



## پیش‌بینی بازده بازار سرمایه با استفاده از الگوی یادگیری الگوریتم لورنبرگ مارکوات،

### گرادبان نزولی و الگوی آریمای (ARIMA)

مهدی اشعریون قمی زاده<sup>۱</sup>  
محمد محمودی<sup>۲</sup>

تاریخ دریافت مقاله: ۹۸/۱۰/۲۸ تاریخ پذیرش مقاله: ۹۹/۰۱/۰۷

#### چکیده

پژوهش حاضر بر اساس ارزیابی الگوی یادگیری الگوریتم لورنبرگ مارکوات، گرادبان نزولی و الگوی آریمای به مقایسه و توانایی پیش‌بینی کنندگی در بازار سرمایه می‌پردازد. بدین منظور داده‌های بازار در سال‌های ۱۳۹۴ تا ۱۳۹۷ مورد استفاده قرار گرفت و بیش از ۷۵ درصد از این داده‌ها تا قبل از سال ۱۳۹۷ به عنوان داده‌های آموزشی استفاده شد و داده‌های یک سال پایانی نیز به عنوان داده‌های آزمایشی مورد استفاده قرار گرفته شده است. نتایج تحقیق نشان داده‌اند، شبکه‌های عصبی مصنوعی ظرفیت بالایی برای پیش‌بینی قیمت دارند. مقایسه نتایج و عملکرد شبکه‌های عصبی و الگوی آریمای (ARIMA) حاکی از آن است که شبکه عصبی قدرت پیش‌بینی بالاتری در مقایسه با الگوی خطی آریمای (ARIMA) دارد، همچنین مقایسه عملکرد و دقت پیش‌بینی دو نوع شبکه عصبی با الگوریتم یادگیری لورنبرگ مارکوات و الگوریتم یادگیری گرادبان نزولی نشان داد که استفاده از الگوریتم یادگیری لورنبرگ مارکوات توانسته است دقت پیش‌بینی شبکه عصبی را افزایش داده و خطای آن را کاهش دهد، بنابراین بر پایه پژوهش انجام شده می‌توان چنین نتیجه گرفت که الگوریتم یادگیری لورنبرگ مارکوات قدرت پیش‌بینی شبکه عصبی را بهبود می‌بخشد.

#### کلمات کلیدی

پیش‌بینی بازده بازار سرمایه، الگوریتم لورنبرگ مارکوات، گرادبان نزولی و الگوی آریمای (ARIMA).

۱- گروه حسابداری، واحد دماوند، دانشگاه آزاد اسلامی، دماوند، ایران. M\_asharion@yahoo.com

۲- گروه حسابداری، واحد فیروزکوه، دانشگاه آزاد اسلامی، فیروزکوه، ایران. (نویسنده مسئول) Mahmoodi\_1978@yahoo.com

## پیش‌بینی بازده بازار سرمایه با استفاده از الگوی یادگیری .../محمودی و اشعریون قمی‌زاده

### مقدمه

در دنیای امروز با توجه به تغییر سبک زندگی، مردم به دنبال روشی برای بهبود و پیشرفت وضع اقتصادی خود هستند، یکی از آسان‌ترین راه‌ها، سرمایه‌گذاری است که ابعاد مختلف دارد. در کشور ایران با توجه به تغییرات شدید بازار سکه و ارز، افراد بیشتری به سمت بازار سهام رو آورده‌اند. پیش‌بینی قیمت سهام امروزه یکی از ابزارهای مهم جهت سرمایه‌گذاری شده است. لازمی به دست آوردن سود، داشتن اطلاعات درست از بازار سرمایه، تغییرات قیمت سهام و فاکتورهای تاثیر گذار است. شناسایی عوامل تاثیرگذار و میزان اثر گذاری آن‌ها بر بازار توسط کارشناسان نیازمند دانش و تحلیل‌های فنی قوی است که به راحتی امکان‌پذیر نیست. بنابراین، پیش‌بینی قیمت سهام که یک فرایند در طول زمان (سری زمانی) است بدلیل در اختیار نبودن دانش همه فاکتورها و میزان اثرگذاری آن‌ها با روش‌های سنتی همراه با خطا است. از آنجایی که بازار سهام دارای سیستمی غیر خطی و آشوب گونه است و تحت تأثیر شرایط سیاسی، اقتصادی و رفتاری سرمایه‌گذاران می‌باشد، تاکنون روش‌های مختلفی جهت پیش‌بینی قیمت سهام استفاده شده است که این روش‌ها بطور کلی آماری یا هوشمند هستند. روش‌های هوشمند اغلب مبتنی بر آموزش هستند و دارای پارامترهایی هستند که در فرآیند یادگیری بایستی تنظیم شوند. از بین روش‌های هوشمند می‌توان شبکه‌های عصبی یا عصبی فازی نام برد. در این گونه شبکه‌ها با افزایش تعداد ورودی‌ها (ویژگی‌ها) تعداد پارامترهای آموزش به صورت نمایی افزایش می‌یابد. بنابراین کاهش ویژگی یک امر مهم در این گونه شبکه‌هاست. جهت کاهش ویژگی و هزینه محاسباتی روش‌های مختلفی ارائه شده‌اند (عاملی و رضانی، ۱۳۹۴). از روش‌های انتخاب ویژگی می‌توان روش‌های یادگیری الگوریتم لورنبرگ مارکوات، گرادیان نزولی و الگوی آریمما نام برد. این مقاله با هدف ارزیابی مقایسه‌ای توانایی پیش‌بینی کنندگی سه الگوی الگوریتم لورنبرگ مارکوات، گرادیان نزولی و آریمما بر بازده بازار شکل گرفته است تا توانایی الگوریتم‌های موصوف برای بهبود رویکرد شبکه عصبی تبیین گردد. در واقع هدف این مقاله این است که بررسی کند که آیا شبکه عصبی در مقایسه با الگوی آریمما قدرت پیش‌بینی کنندگی بهتری دارد و اینکه الگوی یادگیری لورنبرگ مارکوات می‌تواند قدرت پیش‌بینی شبکه عصبی را بهبود بخشد. در این مقاله ابتدا به بررسی چارچوب نظری و پیشینه تحقیق پرداخته می‌شود و سپس فرضیه‌های تحقیق و روش‌شناسی پژوهش بیان شده و به تبیین الگوها پرداخته می‌شود و در نهایت پیش‌بینی‌های انجام شده توسط شبکه عصبی و الگوی آریمما مورد بررسی قرار گرفته و مقایسه می‌شوند.

### چارچوب نظری و پیشینه تحقیق

پیش‌بینی قیمت سهام یکی از موارد جذاب و پرچالشی است که پژوهش‌گران زیادی را به خود جلب

کرده است و رشته‌های علمی زیادی را نیز درگیر نموده است (ژانگ و همکاران، ۲۰۱۸). پیش‌بینی روندها و بهبود قدرت پیش‌بینی ارزش بالایی در کاهش ریسک دارد (باساک و همکاران، ۲۰۱۸). پژوهشگران همواره تمایل به بهبود مدل پیش‌بینی‌های موجود را دارند. در دهه‌های اخیر، روش جدیدی از پیش‌بینی به نام شبکه‌های عصبی مصنوعی پا به عرصه وجود نهاده که با اقتباس از فرآیند یادگیری مغز انسان می‌تواند روابط بین متغیرها را هرچند پیچیده و غیرخطی باشد کشف کند. از کاربردهای مهم این روش، پیش‌بینی و بهینه‌سازی تصمیم‌گیری‌ها در بازارهای مالی است که به تصمیم‌گیرنده این امکان را می‌دهد تا به منظور حداکثر نمودن شاخص و حداقل نمودن خطر سرمایه‌گذاری در شرایط مبهم از آن استفاده کند (بهمنش، ۱۳۹۴). فنون هوش مصنوعی نیز از یک سو دارای ماهیت غیرخطی هستند زیرا به دنبال تقلید و الگوبرداری از نمونه‌های طبیعی می‌باشند و از سوی دیگر دارای ماهیت کیفی هستند و کاربردهای آن‌ها در رشته‌های مدیریت افزایش یافته است. در این خصوص شاخه‌های هوش مصنوعی بخصوص شبکه‌های عصبی مصنوعی و الگوریتم انبوه ذرات در کنار سایر تکنیک‌های محاسباتی از جمله تئوری موجک از کاربرد و استقبال شایان توجه محققین برخوردار بوده‌اند.

مسائل مالی و اقتصادی عمدتاً با یک سری روابط غیرخطی مخصوصاً در بازار سهام سروکار دارند. لذا پیش‌بینی وضعیت آینده بازار سهام با استفاده از مدل‌های متعارف خطی میسر نخواهد بود. استفاده از شبکه‌های عصبی مصنوعی در کنار سایر تکنیک‌های مورد استفاده برای پیش‌بینی سری‌های غیرخطی علی‌الخصوص جایی که شرایطی از قبیل ایستائی که امکان استفاده از تکنیک‌های کلاسیک مقدور نباشد و همچنین در سری‌های زمانی پیچیده، بسیار متداول می‌باشد (راعی و همکاران، ۱۳۹۵). در ادامه تعدادی از تحقیق‌هایی که با استفاده از شبکه عصبی به تجزیه و تحلیل بازارهای سرمایه و پیش‌بینی قیمت سهام آن‌ها پرداخته‌اند، اشاره خواهد شد.

مهری نمک آورانی امید و احتشام رائی رضا (۱۳۹۸)، در تحقیقی با موضوع پیش‌بینی منابع مالی بانک با استفاده از مدل خطی (ARIMA) و غیرخطی شبکه‌های عصبی مصنوعی فازی پرداختند. در این پژوهش سعی شده است با استفاده از تکنیک‌های آماری و رویکرد مدل‌های شبکه‌های عصبی مصنوعی مدلی مناسب با بیشترین قدرت تخمین و کمترین میزان خطا برای پیش‌بینی میزان سپرده‌ها یا همان منابع مالی به تفکیک انواع آن‌ها برای بانک مورد نظر معرفی گردد. برای آزمون فرضیه‌ها از اطلاعات یک بانک خصوصی طی بازه زمانی سال‌های ۱۳۸۷-۱۳۹۶ استفاده شده است. در این پژوهش، پس از بررسی توان پیش‌بینی‌کنندگی روش خود رگرسیو میانگین متحرک انباشته (ARIMA) و روش شبکه‌های عصبی مصنوعی، به مقایسه‌ی این دو روش پرداخته شده است. نتایج پژوهش بر میزان

### پیش‌بینی بازده بازار سرمایه با استفاده از الگوی یادگیری .../محمودی و اشعریون قمی‌زاده

سپرده‌های بانک به‌صورت ماهانه حاکی از آن است که روش شبکه‌های عصبی تخمین‌های بهتری نسبت به روش ARIMA ارائه می‌نمایند.

میر علوی سید حسین و پورزمانی زهرا (۱۳۹۸)، نیز به‌ارایه مدل پیشنهادی یک سیستم دو سطحی از شبکه‌های عصبی پرسپترون چندلایه پرداختند و از چندین شاخص برای پیش‌بینی استفاده نمودند. در این پژوهش داده‌های شاخص قیمت بورس اوراق بهادار تهران از ۱۳۹۱ تا ۱۳۹۵ در نظر گرفته شده است. همچنین برای آموزش بهتر شبکه‌ی عصبی و در نتیجه بهبود نتایج بدست آمده، از الگوریتم بهینه‌سازی ملخ برای انتخاب بهترین نمونه‌ها استفاده شده است. نتایج بدست آمده نشان می‌دهد که مدل پیشنهادی توانسته با خطای پیش‌بینی پایین‌تری نسبت به دیگر مدل‌ها عمل کند.

زمردیان غلامرضا و همکاران (۱۳۹۸)، در تحقیقی به استفاده از شبکه‌های عصبی موجکی به منظور تعیین و ارزیابی تاثیرات ریسک سیستماتیک بر بازده مالی سهام پرداختند. در این پژوهش بررسی رابطه بین بازده سهام و ریسک سیستماتیک در افق‌های زمانی میان مدت و بلندمدت و بررسی تأثیر میزان نوسانات بازار بر رابطه فوق در شرکت‌های موادغذایی و لبنی پذیرفته شده در بورس اوراق بهادار تهران در بازده زمانی ۱۳۹۱ الی ۱۳۹۶ می‌پردازد. به منظور آزمون فرضیات تحقیق ابتدا دوره تحقیق را بر اساس واریانس شاخص صنعت داروسازی و شیمیایی به دو دسته دوره‌های پرنوسان و کم‌نوسان تقسیم شده است. سپس اطلاعات مربوط به ریسک سیستماتیک و بازده سهام در دوره‌های پرنوسان و کم‌نوسان را با روش تبدیل موجک گسسته همپوشانی (DWT) و با موجک دابشیز با استفاده از نرم افزار MATLAB به دوره زمانی کوچک‌تر تجزیه نموده است. نتایج آزمون فرضیه‌های تحقیق نشان می‌دهد رابطه معناداری بین ریسک سیستماتیک و بازده در دوره زمانی پر نوسان در افق‌های زمانی میان مدت و بلندمدت وجود دارد. همچنین در دوره‌های زمانی کم‌نوسان نیز در افق‌های زمانی میان مدت رابطه معناداری میان ریسک سیستماتیک و بازده وجود دارد ولی فقط در افق زمانی بلندمدت ۱۸۲ روزه رابطه معنادار میان ریسک و بازده به اثبات می‌رسد.

زارعی و همکاران (۱۳۹۷)، به مقایسه قدرت پیش‌بینی روش‌های شبکه‌های عصبی فازی با شبکه عصبی موجک فازی در پیش‌بینی قیمت سهام بانک‌ها در بورس اوراق بهادار تهران طی سال‌های ۱۳۹۰ تا ۱۳۹۵ پرداختند. در این پژوهش از سیستم منطق فازی به همراه سیستم شبکه عصبی چندلایه با ساختار بهینه‌سازی پس انتشار خطا و ماکزیم همپوشانی تبدیل موجک گسسته برای متغیرهای نرخ ارز، نفت اوپک، طلا، شاخص کل سهام و همچنین حجم معاملات برای پیش‌بینی قیمت سهام استفاده شده است. نتایج حاصل از مدل با استفاده از تابع هزینه بروزرسانی شده انجام گرفت. نتایج پژوهش نشان داد که

قابلیت اطمینان پیش‌بینی قیمت سهام بانک‌ها با شبکه عصبی موجک فازی بالای ۹۰ درصد و با شبکه عصبی فازی بالای ۸۰ درصد است. در نتیجه شبکه عصبی موجک فازی با قابلیت اطمینان بالاتری نسبت به شبکه عصبی فازی عمل می‌کند.

محمدی و همکاران (۱۳۹۴) به بررسی پیش‌بینی نوسانات قیمت سهام در بازار بورس و فرابورس با استفاده از شبکه عصبی و الگوریتم ژنتیک (مطالعه موردی شرکت‌های پذیرفته شده پتروشیمی در بورس و فرابورس) پرداخت و به طراحی و ارائه یک مدل پیش‌بینی قیمت سهام با استفاده از شبکه عصبی و الگوریتم ژنتیک و کاهش خطای پیش‌بینی قیمت سهام با استفاده از آن نسبت به استفاده از تکنیک شبکه عصبی مصنوعی به صورت منفرد پرداخته شد. ابتدا شبکه عصبی پرسپترون چند لایه<sup>1</sup> MLP به منظور پیش‌بینی طراحی و سپس آن را با الگوریتم ژنتیک آموزش داده و در پایان درستی شبکه روی داده‌های واقعی نشان داده شد.

فلاح پور و پورریکنده (۱۳۹۳) با ارزیابی اطلاعات شرکت‌ها از ابتدای سال ۱۳۸۱ لغایت ۱۳۹۰ به پیش‌بینی شاخص سهام با استفاده از شبکه‌های عصبی موجکی در بورس اوراق بهادار تهران پرداختند. آن‌ها برای ایجاد مدل WDBP از موجک db5 برای نوپزدایی داده‌ها و تا پنج مرحله صورت گرفته است. جذر میانگین مربعات خطا (RMSE) معیار ارزیابی برای سنجش خطای پیش‌بینی است. نتایج این تحقیق نشان می‌دهد، عملکرد شبکه عصبی موجکی در پیش‌بینی شاخص سهام سطح خطای کمتری دارد و از شبکه عصبی بهتر است.

جدها و همکاران (۲۰۱۸)، شاخص‌های بازار سهام را با الگوریتم‌های پیش‌بینی شبکه‌های عصبی مصنوعی پیش‌بینی کردند. الگوریتم ارائه شده توانایی پاسخ‌های خرید، فروش، نگهداری سهام را به شخص سرمایه‌گذار دارد. الگوریتم پیشنهادی در بازار سهام بمبئی آزمایش شد و نتایج عملکرد خوب مدل ارائه شده را نشان می‌دهد. برونو و همکاران (۲۰۱۸)، در پژوهشی از تکنیک رگرسیون بردار پشتیبانی (SVR) برای پیش‌بینی قیمت سهام سرمایه‌گذاری‌های بزرگ و کوچک استفاده کردند. نتایج پیش‌بینی این مدل با مدل تصدفی فرضیه بازار کارا مقایسه شد و نتایج نشان داد که SVR دارای قدرت پیش‌بینی کنندگی است به ویژه هنگامی که از استراتژی به‌روز رسانی مدل به صورت دوره‌ای استفاده می‌شود.

پتال و همکاران (۲۰۱۵) در پژوهشی به پیش‌بینی شاخص بازار سهام با استفاده از تلفیق تکنیک‌های یادگیری ماشین پرداختند. برای ارزیابی تجربی از دو شاخص بورس اوراق بهادار ملی هند (CNX Nifty) و بورس اوراق بهادار بمبئی (S&P BSE) از بازارهای سهام هند استفاده گردیده است. آزمایش‌ها براساس تاریخچه اطلاعات ۱۰ ساله این دو شاخص انجام شده است. پیش‌بینی‌ها بر اساس ۱

### پیش‌بینی بازده بازار سرمایه با استفاده از الگوی یادگیری .../محمودی و اشعریون قمی‌زاده

تا ۱۰، ۱۵ و ۳۰ روز پیش از مدت معین انجام شده است. در این مقاله روش دو مرحله‌ای ترکیبی پیشنهاد گردیده که در مرحله اول آن از رگرسیون بردار پشتیبانی (SVR) استفاده شده است. در دومین مرحله روش ترکیبی، از شبکه‌های عصبی مصنوعی (ANN)، جنگل تصادفی (RF) و نتایج رگرسیون بردار پشتیبانی (SVR) در مدل‌های پیش‌بینی SVR-ANN، SVR-RF و SVR-SVR استفاده شده است. عملکرد پیش‌بینی این مدل‌های ترکیبی با سناریوهای تک مرحله ای ANN، RF و SVR مقایسه گردیده است. برای هر یک از مدل‌های پیش‌بینی، ۱۰ شاخص فنی به عنوان ورودی انتخاب شده است.

ژی و همکاران (۲۰۱۴) در مطالعه‌ای با عنوان یک متد شبکه عصبی جدید برای پردازش صدا و کاربرد آن در پیش‌بینی بازار سهام، جهت بهبود قدرت شبکه عصبی معمولی شعاع پایه در مواجه با نقاط ناپیوسته اقدام به ایجاد و استفاده از تابعی برای پرش شبکه در نقاط ناپیوسته کرده و نشان دادند که تکنیک پیشنهادی ایشان با تعداد نرون‌های کمتری در لایه پنهان دارای قدرت پیش‌بینی بالاتری می‌باشد. تیکنور (۲۰۱۳) در پژوهشی به بررسی شبکه عصبی مصنوعی منظم شده بیزین برای پیش‌بینی بازار سهام پرداخته است. قیمت‌های روزانه بازار و شاخص‌های مالی فنی به عنوان ورودی برای پیش‌بینی قیمت نهایی روز آینده سهام مورد استفاده قرار گرفته است. برای تعیین اثربخشی این مدل ارزیابی از سهام شرکت مایکروسافت و سهام شرکت گروه گل‌دمن ساکس انجام شد. نتایج نشان می‌دهند که مدل پیشنهاد شده به خوبی مدل‌های پیشرفته است و نیاز به پیش پردازش داده‌ها، آزمون‌های فصلی و یا تجزیه و تحلیل چرخه ندارد.

کاو و همکاران (۲۰۱۳)، در مطالعه‌ای با عنوان ترکیب تحلیل مولفه غیرخطی و رگرسیون بردار پشتیبان برای پیش‌بینی قیمت سهام، اقدام به معرفی تکنیک کردند که در قدم اول به استخراج ویژگی سری زمانی با استفاده از تکنیک تحلیل مولفه‌های مستقل بطور غیر می‌پرداخت تا منابع مستقل را در میان ترکیبی از منابع و داده‌ها آماری ترکیب شده و نامعین شناسایی نماید. نتایج مقایسه تکنیک پیشنهادی این مطالعه نشان داد که این روش بر کلیه روش‌های ترکیبی رگرسیون بردار پشتیبان برتری داشته است.

### **تبیین فرضیه‌های تحقیق**

باتوجه به اهمیت مسئله پیش‌بینی شاخص بازار سهام، در این پژوهش سعی شده است تا قدرت پیش‌بینی مدل شبکه عصبی با پیش‌بینی به روش ARIMA مقایسه شود و در این راستا فرضیات زیر ارائه شده است:

شبکه عصبی قدرت پیش‌بینی بالاتری در مقایسه با الگوی خطی آریما (ARIMA) دارد. الگوریتم یادگیری لونبرگ مارکوارت قدرت پیش‌بینی شبکه عصبی را بهبود می‌دهد.

### روش‌شناسی پژوهش

این پژوهش در چارچوب استدلال‌ات قیاسی - استقرائی می‌باشد، بدین معنی که مبانی نظری و پیشینه پژوهش از راه مطالعات کتابخانه‌ای، مقالات و سایت‌ها در قالب قیاسی و گردآوری اطلاعات برای تأیید یا رد فرضیه‌ها در قالب استقرائی می‌باشد. با توجه به مطالب فوق و با توجه به ماهیت پژوهش در حوزه مالی و اقتصادی، در این پژوهش سعی شده است تا قدرت پیش‌بینی شبکه عصبی با مدل ARIMA مقایسه شود. برای این مقصود از تحقیق‌های توصیفی بهره‌برداری می‌شود. تحقیق توصیفی آنچه را که هست بدون دخل و تصرف توصیف و تفسیر می‌کند و در این تحقیق توصیفی از روش همبستگی در داده‌ها استفاده می‌شود. در نتیجه این تحقیق از نوع توصیفی همبستگی بوده و درصدد پاسخگویی به سوالات پژوهش خواهد بود. جامعه آماری پژوهش حاضر شاخص کل بورس اوراق بهادار تهران در فاصله سال‌های بین ۱۳۹۴ تا ۱۳۹۷ در بازه روزانه می‌باشد. روش نمونه‌گیری در این مطالعه با توجه به گستردگی شاخص‌ها می‌باشد، پژوهش حاضر حیطه شاخص کل بورس اوراق بهادار تهران را مورد بررسی قرار می‌دهد.

### شبکه عصبی

شبکه‌های عصبی به عنوان سیستم‌های یادگیرنده دارای این توانایی هستند که از گذشته، تجربه‌اندوزی نموده و رفتار خود را در حین هر یادگیری بهبود ببخشند. بهبود در یادگیری در طول زمان باید براساس معیاری سنجیده شود. معیار بهبود، همان هدف سیستم یادگیرنده را مدل می‌کند لذا از آنجا که اطلاعات (ارتباط ورودی و خروجی) کاملاً مشخص نیستند، به فرایند یادگیری نیاز است. در ادامه الگوریتم‌های مورد استفاده در تحقیق حاضر که برای بهبود توانایی شبکه عصبی مورد مقایسه قرار می‌گیرند به اختصار تشریح می‌گردند.

### الگوریتم گرادیان نزولی<sup>۱</sup>

باتوجه به سطح خطا که به‌صورت یک سهمی خواهد بود تحلیلگران به‌دنبال وزن‌هایی هستند که حداقل خطا را داشته باشند. الگوریتم گرادیان در فضای وزن‌ها به‌دنبال برداری می‌گردد که خطا را حداقل کند. این الگوریتم از یک مقدار دلخواه برای بردار وزن شروع کرده و در هر مرحله وزن‌ها را طوری تغییر می‌دهد که در جهت شیب کاهشی منحنی، خطا کاهش داده شود.

## الگوریتم لونیبرگ مارکوارت ۲

این الگوریتم که TRAINLM هم نامیده می‌شود و جزء الگوریتم‌های سریع پس انتشار است که از تکنیک‌های استاندارد بهینه‌سازی عددی استفاده می‌کند. این روش سعی در کاهش محاسبات با استفاده از عدم محاسبه ماتریس Hessian (مشتق دوم ماتریس داده‌ها) دارد. زمانی که تابع کارایی به صورت مجموع مربعات (که در شبکه‌های پیشرو مرسوم است) باشد ماتریس Hessian به کمک روابط زیر قابل تخمین است. در این روابط  $J$  ماتریس ژاکوبین می‌باشد که شامل مشتقات اول از خطاهای شبکه نسبت به وزن‌ها و بایاس‌ها است و  $e$  بردار خطای شبکه است. ماتریس ژاکوبین از طریق تکنیک‌های استاندارد پس انتشار قابل محاسبه است و پیچیدگی محاسبات آن نسبت به محاسبه ماتریس Hessian بسیار کمتر است.

$$H = JJ^T \quad \text{رابطه (۱)}$$

$$g = eJ^T \quad \text{رابطه (۲)}$$

به طور کلی الگوریتم لونیبرگ مارکوارت یک تکنیک بهینه‌یابی برای توابع غیرخطی چند متغیره است که به نوعی ترکیب دو الگوریتم گاوس نیوتون و گرادیان نزولی به شمار می‌رود که کارایی بهتری از سایر الگوریتم‌ها دارد که در ادامه به نحوه عملکرد آن اشاره می‌شود. اصولاً در مسائل برازش منحنی با مسئله حداقل‌سازی مربع خطاهای برازش مواجه هستیم به نحوی که الگوریتم بهینه‌یاب می‌بایست پارامترهای مسئله را به نحوی پیدا کند که پاسخ مسئله بسیار نزدیک به پاسخ واقعی بوده و به عبارتی مربع خطاهای پیش‌بینی حداقل شود.

مثلاً چنانچه با یک مسئله بهینه‌یابی که  $m$  تابع  $f_1, f_2, \dots, f_m$  تا  $f_m$  با  $n$  پارامتر  $P_1, P_2, \dots, P_n$  تا  $P_n$  مواجه باشیم به نحوی که  $m$  بزرگتر مساوی  $n$  باشد. به صورت برداری خواهیم داشت:

رابطه (۳)

$$P^T = (P_1, P_2, \dots, P_n) \quad , \quad f^T = (f_1, f_2, \dots, f_m)$$

در این حالت تابع هزینه برای جستجوی بردار پارامترهای بهینه به صورت مسئله حداقل مربعات خطا نوشته می‌شود:



$$S(P) = f^T f = \sum_{i=1}^m [f_i(P)]^2 \quad \text{رابطه (۴)}$$

در این حالت جهت پیش‌بینی با استفاده از شبکه عصبی مجموعه جفت اعداد واقعی (t) و پیش‌بینی (y) بصورت  $(t_i, y_i)$  در نظر گرفته می‌شود که هدف آن یافتن P به نحوی هست که  $c(t|P)$  به نحوی بهینه‌یابی شود که مجموع مربعات خطاها در رابطه زیر حداقل گردد:

$$f_i(P) = y_i - c(t_i | P) \quad \text{رابطه (۵)}$$

الگوریتم لئونبرگ مارگوارت همچون سایر الگوریتم‌های عددی یه چرخه تکرار شونده را در دستور کار دارد. به نحوی که ابتدا از یک نقطه شروع به صورت حدسی برای بردار P شروع کرده و در هر گام از چرخه تکراری بردار P با یک تخمین جدید  $p+q$  جایگزین می‌شود که در آن بردار q از تقریب زیر حاصل می‌شود:

$$f(p+q) \approx f(p) + Jq \quad \text{رابطه (۶)}$$

در رابطه فوق J ژاکوبین f در P است که یک فرایند بهینه‌سازی وزن‌های شبکه در مسئله مجموع مربعات S داریم  $\nabla_q S = 0$  با خطی سازی رابطه فوق می‌توان به معادله زیر دست یافت:

$$(J^T J)q = -J^T f \quad \text{رابطه (۷)}$$

در رابطه فوق به سادگی می‌توان با وارون کردن  $(J^T J)$  به دست یافت، البته نسخه اصلاح شده رابطه فوق استفاده از یک ضریب تعدیل  $\lambda$  به صورت یک ضریب میرایی مثبت است که وظیفه تنظیم همگرایی پاسخ الگوریتم را بر عهده دارد. لذا پس از لحاظ کردن این ضریب رابطه فوق بصورت زیر اصلاح می‌شود:

$$(J^T J + \lambda)q = -J^T f \quad \text{رابطه (۸)}$$

ضریب  $\lambda$  به نحوی تنظیم می‌شود که شتاب همگرایی پاسخ‌ها تعدیل شود. به این صورت که اگر کاهش S به عنوان خطای پیش‌بینی شبکه تند باشد مقدار  $\lambda$  کوچک شده و رفتار آن شبیه به الگوریتم

### پیش‌بینی بازده بازار سرمایه با استفاده از الگوی یادگیری ... /محمودی و اشعریون قمی‌زاده

گاوس نیوتون می‌شود و چنانچه که کاهش  $S$  اندک باشد مقدار  $\hat{\mu}$  افزایش یافته و رفتار الگوریتم شبیه به الگوریتم گرادیان نزولی می‌شود.

#### الگوی خودرگرسیو میانگین متحرک انباشته (آر‌ی‌ما)

یکی از مباحث مهم در اقتصادسنجی، بحث مربوط به سری‌های زمانی می‌باشد. از آنجا که داده‌های سری زمانی در فواصل زمانی مساوی و منظمی جمع‌آوری می‌شوند و در نتیجه آمار مربوط به متغیری که پیش‌بینی و یا توضیح داده می‌شود در دوره‌های زمانی گذشته موجود است؛ لذا می‌توان از الگوی حاکم بر رفتار گذشته یک متغیر استفاده کرد و براساس اطلاعات حاصل شده از این الگو، اقدام به توضیح و پیش‌بینی سری زمانی متغیر مورد نظر کرد، این رویکرد در اقتصادسنجی به رویکرد سری‌های زمانی مشهور است از معروفترین و کامل‌ترین مدل‌های اقتصادسنجی سری زمانی مدل  $ARIMA$  می‌باشد. از آنجا که در برخی موارد برای مدل‌سازی یک سری زمانی انتخاب درجات بسیار بالای خودرگرسیو یا میانگین متحرک لازم است، درچنین شرایطی استفاده از مدل ترکیبی خودرگرسیو میانگین متحرک ( $ARMA$ ) بسیار مفید خواهد بود. الگوی  $ARMA(p,q)$  براساس ترکیب دو الگوی  $AR(p)$  و  $MA(q)$  می‌باشد و حالت کلی آن به صورت زیر است:

$$\begin{aligned} ARMA(p, q): y_t & \text{ رابطه (۹)} \\ & = \alpha + \beta_1 y_{t-1} + \dots + \beta_p y_{t-p} + \varrho_t \\ & + \gamma_1 \varrho_{t-1} + \dots + \gamma_q \varrho_{t-q} + v_t \end{aligned}$$

بر اساس عملگر وقفه می‌توان عبارت فوق را به صورت خلاصه شده زیر نوشت:

$$ARMA(p, q): \beta(L)y_t = \alpha + \gamma(L)\varrho_t + v_t \quad \text{رابطه (۱۰)}$$

$$L^i y_t = y_{t-i}$$

$$\beta(L) = (1 - \beta_1 L + \dots + \beta_p L^p)$$

$$\gamma(L) = (1 + \gamma_1 L + \dots + \gamma_q L^q)$$

الگوی فوق را می‌توان به صورت بدون جز ثابت نیز نوشت:

$$ARMA(p, q): \beta(L)y_t = \gamma(L)\varrho_t + v_t \quad \text{رابطه (۱۱)}$$

$$L^i y_t = y_{t-i}$$

$$\beta(L) = (1 - \beta_1 L + \dots + \beta_p L^p)$$

$$\gamma(L) = (1 + \gamma_1 L + \dots + \gamma_q L^q)$$

مدل‌های  $AR(P)$  و  $ARMA(p,q)$  تحت فرض مانایی سری مورد بررسی دارای اعتبار می‌باشند. در صورت نامانا بودن سری این مدل‌ها فاقد اعتبار هستند. البته ذکر این نکته ضروری است که اگر یک سری زمانی از فرآیند  $MA(q)$  تبعیت کند آن سری همواره مانا می‌باشد. اما این اصل در مورد الگوهای  $AR(P)$  و  $ARMA(p,q)$  صادق نیست و در این مدل‌ها لازم است قبل از برآورد سری از مانا بودن آن اطمینان شود و در مواردی که سری زمانی تحت بررسی نامانا می‌باشد، لازم است با  $d$  بار تفاضل‌گیری سری زمانی را مانا از درجه  $d$  کرد. سری زمانی نامانا که با  $d$  بار تفاضل‌گیری تبدیل به سری زمانی مانا می‌شود سری مانا از درجه  $d$  گفته می‌شود. به عنوان مثال اگر سری  $y_t$  بعد از یکبار تفاضل‌گیری مانا شود، گویند سری  $y_t$  مانا از درجه  $d(1)$  می‌باشد. در مدل‌سازی‌های اقتصادی لازم است سری به شکل مانا وارد مدل شود. در چنین شرایطی مدل ترکیبی خودرگرسیو میانگین متحرک  $ARMA(p,q)$  به مدل ترکیبی خود بازگشت میانگین متحرک انباشته  $ARIMA(p,d,q)$  تبدیل می‌شود. مثلاً اگر فرض کنیم  $y_t$  متغیری مانا از درجه  $d(1)$  است در آن صورت مدل  $ARIMA(p,1,q)$  مطرح می‌شود:

$$ARIMA(p, d = 1, q): \beta(L)\Delta y_t = \alpha + \gamma(L)q_t + v_t \quad \text{رابطه (۱۱)}$$

حالت کلی برای الگوی  $ARIMA(p,d,q)$  برای یک سری مانا از درجه  $d$  به صورت زیر نوشته می‌شود:

$$ARIMA(p, d, q): \Delta^d y_t \quad \text{رابطه (۱۲)}$$

$$= \alpha + \beta_1 \Delta^d y_{t-1} + \dots + \beta_p \Delta^d y_{t-p} + q_t \quad \text{رابطه (۱۳)}$$

$$+ \gamma_1 q_{t-1} + \dots + \gamma_p q_{t-p} + v_t$$

$$ARIMA(p, d, q): \beta(L)\Delta^d y_t = \alpha + \gamma(L)q_t + v_t$$

همان‌طور که در معادلات فوق مشاهده می‌شود، تفاضل‌گیری با جز  $MA(q)$  مدل‌های  $ARIMA$  هیچ ارتباطی ندارد.

## پیش‌بینی بازده بازار سرمایه با استفاده از الگوی یادگیری .../محمودی و اشعریون‌قمی‌زاده

### تجزیه و تحلیل داده‌ها


#### آمار توصیفی

جدول زیر آمار توصیفی داده‌های بکار رفته را نمایش می‌دهد.

جدول ۱: آمار توصیفی و نماد متغیر تحقیق

متغیر	Mean	median	min	max	std	Skewness	Kurtosis
شاخص کل	۱۶,۲۰۰	۱۵,۲۹۴	۹,۴۴۵	۳۴,۰۰۷	۵,۲۹۳	۱,۰۴۶	۳,۹۳

همانگونه که قابل مشاهده است میانگین شاخص در طی دوره تحت بررسی ۱۶,۲۰۰ واحد بوده و کمترین میزان آن ۹,۴۴۵ واحد و بیشترین میزان آن ۳۴ هزار واحد بوده است. همچنین انحراف معیار این متغیر ۵,۲۹۳ واحد و چولگی آن در حدود یک واحد مثبت و کشیدگی آن برابر ۳,۹ می‌باشد. نمودار سری زمانی متغیر تحقیق بشرح جدول زیر می‌باشد.



نمودار ۱: نمودار روند شاخص کل

آزمون های ریشه واحد

جداول زیر خروجی Eviews در محاسبه آماره دیکی فولر تعمیم یافته را نشان می دهد.

جدول ۲: آزمون ریشه واحد-قبل از مانایی

Prob.*	t-Statistic	Augmented Dickey-Fuller test statistic	
۰,۶۶۵۵	-۱,۸۷۷۱۶۸		
	-۳,۹۶۸۱۱۱	Level 1%	Test critical values:
	-۳,۴۱۴۷۳۳	Level 5%	
	-۳,۱۲۹۵۲۶	Level 10%	

Prob.	t-Statistic	Std. Error	Coefficient	Variable
۰,۰۶۰۸	-۱,۸۷۷۱۶۸	۰,۰۰۱۹۰۴	-۰,۰۰۳۵۷۵	SHAKHES(-1)
.	۱۷,۴۵۳۵۶	۰,۰۳۳۳۲۱	۰,۵۸۱۵۷۹	D(SHAKHES(-1))
۰,۱۰۱۶	-۱,۶۳۸۷۶۵	۰,۰۳۸۴۷۲	-۰,۰۶۳۰۴۷	D(SHAKHES(-2))
.	۵,۸۱۵۱۴۸	۰,۰۳۸۵۱۷	۰,۲۲۳۹۸۱	D(SHAKHES(-3))
۰,۲۱۵۵	-۱,۲۳۹۵۸۴	۰,۰۳۹۱۴۴	-۰,۰۴۸۵۲۲	D(SHAKHES(-4))
۰,۸۸۱۴	-۰,۱۴۹۲۳	۰,۰۳۹۱۱۱	-۰,۰۰۵۸۳۷	D(SHAKHES(-5))
۰,۰۷۱۸	-۱,۸۰۲۵۷۴	۰,۰۳۸۷۲۳	-۰,۰۶۹۸۰۱	D(SHAKHES(-6))
۰,۰۶۷۱	۱,۸۳۳۱۲۳	۰,۰۳۸۸۵۴	۰,۰۷۱۲۲۴	D(SHAKHES(-7))
۰,۴۹۷۷	۰,۶۷۸۳۸۷	۰,۰۳۹۰۳۲	-۰,۱۳۲۸۵۱	D(SHAKHES(-8))
۰,۰۰۰۷	-۳,۳۹۲۳۲۶	۰,۰۳۹۱۶۲	۰,۰۷۱۸۶	D(SHAKHES(-9))
۰,۰۶۹۵	۱,۸۱۷۲۹	۰,۰۳۹۵۴۳	-۰,۰۳۵۴۰۷	D(SHAKHES(-10))
۰,۳۷۲۲	-۰,۸۹۲۸۹۲	۰,۰۳۹۶۵۵	۰,۰۳۴۸۰۳	D(SHAKHES(-11))
۰,۳۸۲۵	۰,۸۷۳۶۴۴	۰,۰۳۹۸۳۷	۰,۰۳۷۷۷۱	D(SHAKHES(-12))
۰,۳۴۳۴	۰,۹۴۷۹۱۷	۰,۰۳۹۸۴۶	۰,۱۷۴۳۴۹	D(SHAKHES(-13))
.	۴,۳۸۴۲۰۲	۰,۰۳۹۷۶۸	۰,۱۷۴۳۴۹	D(SHAKHES(-14))
۰,۰۹۰۷	-۱,۶۹۳۵۳۳	۰,۰۴۰۳۲۸	-۰,۰۶۸۲۹۷	D(SHAKHES(-15))
۰,۰۲۲	-۲,۲۹۳۷۶	۰,۰۴۰۴۱۳	-۰,۰۹۲۶۹۷	D(SHAKHES(-16))
۰,۷۶۰۵	-۰,۳۰۴۸۸۹	۰,۰۳۹۵۶	-۰,۰۱۲۰۶۱	D(SHAKHES(-17))
۰,۰۱۱۴	-۲,۵۳۵۹۰۷	۰,۰۳۹۳۷۸	-۰,۰۹۹۸۵۹	D(SHAKHES(-18))
۰,۰۲۷۴	۲,۲۰۹۰۱۱	۰,۰۳۳۸۲۴	۰,۰۷۴۷۱۷	D(SHAKHES(-19))

پیش بینی بازده بازار سرمایه با استفاده از الگوی یادگیری .../محمودی و اشعریون قمی زاده

۰,۱۰۹۷	۱,۶۰۱۱۵۸	۱۷,۱۸۱۲۶	۲۷,۵۰۹۹۲	C
۰,۰۳۰۴	۲,۱۶۷۹۰۷	۰,۰۳۶۵۱۸	۰,۰۷۹۱۶۷	@TREND("1")

۲۰,۹۶۲۴	Mean dependent var	۰,۴۳۶۷۶۳	R-squared
۱۶۴,۱۹۵۴	S.D. dependent var	۰,۴۲۳۵۱۸	Adjusted R-squared
۱۲,۵۱۲۹۳	Akaike info criterion	۱۲۴,۶۶۷۶	S.E. of regression
۱۲,۶۲۸۷۹	Schwarz criterion	۱۳۸۷۹۰۲۴	Sum squared resid
۱۲,۵۵۷۱۶	Hannan-Quinn criter.	-۵۷۰۲,۶۶۵	Log likelihood
۲,۰۰۳۳۱۶	Durbin-Watson stat	۳۲,۹۷۵۱۸	F-statistic
		۰,۰۰۰	Prob(F-statistic)

جدول ۳: آزمون ریشه واحد-بعد از مانایی تفاضل گیری

Prob.*	t-Statistic	Augmented Dickey-Fuller test statistic		
۰,۰۰۰۰	-۵,۵۷۵۹۳۵			
	-۳,۹۶۸۱۳۳	Level 1%		Test critical values:
	-۳,۴۱۴۷۴۴	Level 5%		
	-۳,۱۲۹۵۲۳	Level 10%		
Prob.	t-Statistic	Std. Error	Coefficient	Variable
۰,۰۰۰۰	-۵,۵۷۵۹۳۵	۰,۰۵۷۴۹۹	-۰,۳۲۰۶۱۲	SHAKHES(-1)
۰,۰۹۲۱	-۱,۶۸۱۶۳۶	۰,۰۶۰۰۳۵	-۰,۱۰۱۲۲۷	D(SHAKHES(-1))
۰,۰۰۳۶	-۲,۹۱۷۹۳۸	۰,۰۵۸۷۰۳	-۰,۱۷۱۲۹۲	D(SHAKHES(-2))
۰,۲۶۷۱	۱,۱۱۰۳۷۵	۰,۰۵۷۰۰۵	۰,۰۶۳۲۹۷	D(SHAKHES(-3))
۰,۷۵۴۰	۰,۳۱۳۵۲۰	۰,۰۵۵۹۴۶	۰,۰۱۷۵۴۰	D(SHAKHES(-4))
۰,۶۷۶۴	۰,۴۱۷۴۷۷	۰,۰۵۴۹۶۹	۰,۰۲۲۹۴۸	D(SHAKHES(-5))
۰,۴۲۸۷	-۰,۷۹۱۷۳۶	۰,۰۵۴۴۵۷	-۰,۰۴۳۱۱۵	D(SHAKHES(-6))
۰,۹۳۸۰	۰,۰۷۷۸۲۱	۰,۰۵۴۲۵۱	۰,۰۰۴۲۲۲	D(SHAKHES(-7))
۰,۶۷۵۴	۰,۴۱۸۹۴۷	۰,۰۵۳۱۸۶	۰,۰۲۲۲۸۲	D(SHAKHES(-8))
۰,۰۲۷۴	-۲,۲۰۹۵۵۹	۰,۰۵۱۷۹۸	-۰,۱۱۴۴۵۱	D(SHAKHES(-9))
۰,۳۸۴۱	-۰,۸۷۰۷۵۰	۰,۰۵۰۲۲۲	-۰,۰۴۳۷۳۱	D(SHAKHES(-10))
۰,۰۸۴۶	-۱,۷۲۶۲۵۳	۰,۰۴۸۶۷۳	-۰,۰۸۴۰۲۱	D(SHAKHES(-11))
۰,۴۰۴۵	-۰,۸۳۴۰۳۵	۰,۰۴۶۷۲۹	-۰,۰۳۸۹۷۴	D(SHAKHES(-12))
۰,۹۴۷۱	-۰,۰۶۶۴۰۵	۰,۰۴۵۵۵۰	-۰,۰۰۳۰۲۵	D(SHAKHES(-13))

فصلنامه مهندسی مالی و مدیریت اوراق بهادار / شماره چهل و چهارم / پائیز ۱۳۹۹

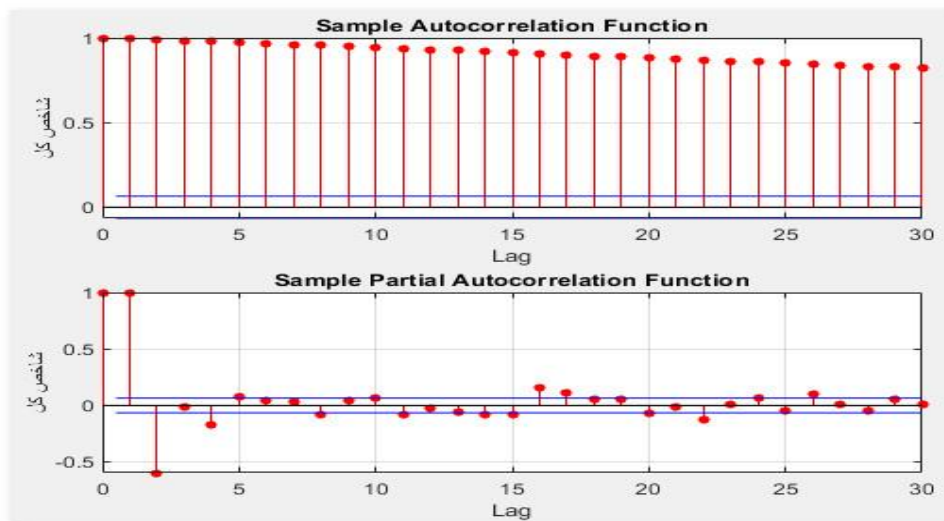
۰,۰۰۰۴	۳,۵۴۵۶۹۳	۰,۰۴۴۹۵	۰,۱۵۷۷۶۷	D(SHAKHES(-14))
۰,۰۱۷۹	۲,۳۷۲۲۸۰	۰,۰۴۲۸۱۹	۰,۱۰۱۵۷۸	D(SHAKHES(-15))
۰,۹۵۱۸	۰,۰۶۰۴۷۰	۰,۰۴۲۰۴۹	۰,۰۰۲۵۴۳	D(SHAKHES(-16))
۰,۹۰۱۵	-۰,۱۲۳۸۱۲	۰,۰۴۰۵۷۸	-۰,۰۰۵۰۲۴	D(SHAKHES(-17))
۰,۰۰۰۵	-۳,۴۸۳۹۱۷	۰,۰۳۹۸۶۵	-۰,۱۳۸۸۸۵	D(SHAKHES(-18))
۰,۰۶۸۵	-۱,۸۲۳۶۴۹	۰,۰۳۶۰۹۹	-۰,۰۶۵۸۳۲	D(SHAKHES(-19))
۰,۰۰۰۲	-۳,۶۸۲۵۵۴	۰,۰۳۳۷۳۱	-۰,۱۲۴۲۱۵	D(SHAKHES(-20))
۰,۹۵۲۲	-۰,۰۵۹۹۹۰	۸,۵۱۲۰۴۵	-۰,۵۱۰۶۴۱	C
۰,۳۳۶۴	۰,۹۶۱۸۲۴	۰,۰۱۵۸۳۷	۰,۰۱۵۲۳۲	@TREND("1")
۰,۰۰۳۵۰۵	Mean dependent var	۰,۳۰۳۳۲۹	R-squared	
۱۴۶,۹۴۷۸	S.D. dependent var	۰,۲۸۶۱۰۸	Adjusted R-squared	
۱۲,۵۰۵۸۸	Akaike info criterion	۱۲۴,۱۵۹۳	S.E. of regression	
۱۲,۶۲۷۲۲	Schwarz criterion	۱۳۷۱۹۸۳۰	Sum squared resid	
۱۲,۵۵۲۲۰	Hannan-Quinn criter.	-۵۶۸۵,۹۳۳	Log likelihood	
۱,۹۹۸۶۳۷	Durbin-Watson stat	۱۷,۶۱۳۸۳	F-statistic	
		۰,۰۰۰۰	Prob(F-statistic)	

همانگونه که جداول فوق نشان می‌دهند متغیر تحت بررسی در سطح مانا نبوده و با یک بار تفاضل‌گیری مانا شده است. چنانچه که در سطح آماره دیکی فولر ۱,۸۸ و سطح معنی‌داری ۰,۶۶ بوده و بالاتر از ۵٪ می‌باشد ولی پس از تفاضل‌گیری این آماره به ۵,۵۷ رسیده و سطح معنی‌داری آن نیز کمتر از ۱٪ می‌باشد.

### برآورد الگوی آر‌ایما

در این بخش به کمک نرم افزار متلب، به برآورد الگوی ARIMA پرداخته می‌شود. پیش از برآورد الگو لازم است تا چشم‌انداز تقریبی از مدل مورد نیاز و درجات AR و MA داشته باشیم (درجه انباشته با توجه به مانایی متغیرها یک  $I(1)$  است) بدین منظور از تابع خودهمبستگی و خودهمبستگی جزئی استفاده می‌شود که نتایج آن به شرح شکل زیر است:

پیش بینی بازده بازار سرمایه با استفاده از الگوی یادگیری .../محمودی و اشعریون قمی زاده



نمودار ۲: سری زمانی مربوط به برآورد الگوی آریما

چنانچه که نمودار (۲) فوق قابل مشاهده است. شاخص کل از یک فرایند AR با وقفه های ۱، ۲، ۴، ۵، ۸، ۱۰، ۱۱، ۱۶، ۱۷، ۲۲، ۲۴ و ۲۶ پیروی می کند. چراکه این ضرایب همبستگی جزئی بیرون از محدوده معنی داری قرار دارند. لذا به نظر می رسد که شاخص کل از یک فرایند  $ARIMA(26,0,1)$  پیروی می کند. با این وجود طبق اصول باکس جنکینز می بایست به معنی داری این ضرایب درون مدل و نکویی برازش نیز توجه کرده و بهترین مدل شناسایی شود. نتایج حاصل از برآورد الگوی آریما بشرح جدول زیر می باشد:

جدول ۴: نتایج برآورد الگوی  $ARIMAX(26,1,0)$

Prob.	t-Statistic	Std. Error	Coefficient	Variable
۰,۰۹۵۵	۱,۶۶۸۷۹۴	۱۲,۴۸۴۲۸	۲۰,۸۳۳۶۹	C
۰,۰۰۰۰	۳۶,۲۰۹۹۴	۰,۰۱۵۹۱۸	۰,۵۷۶۳۹۱	AR (1)
۰,۰۵۱۷	۱,۹۴۸۳۷۶	۰,۰۱۷۹۷۳	۰,۰۳۵۰۱۹	AR (2)
۰,۰۰۲۶	۳,۰۱۸۵۴۳	۰,۰۲۰۵۷۵	۰,۰۶۲۱۰۷	AR (4)
۰,۰۰۹۵	-۲,۶۰۰۴۴۹	۰,۰۱۷۳۸۸	-۰,۰۴۵۲۱۵	AR (5)
۰,۰۶۸۷	-۱,۸۲۲۵۶۹	۰,۰۱۸۳۶۸	-۰,۰۳۳۴۷۸	AR (8)
۰,۰۹۵۵	۰,۷۵۳۷۹۸	۰,۰۱۹۸۷۵	۰,۰۱۴۹۸۲	AR (10)
۰,۰۰۴۲	۲,۸۷۲۶۹۸	۰,۰۱۶۵۴۹	۰,۰۴۷۵۴۱	AR (11)



فصلنامه مهندسی مالی و مدیریت اوراق بهادار / شماره چهل و چهارم / پائیز ۱۳۹۹

۰,۰۰۰۰	-۴,۸۲۵۶۲۱	۰,۰۱۸۷۰۳	-۰,۰۹۰۲۵۶	AR (16)
۰,۷۵۷۵	-۰,۳۰۸۹۰۱	۰,۰۲۲۱۵۴	-۰,۰۰۶۸۴۳	AR (17)
۰,۰۲۱۰	۲,۳۱۱۲۵۶	۰,۰۱۷۰۷۱	۰,۰۳۹۴۵۶	AR (22)
۰,۰۶۵۸	۱,۸۴۲۰۷۶	۰,۰۱۹۶۱۰	۰,۰۳۶۱۲۳	AR (24)
۰,۰۰۰۸	-۳,۳۶۹۹۵۴	۰,۰۱۶۵۵۹	-۰,۰۵۵۹۳۹	AR (26)
۰,۰۰۰۰	۵۱,۵۹۸۸۰	۳۲۲,۰۵۶۷	۱۶۶۱۷,۷۴	SIGMASQ
۲۰,۸۲۵۰۵	Mean dependent var	۰,۳۷۵۱۰۵	R-squared	
۱۶۳,۱۶۰۵	S.D. dependent var	۰,۳۶۶۲۷۴	Adjusted R-squared	
۱۲,۵۸۷۰۸	Akaike info criterion	۱۲۹,۸۸۷۰	S.E. of regression	
۱۲,۶۵۹۶۲	Schwarz criterion	۱۵۵۲۰۹۷۱	Sum squared resid	
۱۲,۶۱۴۷۴	Hannan-Quinn criter.	-۵۸۶۴,۱۶۷	Log likelihood	
۱,۹۹۷۰۴۱	Durbin-Watson stat	۴۲,۴۸۰۴۸	F-statistic	
		۰,۰۰۰۰۰۰	Prob(F-statistic)	
.86+.24i	.86-.24i	.89-.11i	.89+.11i	Inverted AR Roots
.61-.66i	.61+.66i	.82-.49i	.82+.49i	
.23-.88i	.23+.88i	.45+.79i	.45-.79i	
-.18-.89i	-.18+.89i	.01-.88i	.01+.88i	
-.58+.67i	-.58-.67i	-.41-.79i	-.41+.79i	
-.83+.26i	-.83-.26i	-.75+.50i	-.75-.50i	
	-.84+.10i		-.84-.10i	

چنانچه که قابل مشاهده است وقفه‌های ۸، ۱۰، ۱۷ و ۲۴ معنی‌دار نبوده و از مدل حذف می‌شوند.

نتایج زیر پس از حذف متغیرهای بی‌معنی از مدل بشرح جدول زیر می‌باشد:

جدول ۵: نتایج برآورد الگوی **ARIMAX(26,1,0)** بعد از حذف متغیرهای بی‌معنی

Prob.	t-Statistic	Std. Error	Coefficient	Variable
۰,۰۹۵۵	۱,۷۰۰۳۶۳	۱۲,۲۴۶۳۹	۲۰,۸۲۳۳۱	C
۰,۰۰۰۰	۳۹,۱۷۹۰۳	۰,۰۱۴۵۷۴	۰,۵۷۱۰۰۸	AR (1)
۰,۰۵۱۷	۲,۵۹۶۶۳۹	۰,۰۱۶۸۹۹	۰,۰۴۳۸۸۲	AR (2)
۰,۰۰۲۶	۳,۱۵۷۹۸۲	۰,۰۱۸۵۳۵	۰,۰۵۸۵۳۴	AR (4)
۰,۰۰۹۵	-۴,۰۱۸۸۰۴	۰,۰۱۴۴۸۴	-۰,۰۵۸۲۱۰	AR (5)
۰,۰۰۴۲	۴,۱۳۶۵۲۳	۰,۰۱۱۹۱۸	۰,۰۴۹۲۹۹	AR (11)
۰,۰۰۰۰	-۸,۰۳۰۶۱۷	۰,۰۱۱۷۵۴	-۰,۰۹۴۳۸۹	AR (16)


پیش‌بینی بازده بازار سرمایه با استفاده از الگوی یادگیری .../محمودی و اشعریون قمی‌زاده

۰,۰۲۱۰	۳,۳۹۳۵۱۶	۰,۰۱۲۸۱۵	۰,۰۴۳۴۸۹	AR (22)
۰,۰۰۰۸	-۲,۹۸۷۸۲۵	۰,۰۱۳۵۰۱	-۰,۰۴۰۳۳۸	AR (26)
۰,۰۰۰۰	۵۳,۳۹۶۸۸	۳۱۲,۲۳۵۹	۱۶۶۷۲,۴۲	SIGMASQ
۲۰,۸۲۵۰۵	Mean dependent var	۰,۳۷۳۰۴۸	R-squared	
۱۶۳,۱۶۰۵	S.D. dependent var	۰,۳۶۶۹۴۲	Adjusted R-squared	
۱۲,۵۸۱۷۱	Akaike info criterion	۱۲۹,۸۱۸۶	S.E. of regression	
۱۲,۶۳۳۵۳	Schwarz criterion	۱۵۵۷۲۰۴۱	Sum squared resid	
۱۲,۶۰۱۴۷	Hannan-Quinn criter.	-۵۸۶۵,۶۵۹	Log likelihood	
۱,۹۹۸۴۱۶	Durbin-Watson stat	۶۱,۰۸۸۶۷	F-statistic	
			۰,۰۰۰۰۰۰	Prob(F-statistic)
.84+.26i	.84-.26i	.91+.11i	.91-.11i	Inverted AR Roots
.60+.67i	.60-.67i	.81-.49i	.81+.49i	
.21+.87i	.21-.87i	.43+.78i	.43-.78i	
-.15-.88i	-.15+.88i	.00-.82i	.00+.82i	
-.56+.68i	-.56-.68i	-.39+.78i	-.39-.78i	
-.82-.27i	-.82+.27i	-.74-.50i	-.74+.50i	
-.85-.12i		-.85+.12i		

همانگونه که قابل مشاهده است کلیه متغیرهای مورد استفاده غیر از عرض از مبدا در سطح اطمینان ۹۵٪ معنی‌دار شده و ضریب تعیین یعنی دقت مدل حدود 37 درصد می‌باشد.

### برآورد الگوی شبکه عصبی

در این بخش به کمک ابزار شبکه عصبی در نرم افزار متلب به مدلسازی و پیش‌بینی شاخص کل پرداخته می‌شود. جهت معماری شبکه عصبی از اصول معرفی شده توسط استاتاکیس (۲۰۰۹) استفاده می‌شود. بر این اساس جهت معماری شبکه عصبی در لایه اول ۷ نرون (تعداد ورودی‌ها) در لایه دوم ۵۳ نرون و در لایه سوم ۱۸ نرون و در لایه آخر از یک نرون استفاده می‌شود. همچنین کلیه توابع فعال‌سازی مورد استفاده در این شبکه تابع تانژانت سیگموئید می‌باشد. شکل زیر ساختار شبکه عصبی نهایی را نشان می‌دهد:




نمودار ۳: ساختار شبکه عصبی نهایی

پس از تعیین معماری شبکه عصبی و آموزش آن به ارزیابی دقت پیش‌بینی در داده‌های آموزشی می‌پردازیم. نتیجه ارزیابی دقت پیش‌بینی نشان می‌دهد که شبکه عصبی توانسته است ضریب تعیینی در حدود ۰,۱۴۲۵ حاصل نماید در حالی که الگوی آریما دارای دقت پیش‌بینی ۰,۱۴۲۳ بوده است.

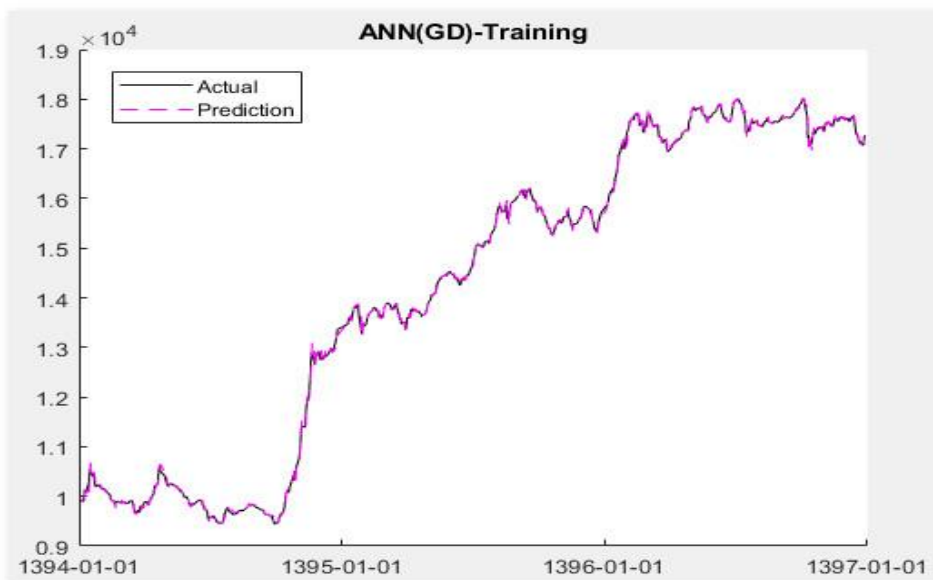
#### پیش‌بینی داده‌ها

در این بخش ضمن بررسی دقت دو الگوی شبکه عصبی و آریما به بررسی توانایی این دو مدل در داده‌های آزمایشی پرداخته می‌شود.




نمودار ۴: سری زمانی پیش‌بینی شاخص بورس-الگوی آریما (داده‌های آموزش)

پیش‌بینی بازده بازار سرمایه با استفاده از الگوی یادگیری ... /محمودی و اشعریون‌قمی‌زاده



نمودار ۵: سری زمانی پیش‌بینی شاخص بورس-گرادیان نزولی (داده های آموزش)



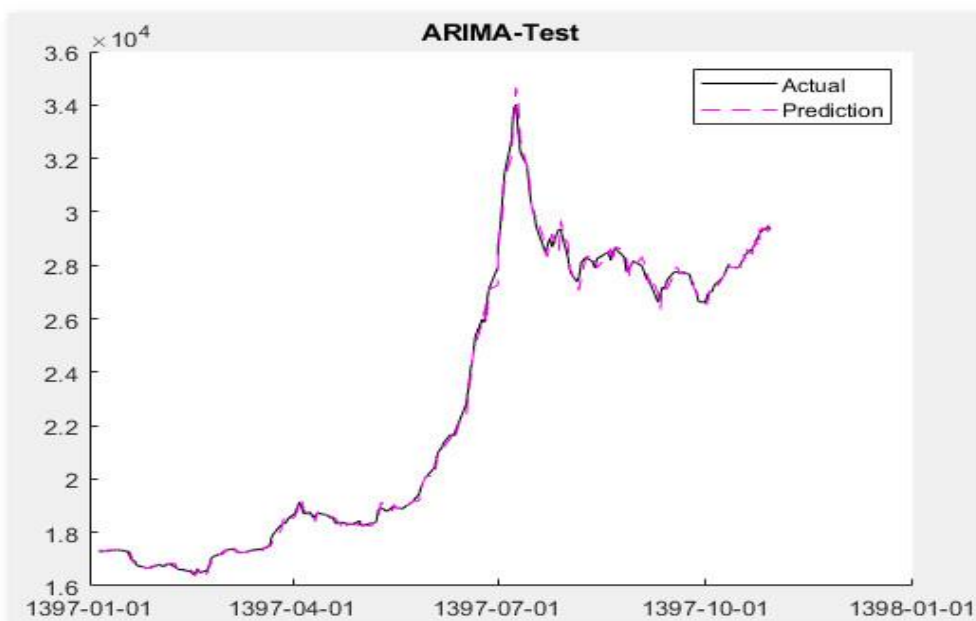
نمودار ۶: سری زمانی پیش‌بینی شاخص بورس-لورنبرگ مارکوات (داده های آموزش)

همچنین جدول زیر نتیجه ارزیابی دقت پیش‌بینی در داده‌های آموزشی را برای هر دو الگوی شبکه عصبی و آریمای نشان می‌دهد:

جدول ۶: دقت پیش‌بینی در داده‌های آموزشی


معیار	ANN(LM)	ANN(GD)	ARIMA
R2	۰,۹۹۹۵	۰,۹۹۹۵	۰,۹۹۹۵
MAPE	۰,۰۰۳۶	۰,۰۰۳۶	۰,۰۰۳۶
RMSE	۶۸,۲۶۶۱	۶۸,۳۰۶۵	۶۸,۴۳۳۱

بر اساس معیار ارزیابی RMSE، الگوی شبکه عصبی خطای کمتر و دقت پیش‌بینی بالاتری در مقایسه با الگوی آریمای نشان می‌دهد. همچنین در مقایسه دو نوع شبکه عصبی با الگوریتم یادگیری لونیبرگ مارکوارت (LM) و الگوریتم یادگیری گرادیان نزولی (GD) مشاهده می‌شود که شبکه عصبی با الگوریتم یادگیری LM خطای کمتر و دقت بالاتری داشته است. در ادامه با استفاده از داده‌های آزمایشی (یک سال آخر) به بررسی دقت پیش‌بینی این دو الگو پرداخته می‌شود.




نمودار ۷: سری زمانی پیش‌بینی شاخص بورس-الگوری آریمای (داده‌های آزمایشی)

پیش‌بینی بازده بازار سرمایه با استفاده از الگوی یادگیری ... /محمودی و اشعریون قمی‌زاده



نمودار ۸: سری زمانی پیش‌بینی شاخص بورس-گرادیان نزولی(داده های آزمایشی)



نمودار ۹: سری زمانی پیش‌بینی شاخص بورس-لورنبرگ مارکوات(داده های آزمایشی)

## فصلنامه مهندسی مالی و مدیریت اوراق بهادار / شماره چهل و چهارم / پاییز ۱۳۹۹

شکل فوق میزان شاخص واقعی و پیش‌بینی شده توسط دو الگوی آریما و شبکه عصبی را نشان می‌دهد. همچنین جدول زیر نتیجه مقایسه معیارهای ارزیابی دقت پیش‌بینی دو الگوی شبکه عصبی و آریما را نشان می‌دهد، همانگونه که قابل مشاهده است. شبکه عصبی بر اساس هر سه معیار ارزیابی، در مقایسه با الگوی آریما توانسته است شاخص را دقیق‌تر پیش‌بینی نماید. با این وجود مقایسه دو نوع شبکه عصبی با الگوریتم یادگیری لونبرگ مارکوارت و شبکه عصبی با الگوریتم یادگیری گرادیان نزولی حاکی از آن است که استفاده از الگوریتم آموزش لونبرگ مارکوارت موجب تقویت و بهبود نتایج شبکه عصبی در مقایسه با الگوریتم یادگیری گرادیان نزولی بوده است.

جدول ۷: دقت پیش‌بینی در داده‌های آزمایشی

معیار	ANN(LM)	ANN(GD)	ARIMA
R2	۰,۹۹۸۵	۰,۹۹۸۳	۰,۹۹۸۰
MAPE	۰,۰۰۵۸	۰,۰۰۵۹	۰,۰۰۶۵
RMSE	۲۰۲,۴۱۹۹	۲۱۵,۳۱۳۵	۲۳۴,۱۱۹۳

### نتیجه گیری

نتایج حاصل از مدل‌سازی دو الگوی خطی (آریما) و غیرخطی (شبکه عصبی) بر اساس داده‌های مورد استفاده مربوط به شاخص کل بورس در بازه ۱۳۹۴ تا ۱۳۹۷ نشان می‌دهد، بهترین حالت الگوی آریما حالت  $ARIMAX(26,1,0)$  بوده و شبکه عصبی با معماری 1-18-53-7 نیز بالاترین دقت پیش‌بینی را در میان معماری‌های مختلف داشته است. به‌نحوی که شبکه عصبی در هر سه معیار ارزیابی پیش‌بینی  $RMSE$  و  $MAPE$  و ضریب تعیین  $R^2$  در داده‌های آزمایشی دقت بالاتری را نشان می‌دهد. همچنین مقایسه عملکرد دو الگوریتم یادگیری شبکه عصبی یعنی الگوریتم لونبرگ مارکوارت و الگوریتم گرادیان نزولی حاکی از آن است که استفاده از الگوریتم یادگیری لونبرگ مارکوارت موجب کاهش خطای پیش‌بینی و بهبود دقت پیش‌بینی می‌گردد.

با توجه به نتایج حاصل می‌توان گفت که در هر دو سری داده‌های آموزشی سال‌های ۱۳۹۴ تا ۱۳۹۶ و آزمایشی در سال ۱۳۹۷ مقایسه نتایج و عملکرد شبکه‌های عصبی و الگوی  $ARIMA$  حاکی از آن است که شبکه عصبی قدرت پیش‌بینی بالاتری در مقایسه با الگوی خطی  $ARIMA$  دارد. لذا فرضیه اول تحقیق تایید می‌گردد. پژوهش انجام شده توسط مه‌ری نمک‌آورانی امید و احتشام‌رانی رضا (۱۳۹۸) نیز این فرضیه را تایید می‌نماید.

### پیش‌بینی بازده بازار سرمایه با استفاده از الگوی یادگیری .../محمودی و اشعریون‌قمی‌زاده

همچنین مقایسه عملکرد و دقت پیش‌بینی دو نوع شبکه عصبی با الگوریتم یادگیری لونبرگ مارکوارت و الگوریتم یادگیری گرادیان نزولی حاکی از آن است که استفاده از الگوریتم یادگیری لونبرگ مارکوارت به نسبت توانسته است دقت پیش‌بینی شبکه عصبی را افزایش داده و خطای آن را کاهش دهد. لذا فرضیه دوم تحقیق مبنی بر اینکه الگوریتم یادگیری لونبرگ مارکوارت قدرت پیش‌بینی شبکه عصبی را بهبود می‌دهد نیز تایید می‌شود.

نتایج حاصل از آزمون فرضیه‌های تحقیق حاضر همسو با تحقیقات انجام شده توسط محققین داخلی همچون میرعلوی و پورزمانی (۱۳۹۸)، زمردیان و همکاران (۱۳۹۸)، زارعی و همکاران (۱۳۹۷)، محمدی و همکاران (۱۳۹۴) و فلاح پور و ریکنده (۱۳۹۳)، و محقق خارجی همچون برونو و همکاران (۲۰۱۸)، جدهاو و همکاران (۲۰۱۸)، پتال و همکاران (۲۰۱۵)، ژی و همکاران (۲۰۱۴) و تیکنور و همکاران (۲۰۱۳) و کاو و همکاران (۲۰۱۳) می‌باشد.

با توجه به نتایج حاصل پیشنهاد می‌شود به منظور پیش‌بینی قیمت سهام در بازار سرمایه از الگوریتم‌های مبتنی بر شبکه عصبی مصنوعی در جهت بهبود پیش‌بینی‌ها بهره برد. همچنین کاربرد شبکه‌های عصبی بر اساس الگوریتم یادگیری لونبرگ مارکوارت قدرت پیش‌بینی شبکه عصبی را در مقایسه با گرادیان نزولی بهبود می‌دهد. بنابراین مبنای مناسبی در جهت پیش‌بینی‌های صحیح و کاهش خطا برای سرمایه‌گذاران در انتخاب فرصت‌های سرمایه‌گذاری مناسب می‌باشد.



## منابع

- ۱) مهری نمک آورانی امید و احتشام راثی رضا (۱۳۹۸) "پیش بینی منابع مالی بانک با استفاده از مدل خطی (ARIMA) و غیرخطی شبکه‌های عصبی مصنوعی فازی"، فصلنامه مهندسی مالی و مدیریت اوراق بهادار، دوره ۱۰، شماره ۴۱، زمستان، صفحه ۱-۲۵.
- ۲) میر علوی سید حسین و پورزمانی زهرا (۱۳۹۸)، "ارائه مدلی جهت پیش‌بینی قیمت سهام با استفاده از روش‌های فرا ابتکاری و شبکه‌های عصبی"، فصلنامه مهندسی مالی و مدیریت اوراق بهادار، دوره ۱۰، شماره ۴۰، پاییز، صفحه ۵۷-۸۳.
- ۳) زمردیان غلامرضا، کاشانی تبار شهرزاد و مانا خاکساریان (۱۳۹۸) "استفاده از شبکه‌های عصبی موجکی به منظور تعیین و ارزیابی تاثیرات ریسک سیستمیک بر بازده مالی سهام"، فصلنامه مهندسی مالی و مدیریت اوراق بهادار، دوره ۱۰، شماره ۳۹، تابستان، صفحه ۱۷۰-۱۹۲.
- ۴) زارعی قاسم، محمدیان رنا، حاضری هاتف، باشکوه اجیرلو محمد. (۱۳۹۷). مقایسه روش‌های شبکه عصبی فازی با شبکه عصبی موجک فازی در پیش‌بینی قیمت سهام بانک‌های پذیرفته‌شده در بورس اوراق بهادار تهران، راهبرد مدیریت مالی، شماره ۲۲، صفحه ۱۰۹-۱۳۸.
- ۵) محمدی، قادر؛ سعیده احصایی و سجاد احصایی، (۱۳۹۴)، بررسی پیش بینی نوسانات قیمت سهام در بازار بورس و فرابورس با استفاده از شبکه عصبی و الگوریتم ژنتیک (مطالعه موردی شرکت‌های پذیرفته شده پتروشیمی در بورس و فرابورس)، هفتمین کنفرانس بین المللی فناوری اطلاعات و دانش، ارومیه، دانشگاه ارومیه.
- ۶) مهدوی، غلامحسین و بهمنش محمد رضا، (۱۳۹۴)، "طراحی مدل پیش بینی قیمت سهام شرکت‌های سرمایه گذاری با استفاده از شبکه‌های عصبی مصنوعی"، فصلنامه پژوهشنامه اقتصادی، شماره ۱۹، صفحه ۲۱۱-۲۳۳.
- ۷) عاملی، احمد و رمضانی ملیحه. (۱۳۹۴). پیش بینی قیمت سهام با استفاده از شبکه عصبی فازی مبتنی بر الگوریتم ژنتیک و مقایسه با شبکه عصبی فازی، فصلنامه تحقیقات مدل سازی اقتصادی دوره ۶، شماره ۲۲، زمستان ۱۳۹۴، صفحه ۶۱-۹۱.
- ۸) فلاح پور، سعید و پورریکنده جواد علی. (۱۳۹۳). پیش‌بینی شاخص سهام با استفاده از شبکه‌های عصبی موجکی در بورس اوراق بهادار تهران. مقاله ۲، دوره ۲، شماره ۴ - شماره پیاپی ۷، زمستان ۱۳۹۳، صفحه ۱۵-۳۱

پیش‌بینی بازده بازار سرمایه با استفاده از الگوی یادگیری ... /محمودی و اشعریون قمی‌زاده

- 9) Zhang, J., Cui, S. Xu, Y. Li, Q. & Li, T. (2018). A novel data-driven stock price trend prediction system. *Expert Systems with Applications* 97, pp. 60–69
- 10) Basak, S. Kar, S. Saha, S. & Khaidem, L. (2018). Predicting the direction of stock market prices using tree-based Classifiers. *North American Journal of Economics and Finance*. (in press).
- 11) Bruno M. H. Vinicius A. S. and Herbet K. (2018). Stock price prediction using support vector regression on daily and up to the minute prices, *The Journal of Finance and Data Science*, in press. pp.1-5.
- 12) Jadhav, S. Dange, B. & Shikalgar, S. (2018). Prediction of Stock Market Indices by Artificial Neural Networks Using Forecasting Algorithms. In *International Conference on Intelligent Computing and Applications* (pp. 455-464).
- 13) Ling-Jing Kao, Chih-ChouChiu, Chi-JieLu, Jung-LiYang(2013). Integration of nonlinear independent component analysis and support vector regression for stock price forecasting, *Neurocomputing* 99534–542.
- 14) Lu Xi, Hou Muzhou, Moon Ho Lee, Jun Li, Duan Wei, Han Hai, Yalin Wu(2014). A new constructive neural network method for noise processing and its application on stock market prediction, *Applied Soft Computing* (15) 57–66.
- 15) Patel, Jigar. Shah, Sahil. Thakkar, Priyank. Kotecha, K.(2015). Predicting stock market index using fusion of machine learning techniques. *Expert Systems with Applications* Vo 42, Issue 4, Pp 2162-2172.
- 16) Ticknor, Jonathan L, (2013). A Bayesian regularized artificial neural network for stock market forecasting. *Expert Systems with Applications* Vol 40, Iss 14, , Pp 5501-5506.

یادداشت‌ها :

- 1 Gradient Descent
- 2 Levenberg-Marquardt