۱۹

تاریخ دریافت: ۹۳/۱۰/۱۶

چکیده

پیش‌بینی سود هر سهم و ارزیابی سودمندی سودهای گذشته برای پیش‌بینی، از دیرباز مورد توجه پژوهشگران بوده و بدین منظور از روش‌ها و مدل‌های متفاوتی به منظور پیش‌بینی سودهای آتی شرکت‌ها استفاده شده است. در این راستا، در پژوهش حاضر، مدل‌های سری زمانی توضیحی جمعی میانگین متحرک ARIMA و شبکه‌های عصبی مصنوعی از نوع پرسپترون چند لایه (MLP) مورد استفاده قرار گرفتند و پیش‌بینی‌ها برای سودهای فصلی شرکت‌های پذیرفته شده در بازار بورس اوراق بهادار تهران و بر اساس داده‌های فصلی سال‌های ۱۳۸۶ تا ۱۳۹۱ انجام پذیرفت. نتایج نشان داد که مدل شبکه‌های عصبی مصنوعی به طور معناداری، خطاهای کوچکتری را در پیش‌بینی نسبت به مدل‌های ARIMA ایجاد می‌کنند و در نتیجه پیش‌بینی سودهای فصلی این شرکت‌ها، توسط شبکه‌های عصبی مصنوعی و با روش MLP از توان بیشتری نسبت به ARIMA برخوردار است.

واژه‌های کلیدی: سود فصلی هر سهم، شبکه پرسپترون چند لایه (MLP)، سری‌های زمانی ARIMA.

۱- دانشیار حسابداری دانشگاه تربیت مدرس (نویسنده مسئول) etemadiah@modares.ac.ir

۲- استاد حسابداری دانشگاه تربیت مدرس anvary@modares.ac.ir

۳- کارشناس ارشد حسابداری دانشگاه تربیت مدرس alcinbusiness3@gmail.com

۱- مقدمه

هدف اصلی اکثر شرکت‌ها کسب سود و ایجاد ارزش برای سهامداران است؛ همچنین با توجه به پیشرفت تکنولوژی و گسترش شرکت‌های عظیم تولیدی و بازرگانی در سطح بین‌المللی و رونق روزافزون بازارهای سهام، یکی از معیارهای مهم ارزیابی عملکرد مدیریت واحدهای مختلف تجاری، پتانسیل سودآوری و ارزش سهام شرکت‌ها می‌باشد. سرمایه‌گذاران و سهامداران تلاش می‌کنند که در تصمیم‌گیری‌ها به نحوی عمل کنند که چشم‌اندازی درست از روند سود شرکت‌ها داشته باشند تا بتوانند با اخذ تصمیمات درست و عینی‌تر به انتظارات و توقعات خویش از سرمایه‌گذاری دست یابند. در این میان، پیش‌بینی^۱ سودهای سهام، یک موضوع مهم در زمینه‌های مختلف تئوری تصمیم می‌باشد. این پیش‌بینی به سرمایه‌گذاران کمک می‌کند تا فرآیند تصمیم‌گیری خود را بهبود بخشند و خطر تصمیم‌های خود را کاهش دهند. آنها علاقه دارند منافع آینده سرمایه‌گذاری خود را برآورد نمایند و درباره دریافت سود نقدی آینده سهام خود داوری کنند. بدین ترتیب، سرمایه‌گذاران پیش‌بینی سودهای سهام را درخواست می‌کنند. این پیش‌بینی-ها کمک می‌کند تا یک سهامدار فعلی تصمیم بگیرد سهامش را بفروشد یا نگه دارد. یک سرمایه‌گذار قبل از عمل با پیش‌بینی توزیع جریان‌های نقدی آینده یک سهام، تصمیم به خرید آن می‌گیرد و یا تصمیم می‌گیرد در جای دیگری سرمایه‌گذاری کند. پس چشم‌داشت در شیوه پرداخت سود سهام در آینده، در درجه اول اهمیت تصمیم‌گیری‌های سرمایه‌گذاری قرار دارد و تصمیم‌گیری‌های مربوط به پرداخت سود نیز به سودآوری شرکت‌ها بستگی دارد (لو، ۱۹۸۹).

برای دارندگان اوراق قرضه و اعتباردهندگان نیز پیش‌بینی سودهای آینده شرکت‌ها اهمیت دارد. برای اعتبار دهندگان موضوع مهم در خصوص اعطای وام و اعتبار، توان‌گیرنده برای بازپرداخت اصل و بهره وام و اعتبارات دریافتی می‌باشد. با داشتن قدرت پیش‌بینی سودآوری شرکت، آنها با قدرت بیشتری در مورد احتمال دریافت بازده سالانه و اصل وام خود تصمیم‌گیری خواهند کرد (کردستانی، ۱۳۸۲).

در رابطه با سود هر سهم، اکثر روشهایی که تاکنون مورد استفاده قرار گرفته، در دسته روشهای خطی قرار می‌گیرند. لکن طی سالهای اخیر مطالعاتی انجام شده که در آنها بر ماهیت غیرخطی بودن اطلاعات مالی تأکید شده است (فروغی و همکاران، ۱۳۹۲). به عنوان مثال کالن و همکاران (۱۹۹۶) بیان می‌کنند که سود هر سهم فصلی دارای ماهیت غیرخطی است و بنابراین استفاده از روش‌های خطی برای پیش‌بینی آن مناسب نخواهد بود. بدین ترتیب، تعداد زیاد روش‌های پیش‌بینی و ناشناخته بودن عوامل موثر بر بازگشت ثروت، موجب عدم اطمینان سرمایه‌گذاران و اعتباردهندگان شده است. به همین دلیل سعی در روی آوردن به روشهایی در پیش‌بینی دارند که بواسطه آنها، تخمین‌های شان به واقعیت نزدیک‌تر و خطایشان کمترین مقدار ممکن باشد. در میان روشهای پیش‌بینی، پیش‌بینی به کمک مدل‌های خطی سری زمانی مانند روش ARIMA^۲ و مدل‌های غیرخطی شبکه عصبی از انواع اصلی روشهای کمی پیش‌بینی می‌باشند (کاو و پاری، ۲۰۰۹). سری زمانی دنباله‌ای از مشاهدات منظم شده یک متغیر برحسب زمان است. سری‌های زمانی فقط از سابقه تاریخی متغیر (متغیرها) استفاده می‌کنند تا مدلی برای پیش‌بینی بدست آید. در

مدلهای تک متغیری سری زمانی، جهت رسیدن به الگویی برای داده‌ها، داده‌های مربوط به گذشته متغیر موردنظر مورد تجزیه و تحلیل قرار می‌گیرد و سپس با این فرض که الگوی بدست آمده تا آینده ادامه خواهد داشت، جهت پیش‌بینی مورد استفاده قرار می‌گیرد. شبکه‌های عصبی نیز اخیراً در بسیاری از زمینه‌های کاربردی استفاده شده‌اند اما به کارگیری آن برای پیش‌بینی سود فصلی هر سهم به صورت سری زمانی در کشور ما بی سابقه بوده است. هدف این پژوهش، مقایسه قدرت پیش‌بینی سود سه ماهه شرکت‌های بورس اوراق بهادار تهران، با استفاده از روش‌های سری‌های زمانی میانگین خود برگشتی جامع متحرک^۳ و شبکه‌های عصبی مصنوعی می‌باشد.

۲- مبانی نظری و مروری بر پیشینه پژوهش سود فصلی و اهمیت آن

گزارش‌های مالی میان‌دوره‌ای، نیازهای اطلاعاتی طیف گسترده‌ای از استفاده‌کنندگان را پوشش می‌دهد و ابزار مهمی برای مطلع ساختن سهامداران و دیگر گروه‌های علاقمند از عملکرد جاری واحد تجاری، به صورتی پیوسته و بهنگام می‌باشد. استفاده‌کنندگان اصلی صورتهای مالی میاندوره‌ای، همان استفاده‌کنندگان صورتهای مالی سالانه هستند که عبارتند از: سرمایه‌گذاران، اعتباردهندگان و سایرین. با توجه به تنوع گسترده نیازهای اطلاعاتی، دستیابی به تعادل مناسب بین خواستها و منافع متعدد ناهم‌ساز، به طور اجتناب‌ناپذیر، مستلزم داوری است. به علاوه، درک چگونگی استفاده از گزارشهای مالی میان‌دوره‌ای به ایجاد تعادل یاد شده کمک می‌کند.

سال مالی، به طور معمول به عنوان دوره اصلی گزارشگری مالی شناخته می‌شود. از نقطه‌نظر توان سودآوری، سودهای میان‌دوره‌ای به عنوان گزارش‌های پیشرفت کار در طول یک سال مالی به حساب می‌آیند. سرمایه‌گذاران و اعتباردهندگان، معمولاً از اطلاعات تاریخی و جاری برای ارزیابی چشم‌اندازهای آینده کمک می‌گیرند. تصمیم‌های اعتباری و سرمایه‌گذاری منعکس‌کننده انتظارات مربوط به عملکرد آینده است که تا حدودی بر ارزیابی عملکرد گذشته مبتنی است. از آنجا که سودهای گزارش شده در صورت سود و زیان میاندوره‌ای به روزترین منبع اطلاعاتی موجود درباره عملکرد گذشته است، در نتیجه می‌توان پذیرفت، اولین فایده سودهای گزارش شده میاندوره‌ای، ارزیابی به موقع عملکرد گذشته و کمک به پیش‌بینی نتایج آینده است (آقایی و احمدیان، ۱۳۹۲). همچنین شرکت‌ها برای رعایت مقررات بازار سرمایه، سودهای فصلی را گزارش می‌کنند. استاندارد حسابداری شماره ۲۲ ایران، تهیه صورتهای مالی میان‌دوره‌ای، چه به صورت فشرده و چه به صورت کامل را در صورتی که بموقع و قابل اتکا باشد، مفید دانسته، بیان می‌دارد که این گزارش‌ها اطلاعات مفیدی را در رابطه با توان کسب سود، ایجاد جریان‌های نقدی، شرایط مالی و نقدینگی واحد تجاری برای استفاده‌کنندگان ارائه می‌کند (استانداردهای حسابداری ایران، ۱۳۸۶).

مدل غیرخطی، شبکه‌های عصبی

اگرچه مدل‌سازی‌های ریاضی برای حل مشکلات و کشف قوانین حاکم بر طبیعت کاربرد فراوانی داشته‌اند اما این مدل‌سازی‌ها تا حد زیادی تابع پیش فرض‌های قبلی و محدود به روابط خطی هستند که باعث شده‌اند تا کامپیوترهای مجهز به فنون الگوریتمی به رغم آن که از سرعت و دقت بسیار زیادی برخوردارند اما از حل بسیاری از مسائل پیچیده، غیرخطی و یا بی‌نظمی عاجز بمانند. الگوسازی و حل چنین مسائلی، با توجه به شیوه عملکرد مغز انسان به راحتی امکان‌پذیر است. شبکه‌های عصبی مصنوعی، جنبه ریاضی فرآیند بیولوژیکی شبکه عصبی طبیعی (ANN) را نشان می‌دهد که در آن، نرون‌ها عناصر ریاضی پردازشگر در نظر گرفته می‌شوند. شبکه‌های عصبی سیستم‌های پویایی هستند که با پردازش داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کنند. به همین خاطر به این سیستم‌ها، هوشمند می‌گویند؛ چرا که بر اساس محاسبات روی داده‌های عددی یا مثال‌ها، قوانین کلی را فرا می‌گیرند (هولناگل، ۱۹۸۹). این سیستم‌های مبتنی بر هوش محاسباتی سعی در مدل‌سازی ساختار نرو-سیناپتیکی مغز بشر دارند. نقش شبکه عصبی، ایجاد تابعی است که هر الگوی ورودی را به یک الگوی خروجی ارتباط می‌دهد. شبکه‌های عصبی علاوه بر ارائه پیش‌بینی‌های دقیق‌تر، مشکلات رایج مدل‌سازی کلاسیک از قبیل پایایی و ناپایایی سری‌های زمانی را ندارند و از این نظر همانند مدل‌سازی کلاسیک، جهت رفع مشکلات خود همبستگی، هم‌خطی و ناهمسانی واریانس، نیازمند آماده‌سازی سربهای زمانی متغیرهای مالی نیستند (خالوزاده و خاکی، ۱۳۸۲). یک شبکه عصبی مصنوعی از تعداد زیادی گره و پاره خط‌های جهت‌دار که گره‌ها را به هم ارتباط می‌دهند، تشکیل شده است. گره‌هایی که در لایه ورودی هستند، گره‌های حسی و گره‌های لایه خروجی، گره‌های پاسخ‌دهنده نامیده می‌شوند. بین نرون‌های ورودی و خروجی نیز نرون‌های پنهان قرار دارند. اطلاعات از طریق گره‌های ورودی به شبکه وارد می‌شود، سپس از اتصالات به لایه‌های پنهان متصل شده، در نهایت خروجی شبکه از گره‌های لایه خروجی به دست می‌آیند. این مراحل مشابه شبکه عصبی بیولوژیکی انسان است.

معمولاً، پردازش اولیه روی تصاویر ورودی در شبکه عصبی (ANN) به وسیله یک تابع مجموع صورت می‌گیرد. خروج نرون‌ها به صورت یک تابع انتقال مدل می‌شود و نیروی سیناپتیک هر اتصال به عنوان وزن آن اتصال در شبکه عصبی مصنوعی در نظر گرفته می‌شود و تغییر این وزن، همان یادگیری در شبکه است. مبنای اصلی شبکه عصبی مصنوعی این است که کلید اصلی درک رفتار مغز انسان به عنوان یک سیستم پردازش اطلاعات در درک چگونگی ارتباط و اتصال نرون‌ها با یکدیگر است.

شبکه پرسپترون چندلایه (Multilayer Perceptron (MLP Model)

بعد از آن که در دهه ۸۰ میلادی مجدداً شبکه‌های عصبی احیا شدند؛ شبکه پرسپترون چند لایه و یا MLP، به عنوان یکی از کارآمدترین آنها در حل مسایل لاینحل غیرخطی مطرح شد. این شبکه به خصوص در زمینه پیش‌بینی متغیرهای مالی و اقتصادی از قابلیت پیش‌بینی بالایی برخوردار می‌باشد. هدف این

نوع شبکه‌های عصبی، کوشش برای ساخت الگوهایی است که همانند مغز انسان عمل می‌کنند. کار آن ایجاد یک الگوی خروجی بر اساس الگوی ورودی ارائه شده به شبکه است. ساختار ساده این مدل متشکل از تعدادی عناصر پردازشی (نرون‌های مصنوعی) می‌باشند که این نرون‌ها درون داده‌ها را دریافت و پردازش می‌کند و در نهایت، برونداد از آن ارائه می‌دهد. درون‌داد می‌تواند داده‌های خام یا برونداد دیگر عناصر پردازشی باشد. برونداد می‌تواند محصول نهایی یا درون‌دادی برای یک نرون دیگر باشد. عملکرد این شبکه را می‌توان با روابط زیر مدل کرد:

$$a_j^1(t) = F \left(\sum_{i=1}^r w_{i,j}^1 P_i(t) + b_j^1 \right) \quad 1 \leq j \leq S_1 \quad (1)$$

$$a_k^2(t) = G \left(\sum_{j=1}^{S_1} w_{k,j}^2 a_j^1(t) + b_k^2 \right) \quad 1 \leq k \leq S_2 \quad (2)$$

که در آن

R تعداد سیگنال‌های ورودی

P بردار ورودی

W_1, W_2 به ترتیب ماتریس وزن لایه مخفی و لایه خروجی

S_1, S_2 به ترتیب تعداد نرونهای لایه مخفی و خروجی

b_1, b_2 به ترتیب بردار بایاس لایه مخفی و لایه خروجی

a_1, a_2 به ترتیب بردارهای خروجی لایه مخفی و لایه خروجی

F, G به ترتیب تابع فعالیت نرونهای لایه مخفی و لایه خروجی را نشان می‌دهد. جهت آموزش این شبکه از الگوریتم BP استفاده می‌گردد.

شبکه‌های پرسپترون چند لایه معماری از شبکه‌های عصبی مصنوعی می‌باشد که پیشخور بوده و پردازنده‌های شبکه به چند لایه مختلف تقسیم شوند. در این شبکه‌ها لایه اول، ورودی، لایه آخر، خروجی و لایه‌های میانی، لایه‌های پنهان نامیده می‌شوند. شبکه پرسپترون چندلایه رایج‌ترین و پرکاربردترین نوع از انواع شبکه‌های عصبی است و دلیل آن نیز قدرت این شبکه‌ها در تخمین نگاشت‌های پیچیده خطی و غیرخطی می‌باشد.

مدل خطی، روش میانگین خود برگشتی جامع متحرک^۵

بسیاری از روش‌های آماری به بررسی مدل‌هایی می‌پردازند که فرض زیر بنایی آنها استقلال مشاهدات است. این درحالیست که اکثر داده‌های مربوط به علوم طبیعی، مهندسی، تجارت و اقتصاد به صورت سری-های زمانی رخ می‌دهند که پیوستگی مشاهدات در آنها امری بدیهی است. فرض بنیادین روش‌شناسی ARIMA این است که مشاهدات مربوط به یک سری زمانی مستقل نبوده و به صورت متوالی بهم وابسته هستند و این وابستگی بین داده‌های متوالی در زمان‌هایی با فواصل مساوی اندازه‌گیری می‌شوند و مورد

توجه قرار می‌گیرند (لورک و ویلینگر، ۲۰۰۸). این روش توسط جی. ای. پی باکس و جی. ام جنکینز به منظور تجزیه و تحلیل سری‌های زمانی مطرح شده و از طریق یک شناسایی تکراری، برآورد و فرآیند تشخیص بقرار زیر پدید می‌آید:

مرحله اول: شناسایی

مدل دوره زمانی تنها بر داده ایستایی کاربرد دارد. در صورتیکه داده ایستایی نباشد، می‌تواند با متمایز کردن داده اولیه ایستایی شود. بمنظور ایمنی از اینکه داده، ایستایی است، شخص می‌تواند طرح دوره زمانی پرداخت نشده یا عملکرد خود برگشتی دوره را بررسی و بازبینی نماید.

مرحله دوم: برآورد

پس از مرحله شناسایی به تخمین پارامترهای مدل پرداخته می‌شود. گاهی اوقات برای تخمین پارامترها از روش حداقل مربعات استفاده می‌شود. اما زمانی که مدل نسبت به پارامترها، غیرخطی باشد به روشهای تخمین غیرخطی متوسل می‌شوند.

مرحله سوم: روند تشخیص

در این مرحله با انجام آزمون ایستایی در مورد باقیمانده‌های مدل ARIMA، مدل از لحاظ خوبی برازش کنترل می‌شود. اگر نامناسب بودن مدل به اثبات برسد مدل باید مورد تعدیل و اصلاح قرار گیرد. روش‌های تشخیص برای تصمیم‌گیری چگونگی اصلاح کردن و بهبود مدل بکار می‌رود.

مرحله چهارم: پیش‌بینی:

در این مرحله با استفاده از مدل نهایی به دست آمده به پیش بینی کوتاه مدت سریهای زمانی مورد بررسی پرداخته خواهد شد. در بسیاری از موارد، پیش‌بینی‌های حاصل از مدل‌های ARIMA به ویژه برای کوتاه‌مدت است و بیش از روش مدلسازی سنتی اقتصاد سنجی، قابل اتکا می‌باشد (ابریشمی، ۲۰۰۹). باید توجه داشت که روش شناسی ARIMA یک روش تکرار می‌باشد. بدین ترتیب که اگر مدل آزمایشی تشخیص داده شده نامناسب تلقی شود، دوباره به مرحله تشخیص آزمایشی بازگشته و مدل جدید و بهتری را بدست آورده سپس پارامترهای مدل جدید را تخمین و مناسب بودن آن بررسی می‌شود. این سیکل تشخیص آزمایشی، تخمین و تشخیص دقت برازش تا زمانی که مدل مناسب نهایی یافت شود، ادامه خواهد داشت و در آخر امر مدل نهایی بدست آمده به منظور پیش بینی مقادیر آینده سری زمانی به کار خواهد رفت (آقایی و احمدیان، ۱۳۹۲). روش شناسی ARIMA هم برای داده‌های مقطعی و هم داده‌های پیوسته و هم داده‌های ناپیوسته قابلیت پیش بینی دارد. از این رو داده‌ها باید در فواصل زمانی برابر اندازه گیری شوند. بعلاوه، روش شناسی ARIMA می‌تواند برای پیش بینی داده‌های فصلی و غیر فصلی مورد استفاده قرار گیرد. انعطاف‌پذیری این روش باعث شده است که کاربرد آن در عرصه اقتصاد و صنعت بیش از پیش باشد و بر سایر مدل‌های پیش‌بینی غالب شود. پیشرفت تکنولوژی رایانه نیز به کاربران اجازه داده است از مدل‌های پیچیده ARIMA استفاده کنند.

پیشینه پژوهش

ژانگ و همکاران (۲۰۰۴) در پژوهش خود، دقت پیش‌بینی مدل‌های خطی یک متغیره و چند متغیره را با دقت شبکه‌های عصبی در پیش‌بینی سود هر سهم مقایسه کردند. آنها در مدل‌های چند متغیره خود از متغیرهای بنیادی حسابداری استفاده کردند. یافته‌های این مطالعه نشان داد که کاربرد رویکرد شبکه‌های عصبی شامل متغیرهای بنیادی حسابداری، نسبت به مدل‌های خطی از دقت پیش‌بینی بالاتری برخوردار است (ژانگ و همکاران، ۲۰۰۴).

کائو و گان (۲۰۰۹) برای پیش‌بینی سود هر سهم، متغیرهای مورد استفاده در پژوهش ژانگ را مورد بررسی قرار دادند. آنها برای پیش‌بینی، از شبکه‌های عصبی و الگوریتم ژنتیک استفاده کردند و به این نتیجه رسیدند که مدل شبکه‌های عصبی با وزن‌های برآورد شده به وسیله الگوریتم ژنتیک، عملکرد مناسب‌تری نسبت به مدل شبکه‌های عصبی با وزن‌های برآورد شده به وسیله الگوریتم پس‌انتشار در پیش‌بینی سود هر سهم دارد.

کاو و پاری (۲۰۰۹) در مطالعه‌های، دقت پیش‌بینی روش‌های خطی یک متغیره و چند متغیره را با شبکه‌های عصبی در پیش‌بینی سود هر سهم مورد مقایسه قرار دادند. آنها در مدل شبکه‌های عصبی جهت تخمین وزن‌ها از الگوریتم پس‌انتشار خطا و الگوریتم ژنتیک استفاده کردند. نتایج بررسی‌ها نشان داد که مدل شبکه‌های عصبی مبتنی بر الگوریتم ژنتیک که شامل متغیرهای بنیادی حسابداری است، نسبت به مدل شبکه‌های عصبی مبتنی بر الگوریتم پس‌انتشار خطا و مدل‌های خطی، از دقت پیش‌بینی بیشتری برخوردار است (کاو و پاری، ۲۰۰۹).

لای و لی (۲۰۰۶) به مقایسه توانایی پیش‌بینی میان مدل میانگین خود برگشتی جامع متحرک (ARIMA)، مدل عملکرد انتقال، مدل شبکه‌های عصبی مصنوعی و مدل الگوریتم زادشناختی پرداخته‌اند. بمنظور ارزیابی دقت و صحت پیش‌بینی، دو بُعد ملاحظه شده است: (الف) انحراف مابین ارزش واقعی سود سه ماهه هر سهم و ارزش پیش‌بینی شده سود سه ماهه هر سهم و (ب) مسیر تغییرات سه ماهه به سه ماه میان ارزش واقعی سود سه ماهه هر سهم و ارزش پیش‌بینی شده سود سه ماهه هر سهم. نتایج حاکی از آن بود که اولاً مدل‌های غیرخطی خطای کمتری نسبت به مدل‌های خطی دارند و از میان مدل‌های غیرخطی نیز، مدل الگوریتم زادشناختی از بهترین دقت و صحت پیش‌بینی هم برای سود پایه‌ای هر سهم و هم سود کاهش یافته هر سهم برخوردار است؛ در حالیکه مدل شبکه‌های عصبی مصنوعی کمترین دقت و صحت پیش‌بینی در هر دو سود پایه‌ای هر سهم و سود کاهش یافته هر سهم را داشته است.

فروغی و همکاران (۱۳۹۲) به پیش‌بینی سود هر سهم با ترکیب شبکه‌های عصبی مصنوعی و الگوریتم بهینه‌سازی حرکت تجمعی ذرات پرداختند. بدین منظور از اطلاعات مربوط به ۱۱۴ شرکت از شرکتهای پذیرفته شده در بورس اوراق بهادار تهران، طی سالهای ۱۳۸۰ تا ۱۳۸۹ استفاده شده است. نتایج این پژوهش نشان می‌دهد که مدل تک متغیره بادقت ۷۸٪ و مدل چند متغیره با دقت ۹۱٪ سود هر سهم را پیش‌بینی می‌نمایند.

انواری رستمی و همکاران (۱۳۹۲) الگوسازی و پیش بینی سود هر سهم شرکت های پذیرفته شده در بورس اوراق بهادار تهران با رویکرد شبکه عصبی GMDH پرداختند. ابتدا الگویی شامل هشت نسبت مالی طراحی و سپس با استفاده از فرآیند قیاسی و نیز کنار گذاشتن هر متغیر از الگوی بنیادی، در مجموع هشت مدل اجرا شد. نتایج نشان داد، الگوهای حاصل از کنار گذاشتن بازده دارایی ها، نسبت جاری و بازده سرمایه از الگوی بنیادی، به ترتیب بیشترین تأثیر را در کاهش خطای پیش بینی سود هر سهم دارند. همچنین گردش موجودی کالا و دوره وصول مطالبات، دارای اثر مضاعف در کاهش خطا هستند.

آقایی و همکاران (۱۳۹۱) به بررسی میزان محتوای اطلاعاتی موجود در اعلان سودهای فصلی شرکت ها برای تأمین نیازهای اطلاعاتی ذینفعان در بورس اوراق بهادار تهران پرداختند. به منظور محاسبه میزان محتوای اطلاعاتی موجود در اعلان سودهای فصلی، از ضریب تعیین به دست آمده از رگرسیون بازده سالانه به بازده های مربوط به چهار فصل سال در پنجره رویداد هفت روزه ناشی از اعلان های فصلی سود استفاده شده است. در ادامه نیز به بررسی عوامل موثر بر این محتوای اطلاعاتی پرداخته شد. بدین منظور داده های مالی مربوط به ۱۰۶ شرکت برای دوره زمانی بین سال های ۱۳۸۵ تا ۱۳۸۹ مورد تجزیه و تحلیل قرار گرفت. نتایج بدست آمده نشان داد که اعلان های فصلی سود بطور متوسط ۹ تا ۱۷ درصد از کل اطلاعات سالانه تأثیرگذار بر قیمت سهام شرکت ها را تشکیل می دهد.

۳- فرضیه پژوهش

فرضیه پژوهش: پیش بینی سود فصلی هر سهم با استفاده از رویکرد غیرخطی شبکه پرسپترون چند لایه (MLP) نسبت به مدل خطی ARIMA با خطای کمتری همراه است.

۴- روش شناسی پژوهش

در این پژوهش، جامعه مورد بررسی شرکت های پذیرفته شده در بورس اوراق بهادار تهران می باشد. داده های مورد نیاز با استفاده از اطلاعات و مدارک موجود و از طریق نرم افزارهای بورس اوراق بهادار از بانک های اطلاعاتی «رهاورد نوین» استخراج شده است. برای انتخاب نمونه تحقیق، شرکت هایی به عنوان نمونه انتخاب می شوند که شرایط ذیل را احراز نمایند:

- ۱) شرکت های مورد بررسی می بایست دارایی اعلان سود فصلی باشند.
 - ۲) شرکت ها جزء شرکت های فعال بورس بوده و یا حداقل در روزهای مورد بررسی فعال باشند.
 - ۳) شرکت ها در بازه زمانی مورد بررسی، افزایش سرمایه نداشته باشند.
 - ۴) از جامعه آماری تحقیق بانک ها، شرکت های بیمه، شرکت های هلدینگ و شرکت های سرمایه گذاری به دلیل ماهیت متفاوت آنها حذف گردیدند.
- با در نظر گرفتن همه شرایط بالا ۶۷ شرکت برای دوره زمانی سالهای ۸۶ تا ۹۱ انتخاب شدند.

در این مطالعه داده‌های جمع‌آوری شده با روش سری زمانی آریمایا و مدل شبکه‌های عصبی مصنوعی مورد تجزیه و تحلیل قرار گرفت. در هر دو مدل ARIMA و MLP، ۷۵٪ مشاهدات به آموزش و ۲۵٪ مشاهدات به آزمون اختصاص داده شد. هم‌چنین، جهت طراحی مدل ARIMA از نرم‌افزار Eviews و برای طراحی مدل NNA از نرم‌افزار Matlab2011a استفاده شده است. به منظور بررسی کارایی مدل‌های پیش‌بینی سری‌های زمانی، از معیارهای (MAE)، (MAPE) و (RMSE) استفاده شده است (هایکان، ۱۹۹۴). (MAE)، میانگین مطلق انحراف مابین پیش‌بینی سه ماهه سود هر سهم و سود واقعی هر سهم است و شیوه محاسبه آن به شکل زیر می‌باشد:

$$MAE = \frac{\sum_{t=1}^N |EPS_t - \overline{EPS}_t|}{N} \quad (3)$$

(MAPE) که عبارت از میانگین مطلق درصد انحراف مابین پیش‌بینی سه ماهه سود هر سهم و سود واقعی هر سهم است به شکل زیر محاسبه می‌شود:

$$MAPE = \frac{\sum_{t=1}^N \left| \frac{EPS_t - \overline{EPS}_t}{EPS_t} \right|}{N} \quad (4)$$

(RMSE) نیز مربع مجذور میانگین خطای استاندارد مابین پیش‌بینی سه ماهه سود هر سهم و سود واقعی هر سهم است و به شکل زیر محاسبه می‌شود:

$$RMSE = \sqrt{\frac{\sum_{t=1}^N (EPS_t - \overline{EPS}_t)^2}{N}} \quad (5)$$

در هر سه فرمول شماره (۱)، (۲) و (۳) بالا:

- EPS_t ارزش سود سه ماهه واقعی هر سهم در زمان t است.
- \overline{EPS}_t ارزش سود سه ماهه پیش‌بینی شده هر سهم در زمان t است.
- N تعداد مشاهدات است

با استفاده از ۳ معیار فوق، دقت مدل‌های پیش‌بینی مقایسه خواهند شد. واضح است که برای هر یک از معیارهای فوق، مقدار بهینه کمترین آن و بهینه‌ترین مقدار، صفر است.

بررسی کارایی مدل ARIMA در پیش‌بینی سودهای فصلی هر سهم

سه مدل اولیه و مهم میانگین خود برگشتی جامع متحرک توسط محققان پیشنهاد شده است. نخستین مدل، مدل براون-روزف است که گوناگونی‌های فصلی و میانگین متحرک فصلی را یکپارچه می‌نماید (براون و روزف، ۱۹۷۹). مدل دوم، مدل واتس-گریفن است، مدلی که میانگین‌های فصلی متفاوت و متحرک را دربردارد (واتس، ۱۹۷۵؛ گریفن، ۱۹۷۷). و مدل فوستر، یک مدل خود برگشتی با شرط حرکت تدریجی است (فوستر، ۱۹۷۷). از سه مدل مزبور، مدل متنوع میانگین خود برگشتی جامع متحرک براون-روزف

نشان داده است که از سایر مدل‌های متنوع بیشتر اجرا می‌شود (لوبو و نیر، ۱۹۹۰). علاوه بر این، این مدل یکی از بهترین مدل‌های ریاضی در زمینه پیش بینی سود سه ماهه هر سهم محسوب می‌شود. براون و روزف (۱۹۷۹) مدارکی ارائه دادند که حاکی از آن است که مدل فوستر بدلیل آنکه کاملاً نمی‌تواند موارد فصلی را توجیه نماید، بطور بالقوه و بقدر کافی مشخص نیست لیکن پیشنهاد می‌نمایند که با افزودن یک پارامتر میانگین متحرک فصلی، مسئله را می‌توان برطرف نمود. ضعف مدل فوستر، براون و روزف را وادار می‌نماید که یک پارامتر میانگین فصلی متحرک به ساختار فوستر بیافزایند و مدل براون و روزف را به بار می‌آورند. این مسئله احتمال دارد بطور جزئی توضیح دهد در مطالعه لوبو و نایر (۱۹۹۰) به چه دلیل مدل براون و روزف بر مدل فوستر تسلط دارد.

در این مطالعه، مدل براون - روزف بدلیل اهمیت و آوازه آن در پیش بینی سود سه ماهه هر سهم، اتخاذ گردیده است. شکل خاص ساختاری مدل براون - روزف در زیر ارائه شده است:

$$E(Q_t) = Q_{t-4} + \alpha_1(Q_{t-1} - Q_{t-5}) - \theta_1 a_{t-4} \quad (۶)$$

در جاییکه

Q_t = سود سه ماهه هر سهم در زمان t است،

α_1 = پارامتر خود برگشتی،

θ_1 = پارامتر میانگین فصلی متحرک،

a_{t-4} = شرط اختلال در زمان $t-4$ است.

پیش بینی‌های سه ماهه سود هر سهم حاصل از مدل براون - روزف بر مبنای روش کالن (۱۹۹۶) ایجاد و فرآوری شده است. برای هر ۶۷ شرکت نمونه، ۴۰ دوره زمانی سود سه ماهه هر سهم در شکل‌گیری نمونه - های فعال ۴۰ دوره سه ماهه، گروه بندی شده اند. با توجه به این نکته که داده سود سه ماهه، فصلی هستند، نمونه نخست از ۴۰ نقاط داده در اخذ ارزش‌های پیش بینی سود هر سهم چهار دوره سه ماهه بعد برای مثال Q41, Q42, Q43, Q44 بکار گرفته شده اند. متشابهاً، نمونه فعال دوم سود سه ماهه هر سهم، از داده دوره های سه ماهه ۵ تا ۴۴ استفاده کرده است و ارزشهای پیش بینی سود هر سهم چهار دوره سه ماهه بعد برای مثال Q45, Q46, Q47, Q48 گردآوری شده است. بنابراین، با توجه به نمونه، هشت دوره وجود دارد که بطور کلی در سنجش این امر که کدام مدل در پیش بینی سود هر سهم دارای اجرای بهتری است، مورد استفاده قرار می‌گیرد (سیونچینگ و هونگچی، ۲۰۰۶).

به منظور بررسی کارایی مدل ARIMA در پیش بینی سریهای زمانی مذکور، ابتدا ایستایی سری با استفاده از آزمون دیکی فولر (DF) و دیکی فولر تعمیم یافته (ADF) بررسی شده است. آزمون دیکی فولر بر اساس سه معادله زیر انجام می‌شود:

$$\Delta y_t = \delta \cdot y_{t-1} + u_t \quad (۷)$$

$$\Delta y_t = \delta \cdot y_{t-1} + u_t + \beta_1 \quad (۸)$$

$$\Delta y_t = \delta \cdot y_{t-1} + u_t + \beta_1 + \beta_2 t \quad (9)$$

هم چنین ایستایی سری با استفاده از آزمون دیکی فولر تعمیم یافته با استفاده از معادله رگرسیونی زیر بررسی می‌شود:

$$(10) \Delta y_t = \delta \cdot y_{t-1} + u_t + \beta_1 + \beta_2 t + \alpha \Delta y_{t-1}$$

جهت بررسی ایستایی سری زمانی فرضیه زیر آزمون شده است:


$$\begin{cases} H_0 : \delta = 0 \\ H_1 : \delta < 0 \end{cases}$$

مقادیر بدست آمده از آزمون فرضیه بالا برای هر چهار مدل شماره (۷) (۸) (۹) (۱۰) بالا حاکی از آن است که با توجه به مقادیر به دست آمده از آزمون دیکی فولر و دیکی فولر تعمیم یافته، سری زمانی مورد مطالعه خود به خود ایستا است و دارای ریشه واحد نمی‌باشد و مقدار $d=0$ است و بدین ترتیب می‌توان از سری زمانی $(ARIMA(p,d,q))$ استفاده کرد. بعد از مرحله تشخیص، نوبت به تخمین مدل و محاسبه p و q می‌رسد. برای به دست آوردن مقادیر مذکور از نمودارهای خودهمبستگی (ACF) و خود همبستگی جزئی (PACF) استفاده شده است. برای به دست آوردن بهترین مدل، نمودار خودهمبستگی و خودهمبستگی جزئی را برای مقادیر باقیمانده سری زمانی (تفاضل مقادیر واقعی از مقادیر حاصل از مدل) به ازای وقفه‌های مختلف رسم می‌شود. با توجه به نمودار خودهمبستگی و خودهمبستگی جزئی مقادیر باقیمانده، از میان تمام تخمین‌های ممکن، مدل $ARIMA(4,0,1)$ با داشتن کمترین میزان باقیمانده بهترین مدل به دست آمده است. حال به پیش‌بینی سری زمانی با استفاده از مدل $ARIMA(4,0,1)$ پرداخته می‌شود. همان گونه که در جدول شماره (۱) ملاحظه می‌شود؛ مقادیر به دست آمده برای معیارهای مربع مجذور میانگین خطای استاندارد (RMSE)، میانگین قدر مطلق خطا (MAE) و میانگین قدر مطلق درصد خطا (MAPE) دلالت بر کارایی بالای پیش‌بینی انجام شده دارد.

جدول ۱. کارایی مدل $ARIMA$ در پیش‌بینی سود فصلی هر سهم

MAPE	MAE	RMSE	ARIMA
۰/۲۴۴	۳۲/۸۱۸	۴۶/۱۶۶	ساختار (۴-۰-۱)

شکل زیر نیز مقادیر واقعی سری زمانی را در مقایسه با مقادیر حاصل از مدل آریمای نمایش می‌دهد.



شکل ۱. مقایسه مقادیر واقعی و مقادیر حاصل از مدل ARIMA

بسط مدل با استفاده از MLP

در این روش، ابتدا به انتخاب وقفه های زمانی تاثیرگذار و روزهای تاثیرگذار بر سود فصلی پرداخته می شود. این امر معادل انتخاب متغیرهای ورودی تاثیرگذار از بین مجموعه ای از متغیرها است. یکی از روش های متداول انتخاب متغیرها روش انتخاب ترتیبی متغیرهاست (SFS). این روش شامل دو بخش است:

- یک تابع هدف که معیار نامیده می شود. معیارهای متداول، خطای میانگین مربع و نرخ دسته بندی نادرست است که به ترتیب مربوط به مدل های رگرسیونی و مدل های طبقه بندی هستند.
- الگوریتم جستجوی ترتیبی که متغیرها را با ارزیابی معیار از یک زیر مجموعه در نظر گرفته شده کم می کند یا بدان می افزاید.

این روش بردو نوع است:

- انتخاب پیشروی ترتیبی که در آن متغیرها به صورت ترتیبی به یک مجموعه خالی اضافه می شوند تا جایی که افزودن متغیرهای بیشتر باعث کاهش معیار نشود.
- انتخاب پسروی ترتیبی که در آن متغیرها به صورت ترتیبی از یک مجموعه کامل حذف می شوند تا جایی که حذف متغیرهای بیشتر، معیار را افزایش دهد.

در این تحقیق از روش انتخاب پسروی ترتیبی از جعبه ابزار آماری نرم افزار MATLAB جهت انتخاب وقفه های زمانی تاثیرگذار استفاده شده و رابطه سود سهام بصورت کلی زیر به دست آمده است.

$$x(t) = f \{x(t-1), x(t-2), x(t-3), x(t-4)\}$$

رابطه ۱۱

در معادله بالا، $x(t)$ نشان دهنده سود فصلی است و رابطه بالا بیانگر این موضوع است که در مدل شبکه عصبی سود هر دوره از سود ۴ دوره قبل تاثیر می‌پذیرد. باید توجه داشت رابطه به دست آمده صرفاً برای داده‌های مورد استفاده در این تحقیق اعتبار دارد و به هیچ عنوان یک رابطه کلی نیست. برای آنالیز، از جعبه ابزار شبکه عصبی در نرم افزار MATLAB برای ساخت مدل‌ها استفاده شده است. جعبه ابزار شبکه عصبی در MATLAB وزنه‌های اولیه را در هر مرتبه از اجرا بطور اتفاقی تعیین می‌کند (مت ورک، ۲۰۰۷). این مسئله باعث می‌شود عملکرد شبکه آموزش دیده حتی وقتی تمام پارامترها و ساختار شبکه ثابت نگه داشته شده است بشدت تغییر کند. در نتیجه، رسیدن به ترکیب بهینه شبکه و تنظیم پارامترها دشوار است. برای حل این مشکل برنامه‌ای (کد) در محیط MATLAB نوشته شده است که فرآیند سعی و خطا را بطور خودکار بکار می‌برد. برنامه مذکور عددهای گوناگونی را برای لایه‌ها و نرون‌ها در لایه پنهان برای اپوک ثابتی چندین بار امتحان می‌کند و از بین پاسخ‌های به دست آمده بهترین پاسخ ارائه می‌شود (جدول شماره ۲).

اطلاعات موجود به دو دسته آموزش و آزمایش تقسیم شده‌اند. از میان ۴۰۰ داده، ۳۰۰ داده جهت آموزش و ۱۰۰ داده جهت آزمایش در نظر گرفته شده است. در مطالعه حاضر بهترین نتایج با استفاده از روش پس انتشار گوسی- نیوتن (trainbfg) به دست آمده است، هم چنین تابع هیپربولیک تانژانت سیگموئید (tansig) بعنوان تابع انتقال بین لایه‌های ورودی و پنهان و تابع انتقال خطی به عنوان تابع انتقال بین لایه‌های پنهان و خروجی انتخاب شده‌اند. توابع سیگموئید خروجی را بین -۱ و ۱ نگه می‌دارند. نرمالیزاسیون ورودی‌ها بین (+۱ و -۱) باعث افزایش سرعت آموزش می‌شود. از فرمول زیر برای نرمالیزه کردن ورودی‌های مدل استفاده شده است.


$$X_n = -1.0 + 2.0 \frac{X_i - X_{i,\min}}{X_{i,\max} - X_{i,\min}} \quad \text{رابطه ۱۲}$$

که در آن X_n عدد نرمالیزه شده از ورودی X_i است. X_{\max} و X_{\min} بترتیب نمایانگر کمترین و بیشترین مقادیر X_i می‌باشند. برای خروجی‌های مدل از نرمالیزاسیون غیرخطی استفاده شده است. بنابراین، خروجی‌ها بین ۰/۹ و ۱ با استفاده از فرمول زیر نرمالیزه شده‌اند.

$$Y_n = 0.1 + 0.8 \frac{\ln(Y_i) - \ln(Y_{i,\min})}{\ln(Y_{i,\max}) - \ln(Y_{i,\min})} \quad \text{رابطه ۱۳}$$

که در آن Y_n عدد نرمالیزه شده از ورودی Y_i است. Y_{\max} و Y_{\min} بترتیب نمایانگر کمترین و بیشترین مقادیر Y_i می‌باشند.

۴وقفه به دست آمده به عنوان ۴ متغیر مستقل، ورودی‌های مدل و سود فصلی به عنوان تنها خروجی مدل در نظر گرفته شده است. بنابراین لایه ورودی دارای ۴ نرون و لایه خروجی دارای یک نرون است. شکل زیر نمای پرسپترون چند لایه‌ای مورد استفاده در این مقاله را نشان می‌دهد.



شکل ۲. شبکه‌های پرسپترون چندلایه (MLP)

در مطالعه حاضر، پس از بارها آزمون و خطا از طرق تغییر موارد مذکور و آموزشهای فراوان، ساختاری که بهترین نتایج را بدست داده است شبکه‌ای با ۴ نرون در لایه ورودی و ۹ نرون در لایه پنهان (۹-۱-۴)، نرخ یادگیری ۰/۰۰۵ آپدیت شده با ضریب ۱/۰۵ بعد از هر اپوک، ممنوم معادل ۰/۰۹ آپدیت شده با ضریب ۰/۰۹ بعد از هر اپوک و آموزش دیده برای ۳۰۰۰ اپوک بوده است. در نهایت رابطه زیر برای پیش بینی سود هر سهم بدست آمده است:

$$Y = \frac{2}{1 + e^{0.025 + \sum_i \tanh(F_i) \times V_i}} - 1$$

رابطه ۱۴

$$F_i = x_1 \times W_{1i} + x_2 \times W_{2i} + x_3 \times W_{3i} + x_4 \times W_{4i} + Bias_i \quad i = 1, \dots, 9$$

رابطه ۱۵


در اینجا x ها بیانگر وقفه های مورد استفاده در مدل، i تعداد نرون های لایه پنهان و W_{4i}, \dots, W_{1i} وزنهای بین لایه ورودی و پنهان و v_i وزن بین لایه پنهان و خروجی است. نتایج بدست آمده برای روشهای ارزیابی عملکرد مدل شبکه‌های عصبی مصنوعی در جدول شماره (۲) نشان داده شده است. همانطور که در شکل ملاحظه می شود، شبکه در سیکل ۸ ام به بهترین جواب رسیده است و معیارهای کارایی این نتیجه در جدول شماره (۲) قابل مشاهده است. مقادیر بسیار پایین معیارهای مربع مجذور میانگین خطا (RMSE)،

میانگین قدر مطلق خطا (MAE) و میانگین قدر مطلق درصد خطا (MAPE) دلالت بر کارایی بالای پیش‌بینی انجام شده دارد.

جدول ۲. کارایی مدل شبکه پرسپترون چند لایه MLP در پیش‌بینی سود فصلی هر سهم

MAPE	MAE	RMSE	MLP
۰/۲۱۳	۲۲/۷۲۰	۳۲/۰۸۶	ساختار (۴-۹-۱)

شکل زیر نیز مقادیر حاصل از مدل MLP را در مقایسه با مقادیر واقعی سری زمانی نمایش می‌دهد.



شکل ۳. مقایسه مقادیر واقعی و مقادیر حاصل از مدل MLP

۵- مقایسه مدل‌ها

در این مطالعه کارایی مدل‌های ARIMA و شبکه پرسپترون چند لایه (MLP) در پیش‌بینی سود فصلی هر سهم مقایسه شد. نتایج مقایسه‌ای دو مدل ARIMA و MLP به طور خلاصه به صورت جدول شماره (۳) به دست آمد:

جدول ۳. نتایج مقایسه‌ای حاصل از روش MLP و ARIMA

MAPE	MAE	RMSE	روش
۰/۲۴۴	۳۲/۸۱۸	۴۶/۱۶۶	با ساختار ARIMA(۴-۰-۱)
۰/۲۱۳	۲۲/۷۲۰	۳۲/۰۸۶	با ساختار MLP(۴-۹-۱)

همان گونه که مشاهده می شود بر اساس همه معیارهای خطا، مدل شبکه پرسپترون چند لایه (MLP) بهتر از مدل ARIMA عمل کرده است. مقدار عددی هر سه معیار مربع مجذور میانگین خطا (RMSE)، میانگین قدر مطلق خطا (MAE) و میانگین قدر مطلق درصد خطا (MAPE) در مدل شبکه پرسپترون چند لایه (MLP) نسبت به مدل ARIMA کمتر بوده است و این نتایج نشان می دهد که MLP از عملکرد بهتری برای پیش بینی سود هر سهم نسبت به الگوی ARIMA برخوردار است.

۶- نتیجه گیری و بحث

سرمایه گذاران، اعتباردهندگان، مدیران، کارکنان در شرکت، تحلیلگران، دولت و دیگر استفاده کنندگان صورتهای مالی از سود سهام به عنوان مبنایی جهت اتخاذ تصمیمات سرمایه گذاری و تشکیل پرتفویهای سودآور، اعطای وام، سیاست پرداخت سود، ارزیابی شرکتهای محاسبه مالیات و سایر تصمیمات مربوط به شرکت استفاده می کنند. اطلاعات ارائه شده توسط شرکت و در نتیجه سود سهام، مبتنی بر رویدادهای گذشته شرکت است اما سرمایه گذاران، نیازمند اطلاعاتی راجع به آینده شرکت برای کاهش عدم اطمینان تصمیم گیری هایشان می باشند. در این میان روش هایی که بتوانند به بهترین نحو سود شرکت ها را پیش بینی کنند بهترین ابزار برای کاهش عدم اطمینان هستند. در این تحقیق ابتدا وقفه های تاثیرگذار بر سود سهام با استفاده از روش انتخاب متغیر ترتیبی (SFS) مشخص شده و سپس به مدل سازی شبکه پرسپترون (MLP) پرداخته شد. مدل MLP با یک لایه پنهان جهت مدل سازی انتخاب شد و مقادیر وزن ها و بایاس های مدل مشخص شدند و معیارهای ارزیابی عملکرد برای مدل غیرخطی MLP با ساختار (۱، ۹، ۴) مشخص شدند. سپس معیارهای RMSE، MAE و MAPE جهت ارزیابی عملکرد بهترین مدل ARIMA با ساختار (۱، ۰، ۴) ARIMA، محاسبه شدند. از مجموع شبیه سازی های انجام شده برای پیش بینی سود هر سهم بر مبنای مشاهدات تاریخی و به وسیله مدل های شبکه پرسپترون چند لایه (MLP) و ARIMA، نتایج به شرح زیر ارائه می شود:

این پژوهش نشان داد که ارتباط مستقیم و مثبتی بین سودهای فصلی دوره های قبلی با سود هر سهم فصل جاری وجود دارد. نتیجه کلی به دست آمده از این پژوهش این است که سری های زمانی سودهای قبلی، در پیش بینی سود فصلی هر سهم، دارای رابطه خطی و غیرخطی با سود هر سهم فصل جاری هستند و هر دو مدل (MLP) و ARIMA، روند مشابهی را برای سود فصلی هر سهم پیش بینی می کنند اما مقادیر معیارهای RMSE، MAE و MAPE در جدول (۳) نشان داد که مدل غیرخطی شبکه پرسپترون چند لایه (MLP) نسبت به مدل خطی ARIMA دقت بالاتر و عملکرد بهتری در پیش بینی سود هر سهم دارد و بنابراین فرضیه این تحقیق مبنی بر اینکه پیش بینی سود فصلی هر سهم با استفاده از رویکرد غیر خطی شبکه پرسپترون چند لایه (MLP) خطای پیش بینی کمتری نسبت به مدل خطی ARIMA دارد، تایید می شود. نتایج این تحقیق در خصوص توان بالای مدل های غیرخطی نسبت به مدل های خطی جهت پیش-

بینی سود سه ماهه هر سهم با نتایج تحقیق لای و لی (۲۰۰۶) مطابقت دارد. همچنین نتایج پژوهش ژانگ (۲۰۰۴) حاکی از برتری مدل‌های غیرخطی در پیش‌بینی سود سهام نسبت به مدل‌های خطی می‌باشد.

فهرست منابع

- * کردستانی، غلامرضا. (۱۳۸۲). تجزیه و تحلیل سری‌های زمانی سود در سطح صنعت. پیشرفت‌های حسابداری. شماره ۳۸، ص ۱۳۷-۱۵۰.
- * فروغی، داریوش، فروغ نژاد، حیدر، میرزایی منوچهر. (۱۳۸۲). پیش‌بینی سود هر سهم: ترکیب شبکه‌های عصبی مصنوعی و الگوریتم بهینه‌سازی حرکت تجمعی ذرات. دانش سرمایه‌گذاری. سال دوم، شماره ششم. ص ۶۳-۸۲.
- * آقای، محمد علی، احمدیان، وحید، دویران، فیروز. (۱۳۹۲). بررسی ویژگیها و توان پیش‌بینی سری‌های زمانی جریانهای نقدی عملیاتی میان دوره‌ای و جایگزین‌های آن. پیشرفت‌های حسابداری. دوره ۵ پنجم، شماره ۱ اول. ص ۱-۳۲.
- * خالوزاده، حمید، خاکی، علی. (۱۳۸۲). ارزیابی روش‌های پیش‌بینی قیمت سهام و ارائه مدلی غیرخطی بر اساس روش شبکه عصبی مصنوعی. تحقیقات حسابداری. شماره ۶۴، ص ۴۳-۸۵.
- * انواری رستمی، علی‌اصغر، آذر، عادل، نوروزی، محمد. (۱۳۹۲). الگوسازی و پیش‌بینی EPS شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران با رویکرد شبکه عصبی GMDH. بررسی‌های حسابداری و حسابرسی. دوره ۲۰، شماره ۱، ص ۱-۱۸.
- * آقای، محمدعلی، ثقفی، علی، تقی‌نجاج، غلامحسین، اسدنیای، جهانبخش. (۱۳۹۱). تأثیر اعلان سود فصلی شرکت‌ها بر تأمین نیاز اطلاعاتی ذینفعان. فصلنامه حسابداری مالی، سال چهارم، شماره ۱۶، صفحات ۱-۳۹.
- * هیأت تدوین استانداردهای حسابداری. (۱۳۸۳). استاندارد شماره ۲۲: گزارش‌گری مالی میان‌دوره‌ای، تهران: سازمان حسابرسی.
- * Abrishami, H. (2009) Principles of Econometrics, Translation, Tehran University Publications, 7nd Ed, 2nd. Vol (in Persian).
- * Brown, L. D. (1993) Earnings forecasting research: its implications for capital markets research, International Journal of Forecasting, 9, 295-320.
- * Callen, J.L., Kwan, C.C.Y., Yip, P.C.Y., Yuan, Y., (1996). Neural Network Forecasting of Quarterly Accounting Earnings. International Journal of Forecasting, 12(4): 475- 482.
- * Cao, Q., & Gan, Q. (2009). Forecasting EPS of Chinese Listed Companies Using Neural Network with Genetic Algorithm. Retrieved from http://works.bepress.com/qiwei_gan/1/.
- * Cao, Qing, Parry Mark, E., (2009). Neural Network Earning per Share Forecasting Models: a Comparison of Backward Propagation and Genetic Algorithm. Decision Support Systems, 47: 32-41.
- * Foster, G. (1977), Quarterly accounting data: Time-series properties and predictive ability results. The Accounting Review, 52, pp. 121.

- * Hagan MT and Menhaj MB, 1994. Training feedforward network with the Marquardt algorithm. IEEE Trans on Neural Networks 5: 989-993.
- * Hollnagel, E., 1989, The Reliability Of Expert Systems, Ellis Horwood Ltd.
- * Lai, S & Li, H. (2006). The predictive power of quarterly earnings per share based on time series and artificial intelligence model. Applied Financial Economics. 16, 1375–1388. <http://dx.doi.org/10.1080/09603100600592752>
- * Lev, B. (1989). On the Usefulness of Earning and Earning research, Lessons and Two Decades of Empirical research, Journal of Accounting research, 153- 192
- * Lorek, K. & Willinger, G. L. (2008). Time-series properties and predictive ability of quarterly cash flows. Advances in Accounting, 24, 65-71.
- * MathWorks Inc.(2007) MATLAB the language of technical computing, Version 7.4, Natick, MA USA.
- * Syouching, L., Hungchih, L. (2006) The predictive power of quarterly earnings per share based on time series and artificial intelligence model, Applied Financial Economics,16,1375-1388.
- * Zhang, W., Cao, Qing, Schniederjans, M., (2004). Neural Network Earning per Share Forecasting Models: a Comparative Analysis of Alternative Methods. Decision Sciences, 35: 205- 237

یادداشت‌ها

1. Forecast
2. Autoregressive Integrated Moving Average
3. Autoregressive Integrated Moving Average (ARIMA) model
4. Artificial Neural Networks
5. Autoregressive Integrated Moving Average (ARIMA) model