

پیش‌بینی شاخص قیمت سهام با استفاده از مدل هیبریدی

مریم دولو^۱

علی صفری^۲

چکیده

پیش‌بینی شاخص قیمت بازار سهام به علت تاثیرپذیری آن از بسیاری عوامل اقتصادی و غیراقتصادی همواره امری مهم و چالش برانگیز بوده، به طوری که انتخاب بهترین و کارآمدترین مدل به منظور پیش‌بینی آن امری دشوار می‌باشد. از طرفی سری‌های زمانی دنیای واقعی، برای مثال سری زمانی شاخص قیمت سهام، به ندرت دارای ساختاری کاملاً خطی و یا غیرخطی است. مدل‌های هموارسازی نمایی، میانگین متحرک خودرگرسیون انباشته (آریمای) و شبکه عصبی خودرگرسیون غیرخطی می‌تواند برای پیش‌بینی بر اساس سری‌های زمانی استفاده گردد. در این پژوهش به منظور استفاده از مزیت‌های هریک از این مدل‌ها و کاهش خطای پیش‌بینی، روشی هیبریدی با استفاده از ترکیب خطی نتایج پیش‌بینی این مدل‌ها آزمون شده است. وزن‌های بکاررفته به منظور ترکیب نتایج با استفاده از الگوریتم ژنتیک و همچنین بکارگیری وزن‌های مساوی تعیین گردیده است. پس از مشخص شدن قابلیت پیش‌بینی‌پذیری سری زمانی مورد مطالعه (با استفاده از آزمون نسبت واریانس)، روش ترکیبی مذکور بر روی مقادیر ماهیانه شاخص قیمت بورس اوراق بهادار تهران بکارگرفته شد. نتایج بدست آمده نشان دهنده کاهش خطای پیش‌بینی‌های صورت گرفته توسط مدل هیبریدی (در حالت استفاده از وزن‌های مساوی) نسبت به مدل‌های تشکیل دهنده آن است.

واژگان کلیدی: آریمای، پیش‌بینی‌پذیری، شبکه عصبی پویا، مدل هیبریدی، هموارسازی نمایی

طبقه‌بندی موضوعی: C22, G17

۱. استادیار دانشکده مدیریت و حسابداری دانشگاه شهید بهشتی

۲. کارشناسی ارشد کارشناس ارشد مدیریت مالی، دانشگاه شهید بهشتی

۱- مقدمه

پیش‌بینی به عنوان یکی از عناصر کلیدی تصمیم‌گیری‌های مدیریتی، پیشامدهای آینده را با هدف کاهش ریسک تخمین می‌زند. بعلاوه، یکی از مهم‌ترین اهداف علوم مالی و اقتصادی، پیش‌بینی است. دقت پیش‌بینی نیز از مهم‌ترین عوامل مؤثر در انتخاب روش پیش‌بینی است. زیرا معمولاً پیش‌بینی‌ها صحیح نبوده و دارای خطا است. در چنین شرایطی به منظور استمرار حضور سرمایه‌گذاران به عنوان اصلی‌ترین ارکان بازار سرمایه، داشتن یک مدل پیش‌بینی با خطای کم مورد علاقه تمام سرمایه‌گذاران می‌باشد. یکی از اهداف مدل‌های سری زمانی، پیش‌بینی است. هنگامی که یک مدل ساختاری^۱ مناسب وجود ندارد، می‌توان از مدل‌های سری زمانی برای پیش‌بینی استفاده کرد. به عبارت دیگر، در شرایطی که امکان استفاده از متغیرهای توضیحی به دلیل تعدد بسیار زیاد یا عدم دسترسی به مقادیر عددی آنها وجود ندارد، استفاده از مدل‌های سری زمانی شیوه مناسبی می‌باشد (سوری، ۱۳۹۲). در روش‌های سری زمانی، وقفه‌های یک متغیر جهت پیش‌بینی مقدار آتی همان متغیر به کار می‌رود. با توجه به سادگی مدل‌های سری زمانی، این روش خصوصاً در حوزه‌های مالی و اقتصادی، گسترش زیادی یافته است (Anderson, et al., 1998). طبق رویکرد مدل‌های سری زمانی یک متغیره، شاخص قیمت سهام را می‌توان تنها تابعی از مقادیر گذشته آن در نظر گرفت. به بیان دیگر، مقادیر شاخص قیمت سهام در دوره‌های گذشته حاوی تمام اطلاعات لازم مربوط به عوامل تعیین‌کننده شاخص قیمت بوده و لذا توانایی توضیح‌دهندگی شاخص در دوره جاری را داشته و مقادیر آن را پیش‌بینی نمی‌نماید. از طرفی، سری زمانی شاخص قیمت سهام دارای ساختاری نه کاملاً خطی و نه کاملاً غیرخطی است و ترکیبی از دو حالت را داراست. بنابراین استفاده از مدل‌های آماری و یا مدل‌های هوش مصنوعی به تنهایی مناسب نمی‌باشد (Wang, et al., 2012). همچنین مطابق با یافته‌های ژانگ (Zhang, 2003) هیچ روش یا مدل منفردی^۲ در تمامی حالات به خوبی عمل نمی‌کند. علاوه بر این‌ها، وقتی چندین نوع پیش‌بینی برای یک متغیر، در دسترس باشد، معمولاً پیشنهاد می‌شود به جای استفاده از یک مدل منحصربه‌فرد^۳، ترکیبی از پیش‌بینی‌ها استفاده گردد (Timmermann, 2006). بنابراین می‌توان گفت استفاده از یک مدل به‌تنهایی نمی‌تواند تمامی حالت‌ها و روابط موجود میان داده‌های سری زمانی شاخص سهام را دربرگیرد. از این‌رو، پژوهش حاضر به منظور دربرگرفتن ویژگی‌های خطی و غیرخطی موجود در سری زمانی شاخص قیمت سهام،

۱. در مدل‌های ساختاری تغییرات یک متغیر توسط تغییرات جاری و گذشته متغیرهای دیگر توضیح داده می‌شود.

2. Single

3. Individual

درصد ترکیب نتایج مدل‌هایی است که به منظور پیش‌بینی سری‌های زمانی استفاده می‌گردد. به این صورت که نتایج ۳ مدل؛ هموارسازی نمایی^۱، میانگین متحرک خودرگرسیون انباشته (آریمما)^۲ که عمدتاً مربوط به داده‌هایی با ساختار خطی است و شبکه عصبی خودرگرسیون غیرخطی^۳ که مربوط به داده‌هایی با ساختار غیرخطی می‌باشد، یکبار با استفاده از وزن‌های مساوی و بار دیگر با بکارگیری وزن‌های حاصل از الگوریتم ژنتیک، ترکیب می‌شود. بر این اساس، سوال اصلی مورد بررسی در این پژوهش به شرح ذیل می‌باشد؛ آیا عملکرد مدل هیبریدی پیشنهاد شده فوق بهتر از هر یک از ۳ مدل تشکیل دهنده آن می‌باشد؟، به عبارت دیگر، آیا با ترکیب خطی نتایج مختلف ۳ مدل هموارسازی نمایی، آریمما و شبکه عصبی خودرگرسیون غیرخطی توسط الگوریتم ژنتیک و همچنین استفاده از وزن‌های مساوی می‌توان به مدل بهتری دست یافت که دارای معیارهای خطای کمتری نسبت به هر یک از این ۳ مدل باشد.

۲- مبانی نظری و پیشینه پژوهش

مبانی نظری

از اواسط دهه ۱۹۷۰ میلادی و نیز از سال ۱۹۸۰ تلاش‌های گسترده‌ای در زمینه پیش‌بینی پذیری قیمت سهام با استفاده از روش‌های ریاضی، سری‌های زمانی طولانی^۴ و ابزارهای پیشرفته آغاز شد که به ظهور دیدگاه آشوب^۵ و پویایی خطی و غیرخطی منجر شد. این نظریه روش قوی و مهمی برای شناسایی ماهیت فرآیندهای اقتصادی و مالی است. تئوری آشوب تلاش می‌کند نظم موجود در سیستم‌های پیچیده را که در نگاه اول بهم ریخته به نظر می‌رسد، کشف کند. بازارهای پولی و مالی یکی از موارد مناسب برای بکارگیری نظریه آشوب است، زیرا مطابق نظریه‌های موجود در اقتصاد و علوم مالی متغیرهایی نظیر نرخ ارز و قیمت‌های سهام، تصادفی و غیرقابل پیش‌بینی است. برای مثال، براساس فرضیه بازار کارا^۶، قیمت‌ها در بازار سهام از فرآیند گام تصادفی^۷ پیروی می‌کند، به این مفهوم که در چنین بازاری، بازده سهام را نمی‌توان بر اساس تغییرات گذشته قیمت‌ها پیش‌بینی نمود. اما نظریه آشوب باعث شد نوع دیدگاه نسبت به مسائل غیرقابل حل و غیرقابل پیش‌بینی تغییر یافته و

1. Exponential Smoothing Model (ESM)
2. Autoregressive Integrated Moving Average model (ARIMA)
3. Nonlinear autoregressive (NAR) neural network
4. Long time series
5. Chaos Theory
6. Efficient Markets Hypothesis (EMH)
7. Random Walk

شیوه‌های جدیدی برای مطالعه جریان‌ات بسیار پیچیده ارائه شود که به ظاهر تصادفی و غیرقابل پیش‌بینی به نظر می‌رسد.

پیشینه تجربی

هدف ترکیب روش‌های مختلف، کاهش ریسک انتخاب و استفاده از یک مدل نامناسب، از طریق ترکیب چندین مدل می‌باشد تا به این ترتیب نتایج دقیق‌تری حاصل شود. یکی از ایده‌های ترکیب پیش‌بینی‌ها، تشابه آن با مباحث کلاسیک متنوع‌سازی پرتفوی برای کاهش ریسک است. به این صورت که در اینجا پرتفوی، ترکیبی از پیش‌بینی‌ها است و منابع ریسک، منعکس‌کننده اطلاعات ناقص در خصوص متغیر هدف و انتخاب مدل نامناسب به سبب نامشخص بودن فرآیند تولید داده است.

بیتز و همکاران (Bates, et al., 1969) نخستین کسانی بودند که در توسعه اساس روش‌های پیش‌بینی ترکیبی مطالعه کردند. ترکیب پیش‌بینی‌ها که توسط بیتز و همکاران (Bates, et al., 1969) معرفی شد، اغلب به عنوان جایگزین موفق استفاده صرف از یک روش مطرح گردید. از طرفی، استاک و همکاران (Stock, et al., 2006) مطالعات گسترده‌ای پیرامون بسیاری از متغیرهای مالی و اقتصادی با استفاده از مدل‌های پیش‌بینی خطی و غیرخطی انجام دادند و دریافته‌اند بطور متوسط، پیش‌بینی‌های ترکیب‌شده نتایج بهتری را نسبت به بهترین مدل‌های انفرادی نشان می‌دهد. تراسویرتا (Teräsvirta, 2006) دریافت که ترکیب پیش‌بینی‌های حاصل از مدل‌های غیرخطی با مدل‌های خطی، ممکن است گاهاً منجر به پیش‌بینی‌هایی گردد که نسبت به نتایج حاصل از مدل‌های غیرخطی، مستحکم‌تر است. گیبس (Gibbs, 2013) با ملحوظ نمودن این واقعیت که درحوزه ترکیب مدل‌های پیش‌بینی، اجماع محکمی در خصوص بهترین استراتژی ترکیب وجود ندارد، در یک پژوهش تئوری به بررسی ترکیب پیش‌بینی‌ها از دیدگاه اقتصادکلان پرداخت. او برای حل مشکل انتخاب مدل مناسب، نتایج (خروجی‌ها) ۲ استراتژی مختلف ترکیب پیش‌بینی (وزن‌های مساوی و وزن‌های بهینه^۲) را مقایسه کرده و نشان می‌دهد در حالی که وزن‌های مساوی رایج‌ترین شیوه ترکیب پیش‌بینی‌ها است، اما استراتژی وزن‌های بهینه، منتج به برآوردهایی می‌گردد که مربعات خطای پیش‌بینی مورد انتظار را حداقل می‌سازد. ناظریان و همکاران (Nazarian, et al., 2013) در پیش‌بینی نوسانات روزانه شاخص

1. Macroeconomy
2. Optimal weights

قیمت و بازده نقدی (TEDPIX) بورس اوراق بهادار تهران توسط مدل‌های رگرسیو^۱ با ویژگی حافظه بلندمدت، شبکه عصبی پیشخور و مدل‌های هیبریدی (بر مبنای روش ترکیب پیش‌بینی) نشان می‌دهند ترکیب مدل‌های ARFIMA-FIGARCH و شبکه عصبی پیش‌خور چندلایه، با توجه به معیارهای ارزیابی پیش‌بینی همچون MSE و RMSE نتایج قابل قبول‌تری در مقایسه با مدل ARFIMA-FIGARCH به همراه دارد.

هوانگ (2001, Hwang) و ژانگ (2003, Zhang) مزایای استفاده از روش ترکیبی را به صورت

زیر تلخیص می‌نمایند.

۱. معمولاً در عمل، تعیین خطی یا غیرخطی بودن سری زمانی مورد مطالعه، مشکل است. بنابراین، برای پیش‌بینی کنندگان انتخاب تکنیک مناسب در موقعیت‌های خاص بسیار دشوار است.

۲. در حالت کلی، هیچ یک از مدل‌های آریمای و شبکه‌های عصبی مصنوعی نمی‌تواند به منظور مدل‌سازی و پیش‌بینی سری‌های زمانی مناسب باشد، چراکه مدل‌های آریمای نمی‌تواند برای مسائل غیرخطی استفاده شود، در حالی که مدل‌های شبکه‌های عصبی نیز در مدل‌سازی الگوهای کاملاً خطی نتایج مطلوبی ارائه نمی‌نماید؛ از این‌رو، با ترکیب مدل‌های شبکه‌های عصبی مصنوعی با آریمای می‌توان ساختارهای خودرگرسیون پیچیده در داده‌ها را به طور دقیق‌تر مدل‌سازی نمود.

۳. در ادبیات پیش‌بینی، هیچ اجماع کلی بر روش واحدی که در هر موقعیت و شرایطی بهترین روش ممکن باشد، وجود ندارد و این بدان دلیل است که مسائل دنیای واقعی ذاتاً پیچیده است و هیچ مدلی به تنهایی نمی‌تواند الگوهای گوناگون موجود را با دقت یکسان مدل‌سازی نماید.

خاشعی و بیجاری (۱۳۸۷) به منظور بهره‌گیری از مزایای منحصربفرد هر یک از روش‌های مدل‌سازی خطی و غیرخطی، روشی ترکیبی با استفاده از مدل‌های آریمای و شبکه عصبی ارائه کردند. این روش ترکیبی را در دو گام می‌توان خلاصه نمود: در گام اول یک مدل آریمای برای آنالیز جزء خطی مساله و در گام دوم یک مدل شبکه عصبی برای مدل کردن باقیمانده‌های حاصل از مدل آریمای به کار گرفته می‌شود. نتایج بدست آمده بیانگر آن بود که مدل تلفیقی نسبت به مدل‌های آریمای و شبکه پرسپترون چندلایه نتایج دقیق‌تری در پیش‌بینی نرخ ارز (یورو در مقابل ریال) ارائه می‌نماید.

1. Regressive models

سعیدی و محمدی (۱۳۹۱) در مطالعه‌ای به پیش‌بینی نوسانات بازده روزانه شاخص کل بورس اوراق بهادار تهران با استفاده از مدل‌های ترکیبی گارچ-شبکه عصبی پرداختند. در این پژوهش به منظور رفع کمبود مدل‌های اقتصادسنجی ناهمسانی واریانس شرطی و شبکه عصبی در پیش‌بینی نوسان پذیری، یک مدل دو گانه سری زمانی-شبکه عصبی پیشنهاد شده بود. براساس نتایج کلی حاصل از این پژوهش، نوسان پیش‌بینی شده توسط مدل‌های ترکیبی نسبت به خروجی خام مدل‌های پایه‌ای گارچ، از دقت بالایی برخوردار بوده است.

محمدی و همکاران (۱۳۹۴) بیان کردند با توجه به دشواری شناسایی دقیق الگوهای خطی و غیرخطی سری‌های زمانی اقتصادی و مالی به‌منظور پیش‌بینی قیمت هفتگی نفت خام برنت، از ترکیب مدل‌های خودرگرسیون میانگین متحرک انباشته (ARIMA) و ماشین بردار پشتیبان (SVM) استفاده می‌کنند. در این مدل ترکیبی سعی شده الگوهای خطی به وسیله ARIMA و الگوهای غیرخطی به وسیله SVM مدل‌سازی شود. بدین صورت که الگوها و روابط غیرخطی در پسماندها با استفاده از SVM مدل‌سازی شده و پیش‌بینی پسماندها با استفاده از ماشین بردار پشتیبان به پیش‌بینی ARIMA اضافه می‌شد. نتایج حاصل بیانگر این بود که مدل ترکیبی مذکور در مقایسه با مدل‌های آریمای و ماشین بردار پشتیبان، برای پیش‌بینی قیمت دارای خطای کمتری می‌باشد.

۳- روش شناسی پژوهش

در این پژوهش نتایج ۳ مدل هموارسازی نمایی، آریمای و شبکه عصبی خودرگرسیون غیرخطی، به صورت خطی ترکیب می‌گردد. یعنی مقدار پیش‌بینی شده توسط مدل هیبریدی در دوره t برابر است با:

$$\hat{Y}_{Hybrid}(t) = w_1 \hat{Y}_{ESM}(t) + w_2 \hat{Y}_{ARIMA}(t) + w_3 \hat{Y}_{NAR}(t) \quad (\text{رابطه ۱})$$

با این قیود که جمع وزن‌ها (W_i ها) برابر ۱ بوده و مقدار آنها نیز بین ۰ و ۱ می‌باشد، یعنی:

$$\sum_{i=1}^3 w_i = 1, \quad 0 \leq W_i \leq 1 \quad (i = 1, 2, 3)$$

وزن‌های استفاده شده به منظور ترکیب نیز توسط الگوریتم ژنتیک و همچنین استفاده از وزن‌های مساوی؛ یعنی ($w_1 = w_2 = w_3 = \frac{1}{3}$) حاصل می‌شود.

بررسی قابلیت پیش‌بینی پذیری

بطور کلی در بحث پیش‌بینی سری‌های زمانی، نخستین سؤالی که باید پاسخ داده شود آن است که آیا سری زمانی مورد مطالعه قابل پیش‌بینی می‌باشد یا خیر. چرا که اگر سری زمانی تصادفی باشد، در آن صورت نمی‌توان از مدل‌های پیش‌بینی براساس روند گذشته استفاده نمود. همچنین می‌توان انتظار داشت کلیه روش‌های موجود در بحث پیش‌بینی سری‌های زمانی نتواند نتایج مناسبی ارائه دهد. بنابراین در نخستین گام به بررسی پیش‌بینی‌پذیری مقادیر ماهیانه شاخص قیمت بورس اوراق بهادار تهران طی سال‌های ۱۳۷۷ تا ۱۳۹۴ پرداخته می‌شود. برای این منظور، آزمون نسبت واریانس استفاده می‌گردد.

یکی از روش‌ها برای پاسخ به این سؤال چالش برانگیز که آیا قیمت دارایی‌ها پیش‌بینی‌پذیر می‌باشد یا خیر، آزمون نسبت واریانس لو و مکیلانی (Lo and MacKinlay, 1988) می‌باشد. لو و مکیلانی آزمون جدیدی را در زمینه آزمون فرضیه گام تصادفی و در نتیجه بررسی کارایی در سطح ضعیف ابداع کردند و نام آن را آزمون نسبت واریانس نهادند. این آزمون، پیش‌بینی‌پذیری مقادیر سری زمانی را از طریق مقایسه واریانس‌های حاصل از تفاضل داده‌ها (بازده) در طول فاصله‌های زمانی مختلف بررسی می‌کند و به ۲ دسته آزمون‌های آماری پارامتریک (شامل آزمون نسبت واریانس معمولی و آزمون نسبت واریانس چندگانه) و آزمون‌های آماری ناپارامتریک (آزمون‌های نسبت واریانس بر مبنای رتبه‌ها و علامت‌ها)^۱ تقسیم می‌گردد (سلیمی‌فر و شیرزور، ۱۳۸۹).

پس از آزمون پیش‌بینی‌پذیری، اکنون به بررسی جداگانه هر یک از اجزای مدل هیبریدی پرداخته می‌شود.

مدل هموارسازی نمایی

هموارسازی نمایی روش آماری برای پیش‌بینی بر مبنای سری‌های زمانی می‌باشد و ایده آن بر این اساس است که مشاهدات اخیر معمولاً بهترین راهنمایی را برای آینده فراهم خواهد کرد. بنابراین وزن بیشتری به مشاهدات اخیر می‌دهد و همچنان که مشاهدات دورتر می‌شود، وزن‌ها به شیوه نمایی^۲ کاهش می‌یابد. انواع مختلفی از مدل‌های هموارسازی نمایی برای حالت‌ها و شکل‌های مشخصی از سری‌های زمانی استفاده می‌گردد.

1. Ranks and Signs based variance ratio tests
2. Exponential fashion

در این پژوهش با توجه به نتایج نمودار توالی^۱ و تجزیه و تحلیل مؤلفه‌ای^۲ حاصل از بکارگیری نرم‌افزار Minitab 17، برای پیش‌بینی از مدل هموارسازی نمایی دوگانه^۳ استفاده می‌گردد.^۴

$$\begin{aligned} L_t &= \alpha Y_t + (1 - \alpha)[L_{t-1} + T_{t-1}] & 0 \leq \alpha \leq 1 \\ T_t &= \gamma[L_t - L_{t-1}] + (1 - \gamma)T_{t-1} & 0 \leq \gamma \leq 1 \\ \hat{Y}_t &= L_{t-1} + T_{t-1} \end{aligned} \quad \text{(رابطه ۲)}$$

که L_t : سطح^۵ در زمان t ، α : پارامتر وزن مربوط به سطح، T_t : روند در زمان t ، γ : پارامتر وزن مربوط به روند، Y_t : مقدار واقعی سری در زمان t و \hat{Y}_t : مقدار برازش شده^۶ در زمان t است.

مدل میانگین متحرک خودرگرسیون انباشته (آریما)

در مدل آریما فرض می‌شود مقدار آتی متغیر تابع خطی چندین مشاهده گذشته و خطاهای تصادفی می‌باشد. اجزای تشکیل دهنده مدل $ARIMA(p, d, q)$ عبارتند از:

$AR(p)$ فرآیند خودرگرسیون از مرتبه p که بیانگر وقفه‌هایی از سری مانا شده است:

رابطه ۳)

$$Y_{t-p} = \mu + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t$$

که Y_t : مقدار واقعی در دوره t ، ε_t : خطای تصادفی در دوره t و μ : عرض از مبدأ است.

$I(d)$: سری انباشته^۷ از مرتبه d (مرتبه انباشتگی)، نشان‌دهنده آن است که سری با تفاضل‌گیری مرتبه d تبدیل به یک فرآیند مانا می‌گردد.

در فرآیند تخمین مدل $ARIMA(p, d, q)$ مشخص کردن مقادیر بهینه مرتبه p ، d و q برای دستیابی به مدل مطلوب بسیار مهم می‌باشد. بدین منظور از گزینه پیش‌بینی اتوماتیک آریما در نرم‌افزار EViews 9 استفاده می‌گردد.

1. Run Chart
2. Component Analysis
3. Double (Holt's) exponential smoothing

۴. در مدل هموارسازی نمایی باتوجه به حالت‌های مختلف داده‌ها (به این مفهوم که آیا سری زمانی داده‌های مورد مطالعه، دارای روند یا الگوهای فصلی است)، باید از مدل‌های متفاوت استفاده کرد.

5. Level
6. Fitted value
7. Integrated

شبکه عصبی پویا^۱: یکی از مزیت‌های اصلی مدل‌های شبکه عصبی مصنوعی در مدل‌سازی و پیش‌بینی مجموعه‌های نامنظم و غیرخطی نسبت به سایر تکنیک‌ها این است که آنها توانایی تقریب (تخمین) سطح جامعی از توابع با درجه بالایی از دقت و درستی را دارا بوده و به اصطلاح تقریب‌زنده‌های عمومی^۲ می‌باشند و نیز قابلیت کشف روابط غیرخطی در مجموعه داده‌های ورودی را بدون هیچ پیش‌فرضی دارند. از زمینه‌های مهم و کاربردی شبکه‌های عصبی پویا، بهره‌گیری از آنها برای مدل‌سازی و پیش‌بینی سری‌های زمانی از جمله سری‌های زمانی مالی است. یکی از روش‌ها برای حل مسائل سری‌های زمانی غیرخطی با استفاده از شبکه‌های عصبی پویا، بکارگیری مدل خودرگرسیون غیرخطی^۳ می‌باشد. در این حالت تنها یک سری زمانی در دست می‌باشد و سری Y_t تنها با استفاده از d مقدار قبلی آن پیش‌بینی می‌گردد. به عبارت دیگر، مقادیر آتی سری زمانی Y_t توسط مقادیر گذشته آن سری پیش‌بینی می‌شود که می‌تواند به صورت ذیل نوشته شود.

(رابطه ۵)

$$Y_t = f(Y_{t-1}, \dots, Y_{t-d})$$

در اینجا f یک نگاشت^۴ انجام گرفته بوسیله شبکه عصبی می‌باشد. یکی از گام‌های مهم برای پیش‌بینی بر مبنای شبکه‌های عصبی، معماری شبکه می‌باشد. شبکه عصبی خودرگرسیون غیرخطی، یک شبکه پیش‌خور^۵ با تابع انتقال (محرک) سیگموئید تاوانت هیپربولیک^۶ در لایه پنهان و تابع انتقال خطی در لایه خروجی می‌باشد. مسئله مهم دیگر علاوه بر انتخاب تعداد مناسب نرون‌های مخفی، انتخاب تعداد وقفه‌های^۷ مشاهدات (d) می‌باشد، زیرا نقش عمده‌ای در تعیین ساختار خودهمبستگی (غیرخطی) سری زمانی دارد (Khashei, et al., 2010). به دلیل آنکه از نظر تئوری روشی مناسب برای انتخاب این پارامترها وجود ندارد، بنابراین اکثر محققان برای به دست آوردن آنها از تجربه و روش سعی و خطا استفاده می‌کنند. همچنین از آنجا که پژوهش حاضر درصدد است تا مقدار شاخص قیمت یک گام جلوتر^۸ را پیش‌بینی کند، تعداد نرون‌ها در لایه خروجی نیز یک می‌باشد. به دلیل نوسان‌پذیری و نویزی بودن ذاتی بازارهای سهام و احتمال برازش

1. Dynamic neural network

2. Universal approximators

3. Non-linear Autoregressive (NAR)

4. Map

5. Feedforward

6. Tan-sigmoid transfer function, $\{ \text{tansig}(n) = \tanh(n) = \frac{2}{1 + \exp(-2n)} - 1 \}$

7. Delays

8. One step ahead

بیش از حد برای شبکه‌های پس‌انتشار معمولی، در این پژوهش برای دستیابی به قدرت تعمیم بالاتر از هر دو الگوریتم آموزش لونیبرگ-مارکواریت^۱ (trainlm) و پس‌انتشار تنظیم بیزین^۲ (trainbr) برای آموزش شبکه عصبی خودرگرسیون غیرخطی (با بهره‌گیری ابزار سری‌های زمانی شبکه عصبی^۳ نرم‌افزار MATLAB) استفاده می‌شود و الگوریتم آموزشی انتخاب می‌گردد که دارای نتایج بهتری باشد.

مدل هیبریدی

چگونه ترکیب کردن تکنیک‌های مختلف پیش‌بینی، موضوعی است که تحقیقات زیادی پیرامون آن صورت گرفته است. روش پیش‌بینی هیبریدی مطرح شده در این پژوهش بر مبنای ترکیب خطی نتایج متفاوت حاصل از مدل‌های پیش‌بینی مختلف است. بطور کلی اگر برای m مدل پیش‌بینی مختلف، f_{it} نشان دهنده مقدار پیش‌بینی شده در دوره t توسط مدل i ($i = 1, \dots, m$) و Y_t نیز مقدار واقعی سری در دوره t ($t = 1, \dots, n$) باشد، در این صورت مقدار پیش‌بینی شده توسط مدل هیبریدی به صورت زیر محاسبه می‌گردد (Wang, et al., 2012).

رابطه ۶)

$$\hat{Y}_{Hybrid}(t) = \sum_{i=1}^m w_i f_{it} \quad (t = 1, 2, \dots, n) \quad , \quad \sum_{i=1}^m w_i = 1$$

از آنجا که در این پژوهش درصدد ترکیب ۳ مدل می‌باشیم، یعنی ($m = 3$)، در نتیجه خطای پیش‌بینی مدل هیبریدی، در دوره t (e_t) برابر است با:

رابطه ۷)

$$e_t = y_t - \hat{y}_t = \sum_{i=1}^3 w_i y_t - \sum_{i=1}^3 w_i f_{it} = \sum_{i=1}^3 w_i (y_t - f_{it}) = \sum_{i=1}^3 w_i e_{it}$$

مشخص کردن وزن هر مدل، یکی از مهمترین گام‌ها در ایجاد مدل هیبریدی است. در ساده‌ترین حالت برای ترکیب ۳ مدل مذکور می‌توان از میانگین‌گیری ساده استفاده کرد، یعنی:

$$w_1 = w_2 = w_3 = \frac{1}{3}$$

1. Levenberg-Marquardt (LM)
2. Bayesian regulation backpropagation
3. Neural Network Time Series Tool

در این پژوهش، علاوه بر بکارگیری وزن‌های مساوی، از الگوریتم ژنتیک (GA)^۱ نیز برای مشخص کردن وزن‌های بهینه استفاده می‌شود. الگوریتم ژنتیک یکی از الگوریتم‌های جستجو می‌باشد که به صورت تصادفی جواب مسئله را پیدا می‌کند و در دسته الگوریتم‌های آزمون و خطا جای می‌گیرد (Eiben, et al., 2003). اصول "GA" بر پردازش تصادفی استوار است. بنابراین نیازی به اطلاعات پیشین ندارد، زیرا جمعیت اولیه به صورت تصادفی ایجاد می‌شود. فرآیند جستجو "GA" به ایجاد جمعیت تصادفی^۲، انتخاب و تولیدمثل^۳ (ادغام^۴ و جهش^۵) بستگی دارد که تمام این‌ها شامل عوامل تصادفی می‌باشد. بنابراین حتی تحت مجموعه پارامترهای یکسان، هربار اجرا کردن "GA" به تنهایی یک فرآیند جستجویی خواهد بود که ممکن است نتایج متفاوتی همراه داشته باشد (Wang, et al., 2012). به منظور بکارگیری الگوریتم ژنتیک برای دستیابی به وزن‌های بهینه در روش ترکیبی نیز از جعبه ابزار بهینه‌سازی نرم‌افزار MATLAB استفاده می‌شود.

معیارهای ارزیابی پیش‌بینی

معیارهای ارزیابی پیش‌بینی، مقادیر واقعی (Y_t) و پیش‌بینی (\hat{Y}_t) را مقایسه کرده و از این طریق، میزان خطای پیش‌بینی را اندازه‌گیری می‌کند. در این پژوهش به منظور بررسی کارایی پیش‌بینی مدل ترکیبی از ۴ معیار میانگین قدرمطلق خطا (MAE)^۶، ریشه میانگین مربعات خطا (RMSE)^۷، میانگین قدرمطلق درصد خطا (MAPE)^۸ و جهت دقت (DA)^۹ برای ارزیابی دقت پیش‌بینی استفاده شده است. این معیارها به صورت زیر محاسبه می‌شود:

$$MAE = T^{-1} \sum_{t=1}^T |Y_t - \hat{Y}_t| \quad \text{رابطه ۸}$$

$$RMSE = (T^{-1} \sum_{t=1}^T (Y_t - \hat{Y}_t)^2)^{\frac{1}{2}} \quad \text{رابطه ۹}$$

$$MAPE = T^{-1} \sum_{t=1}^T \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \quad \text{رابطه ۱۰}$$

$$DA = \frac{100}{T} \sum_{t=1}^T d_t, \quad d_t = \begin{cases} 1 & (Y_t - Y_{t-1})(\hat{Y}_t - \hat{Y}_{t-1}) \geq 0 \\ 0 & \text{در غیر این صورت} \end{cases} \quad \text{رابطه ۱۱}$$

1. Genetic Algorithm (GA)
2. Initialization
3. Reproduction
4. Crossover
5. Mutation
6. Mean Absolute Error (MAE)
7. Root Mean-Square Error (RMSE)
8. Mean Absolute Percentage Error (MAPE)
9. Directional Accuracy (DA)

Y_t : مقدار واقعی در زمان t ، \hat{Y}_t : مقدار پیش‌بینی شده در زمان t و T : اندازه نمونه است. معیارهای قدرمطلق خطا، ریشه میانگین مربعات خطا و میانگین قدرمطلق درصد خطا نشان‌دهنده تفاوت بین مقادیر واقعی و پیش‌بینی شده‌اند. بنابراین زمانی که مقادیر این معیارها کوچکتر باشد، عملکرد پیش‌بینی نیز بهتر خواهد بود. معیار جهت دقت که بر اساس درصد بیان می‌گردد، نشان‌دهنده درستی (صحت) جهت روند پیش‌بینی شده می‌باشد. به بیان دیگر، این معیار جهت‌های پیش‌بینی شده (حرکت رو به بالا/پایین) را نسبت به جهت‌های تحقق یافته^۱ (حرکت رو به بالا/پایین) مقایسه می‌کند. مقادیر بالاتر جهت دقت بیان‌گر این است که پیش‌بینی‌های بهتری انجام گرفته است (Wang, et al., 2012).

بررسی عملکرد پیش‌بینی

بررسی عملکرد پیش‌بینی یک مدل، از طریق تقسیم مجموعه داده‌های موجود به ۲ بخش دوره درون‌نمونه‌ای^۲ (برای برآورد اولیه پارامترها، انتخاب و برازش مدل بهینه استفاده می‌گردد) و دوره خارج از نمونه (برون‌نمونه‌ای)^۳ (به منظور ارزیابی عملکرد پیش‌بینی و بررسی استحکام^۴ مدل به کار می‌رود) انجام می‌شود. پیش‌بینی برون‌نمونه‌ای^۵، برای دوره بعد از برآورد مدل می‌باشد (سوری، ۱۳۹۲). در انجام آزمون خارج از نمونه‌ای می‌توان از یک مبداء پیش‌بینی^۶ یا چندین مبداء که اصطلاحاً به آن روش مبداء چرخان^۷ گفته می‌شود، استفاده کرد. در هنگام استفاده از حالت مبداء چرخان، هر به روز رسانی مبداء پیش‌بینی باعث اضافه شدن یک مشاهده جدید به دوره برازش و در نتیجه تنظیم مجدد پارامترها می‌گردد. از اینرو با توجه به اینکه تنظیم مجدد پارامترها، معیارهای خطا را نسبت به رویدادهای منحصر بفرود در دوره اصلی (اولیه) برازش مدل، بی‌تفاوت می‌کند، بعضاً محققان از بکارگیری یک دوره برازش با طول ثابت پشتیبانی کرده‌اند (Tashman, 2000).

داده‌های مورد نیاز تحقیق، مقادیر ماهیانه شاخص قیمت بورس تهران (TEPIX)^۸ طی سال‌های ۷۷ تا ۱۳۷۷/۱/۲۵) تا سال ۹۴ (۱۳۹۴/۶/۲۵) است که مشتمل بر ۲۱۰ مشاهده می‌باشد. در نمونه مذکور

1. Realized Directions
2. In-sample period
3. Out-sample period
4. Robustness
5. Forecasting
6. Forecasting origin


زمان پایانی در دوره برازش مدل (نقطه‌ای که پیش‌بینی‌ها از آنجا آغاز می‌گردد) به عنوان مبداء پیش‌بینی شناخته می‌شود.

7. Rolling origin
8. Tehran Exchange Price Index (TEPIX)

تعداد ۱۸۹ مشاهده (از تاریخ ۱۳۷۷/۱/۲۵ تا ۱۳۹۲/۹/۲۵) برای ایجاد مدل‌ها، انتخاب حالت بهینه و بدست آوردن پارامترهای مناسب هریک از ۳ مدل ترکیب شده می‌باشد و از تعداد ۲۱ مشاهده (از تاریخ ۱۳۹۲/۱۰/۲۵ تا ۱۳۹۴/۶/۲۵) برای ارزیابی میزان دقت پیش‌بینی‌ها و بررسی عملکرد مدل ترکیبی، به عنوان پیش‌بینی برون‌نمونه‌ای استفاده می‌شود. به عبارت دیگر، از نسبت مجموعه داده‌های آموزشی برابر با ۹۰ درصد اندازه نمونه^۱ استفاده شده است. شایان ذکر است که دلیل مهم استفاده از پارامترهای بهینه بدست آمده در بخش مجموعه داده‌های آموزشی در پیش‌بینی مقدار یک گام جلوتر^۲ جلوتر^۲ هریک از ۲۱ مشاهده با بکارگیری مدل‌های عنوان شده، بررسی توانایی (استحکام) و کارایی مدل ترکیبی مطرح شده است.

۴- یافته‌های پژوهش

نمودار (۱) نشان دهنده مقادیر ماهیانه سری زمانی شاخص قیمت بورس تهران از تاریخ ۱۳۷۷/۱/۲۵ تا ۱۳۹۴/۶/۲۵ است که مشتمل بر ۲۱۰ مشاهده می‌باشد.



شکل (۱): نمودار مقادیر ماهیانه سری زمانی شاخص قیمت بورس تهران

همانطور که مشاهده می‌گردد، مقادیر این سری در طول دوره مورد بررسی دارای نوساناتی بوده و در مشاهده ۱۸۹ ام یعنی در تاریخ ۱۳۹۲/۹/۲۵ به بالاترین مقدار (۴۴۳۱۹) رسیده است. تحلیل آماری داده‌های مورد بررسی در جدول (۱) منعکس گردیده است. این جدول مشخصات آماری و توصیفی مقادیر ماهیانه سری زمانی شاخص قیمت بورس تهران را طی سال‌های مذکور نشان می‌دهد

1. Training Dataset to Sample Size Ratio
2. One-step ahead value

جدول شماره (۱): آمار توصیفی داده‌ها

تعداد مشاهدات	میانگین	میانه	حداکثر
۲۱۰	۱۲۱۷۱/۷۳	۱۰۰۴۴/۵	۴۴۳۱۹
انحراف معیار	چولگی	کشیدگی	حداقل
۹۵۶۶/۱۷	۱/۲۹۸	۴/۲۷۷	۱۴۸۴
آماره جارک - برا		احتمال	
۷۳/۲۹۲		۰/۰۰۰	

به دلیل آنکه مقدار احتمال آماره جارک-برا (برای آزمون نرمال بودن) کمتر از ۰/۰۵ است، لذا فرضیه H_0 مبنی بر نرمال بودن سری رد می‌شود و در نتیجه سری زمانی تپیکس غیرنرمال است. نتایج آزمون نسبت واریانس بر مبنای علامت به منظور بررسی قابلیت پیش‌بینی پذیری سری "تپیکس" نیز در جدول (۲) ارائه شده است.


جدول (۲): نتایج آزمون نسبت واریانس بر مبنای علامت

احتمال	درجه آزادی	مقدار	آزمون مشترک
۰/۰۰۰۰	۲۰۸	۷/۷۶۵۳	Max Z (at period 20)
۰/۰۰۰۰	۱۹	۸۳/۷۷۴۰	Wald (Chi-Square)

نتایج جدول (۲) بیانگر آن است که با رد فرضیه صفر این آزمون (دال بر تصادفی بودن سری زمانی شاخص قیمت سهام)، هیچگونه شواهدی دال بر اینکه سری مذکور (و نیز سری وقفه‌های آن) از نوع فرآیندهای مارتینگلی^۱ (به بیان دیگر تصادفی) باشد، وجود نداشته و در نتیجه، فرآیند تولید داده در آنها تصادفی نمی‌باشد. به همین دلیل می‌توان به پیش‌بینی‌پذیر بودن این سری پی برد. در ادامه، مقایسه بین مقادیر واقعی و پیش‌بینی‌های صورت گرفته توسط هر یک از مدل‌های عنوان شده، به ترتیب در اشکال ۲ تا ۶ نشان داده شده است.

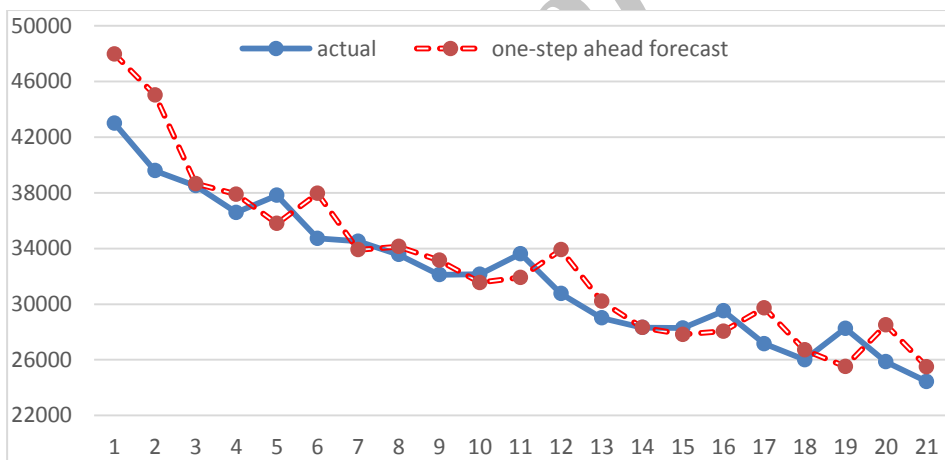
1. Martingale

۲. یک مارتینگیل دنباله‌ای است از بی‌نهایت متغیر تصادفی (به عبارتی دیگر یک فرآیند تصادفی) که در زمانی دلخواه از آن، امید ریاضی مقدار بعدی با مقدار مشاهده شده کنونی برابر است.



شکل (۲): نمودار مقایسه پیش‌بینی مدل همواری سازی نمایی با مقادیر واقعی


شکل (۲) نشان دهنده مقادیر ماهیانه شاخص قیمت در دوره برون‌نمونه‌ای (۲۱ مشاهده) و مقادیر پیش‌بینی شده آن توسط مدل هموارسازی نمایی دوگانه با پارامترهای $\alpha = 1$ و $\gamma = 0.2$ است. شکل (۳) نشان دهنده مقادیر ماهیانه شاخص قیمت در دوره برون‌نمونه‌ای و مقادیر پیش‌بینی شده آن توسط مدل $ARIMA(1,1,1)$ است:



شکل (۳): نمودار مقایسه پیش‌بینی مدل $ARIMA$ با مقادیر واقعی

به دلیل آنکه مدل‌های هموارسازی نمایی و آریما عمدتاً مربوط به داده‌هایی با ساختار خطی هستند اما مشاهدات واقعی شامل اجزای خطی و غیرخطی می‌باشد، همچنانکه در اشکال (۲) و (۳) مشخص است، مقادیر پیش‌بینی شده توسط این مدل‌ها مشخصات سری زمانی شاخص قیمت را به طور تقریبی تشریح می‌کند.


شکل (۴) نشان‌دهنده مقادیر ماهیانه شاخص قیمت در دوره برون‌نمونه‌ای و مقادیر پیش‌بینی شده آن توسط مدل شبکه عصبی خودرگرسیون غیرخطی (NAR) با $d = 4$ ، تعداد نرون‌های لایه مخفی برابر ۸ و همچنین الگوریتم آموزش لونیگ-مارکواریت است:



شکل (۴): نمودار مقایسه پیش‌بینی مدل NAR با مقادیر واقعی


همچنان که در شکل (۴) مشخص است، در برخی نقاط اختلاف بین مقادیر واقعی و پیش‌بینی شده نسبتاً بالا است که نشان‌دهنده حساسیت شبکه عصبی مذکور به برآزش مجدد و بدست آوردن پارامترهای بهینه به منظور پیش‌بینی مقدار یک مرتبه جلوتر هر یک از مشاهدات است.

شکل (۵) نشان‌دهنده مقادیر ماهیانه شاخص قیمت در دوره برون‌نمونه‌ای و مقادیر پیش‌بینی شده آن توسط مدل ترکیبی با استفاده از وزن‌های مساوی است:



شکل (۵): نمودار مقایسه بکارگیری وزن‌های مساوی در مدل پیش‌بینی ترکیبی با مقادیر واقعی

شکل (۶) نشان دهنده مقادیر ماهیانه شاخص قیمت در دوره برون‌نمونه‌ای و مقادیر پیش‌بینی شده آن توسط مدل ترکیبی با استفاده از وزن‌های حاصل از الگوریتم ژنتیک است:



شکل (۶): نمودار مقایسه بکارگیری وزن‌های حاصل از "GA" در مدل پیش‌بینی ترکیبی با مقادیر واقعی

اشکال (۵) و (۶) به وضوح نشان می‌دهد که روش ترکیبی عنوان شده به دلیل دربرگرفتن ساختارهای خطی و غیرخطی موجود در داده‌ها، سری زمانی شاخص قیمت را نسبتاً بهتر پیش‌بینی کرده و تفاوت بین مقادیر واقعی و پیش‌بینی شده به ویژه در هنگام استفاده از وزن‌های مساوی کاهش می‌یابد.

در نهایت، به منظور مقایسه عملکرد هریک از ۵ مدل عنوان شده از معیارهای ارزیابی، میانگین قدرمطلق خطا، ریشه میانگین مربعات خطا، میانگین قدرمطلق درصد خطا و جهت دقت استفاده می‌شود. جدول (۳) نشان دهنده نتایج این معیارهای ارزیابی برای پیش‌بینی مقادیر ماهیانه شاخص قیمت در دوره برون‌نمونه‌ای (۲۱ مشاهده) توسط مدل‌های هموارسازی نمایی، آریمای، شبکه عصبی خودرگرسیون غیرخطی، هیبریدی با وزن‌های مساوی و هیبریدی با وزن‌های حاصل از الگوریتم ژنتیک است.

جدول (۳): نتایج معیارهای ارزیابی عملکرد برای مدل‌های مختلف

مدل‌ها	هموارسازی نمایی	میانگین متحرک خودرگرسیون انباشته	شبکه عصبی خودرگرسیون غیرخطی	هیبریدی با وزن های مساوی	هیبریدی با وزن‌های حاصل از الگوریتم ژنتیک
میانگین قدرمطلق خطا	۱۸۳۱	۱۷۹۳/۶	۱۸۷۰/۷	۱۷۶۷/۸	۱۷۹۳/۶
ریشه میانگین مربعات خطا	۲۲۷۱/۶	۲۳۱۰/۶	۲۴۷۲/۹	۲۱۵۷/۱	۲۳۰۷/۹
میانگین قدرمطلق درصد خطا	٪۵/۵۴	٪۵/۴۷	٪۶/۲۰	٪۵/۵۴	٪۵/۴۷
جهت دقت	٪۶۵	٪۶۵	٪۶۰	٪۶۵	٪۶۰

نتایج جدول (۳) نشان می‌دهد مدل پیش‌بینی هیبریدی با وزن‌های مساوی در معیارهای میانگین قدرمطلق خطا (۱۷۶۷/۸) و ریشه میانگین مربعات خطا (۲۱۵۷/۱) دارای خطای کمتری نسبت به ۳ مدل تشکیل دهنده آن است. همچنین در معیار میانگین قدرمطلق درصد خطا، مدل‌های پیش‌بینی هیبریدی دارای خطایی کمتر از مدل شبکه عصبی (٪۶/۲۰) و برابر با مدل‌های هموارسازی نمایی (٪۵/۵۴) و آریما (٪۵/۴۷) است. بعلاوه معیار "جهت دقت"، مدل‌های هیبریدی نیز برابر با مدل‌های تشکیل دهنده آن است. بنابراین با ثابت در نظر گرفتن مجموعه داده‌های آموزشی و عدم تجدید نظر در مورد پارامترهای بهینه هریک از ۳ مدل ترکیب شده در هنگام اضافه شدن مقدار واقعی کنونی برای پیش‌بینی یک گام جلوتر، نتایج بدست آمده بیانگر برتری نسبی مدل پیش‌بینی هیبریدی به ویژه در زمان استفاده از وزن‌های مساوی نسبت به هریک از مدل‌های تشکیل دهنده آن می‌باشد.

۵- نتیجه‌گیری و پیشنهادها

پیش‌بینی یکی از چالش‌های اساسی فعالان بازار سرمایه، اعم از سرمایه‌گذاران حقیقی و حقوقی است. در شرایط واقعی نیز شناسایی حرکات^۱ سری زمانی شاخص قیمت سهام بسیار پیچیده می‌باشد. بنابراین استفاده از یک مدل کلاسیک به تنهایی نمی‌تواند پیش‌بینی دقیقی از شاخص‌های قیمت سهام داشته باشد. از این رو با بکارگیری روش‌های ترکیبی می‌توان عدم اطمینان در پیش‌بینی را کاهش داد. در این پژوهش روشی هیبریدی با ترکیب رایج‌ترین مدل‌های خطی (مدل‌های هموارسازی نمایی و میانگین متحرک خودرگرسیون انباشته) و پرکاربردترین مدل غیرخطی (تکنیک شبکه عصبی)، مطرح و بر

1. Dynamics

روی مقادیر ماهیانه شاخص قیمت بورس اوراق بهادار تهران بکار گرفته شد. ایده اصلی مدل هیبریدی نیز علاوه بر کاهش ریسک انتخاب مدل نامناسب، به طور مؤثر بدست آوردن حالت‌ها و شکل‌های مختلف روابط میان داده‌های سری زمانی شاخص قیمت سهام می‌باشد. بطور کلی بررسی تطبیقی نتایج تحقیق حاضر با سایر تحقیقات حاکی از آن است که یافته‌های این پژوهش مطابق با اکثریت مطلق تحقیقات صورت گرفته در این حوزه، نشان‌دهنده مؤثر بودن روش‌های پیش‌بینی ترکیبی به منظور کاهش خطا می‌باشد. برای مثال همانطور که در این پژوهش مشخص شد، مطابق با شواهد و یافته‌های تئوری و تجربی ژانگ (Zhang, 2003)؛ وانگ و همکاران (Wang, et al., 2012)؛ ژائو و همکاران (Zhao, et al., 2014) ترکیب مدل‌های مختلف پیش‌بینی می‌تواند روشی مؤثر برای ارتقاء عملکرد پیش‌بینی هر یک از مدل‌های منحصربفرد باشد. همچنین نتایج ارائه شده مطابق با یافته‌های استاک و همکاران (Stock, et al., 2006) و تیمرمن (Timmermann, 2006) که نشان‌دهنده مزیت‌های بوجود آمده در دقت پیش‌بینی از طریق ترکیب پیش‌بینی‌ها، به ویژه در حالت استفاده از روش میانگین‌گیری ساده (وزن‌های مساوی) می‌باشد. با وجود توافق گسترده در مورد ارتقاء دقت پیش‌بینی با استفاده از پیش‌بینی‌های ترکیبی، اما هنوز اجماع و توافقی روی نحوه ترکیب و وزن‌دهی به پیش‌بینی‌های مختلف وجود ندارد. پژوهش حاضر نشان داد با ترکیب نتایج پیش‌بینی مدل‌های مختلف امکان توسعه و گسترش مدل هیبریدی قدرتمندی به منظور پیش‌بینی‌های دقیق‌تری برای سری زمانی بسیار پیچیده شاخص قیمت سهام فراهم می‌گردد. همچنین در روش هیبریدی مطرح شده در این تحقیق، هیچ فرض اولیه‌ای برای نوع روابط موجود بین اجزای خطی و غیرخطی در نظر گرفته نشد. لذا می‌توان استنتاج کرد در مواردی که خطی یا غیرخطی بودن کامل الگوهای موجود در سیستم مشخص نبوده و سیستم مورد مطالعه شامل هر دو نوع الگو می‌باشد (برای مثال بازار بورس) و ضمناً هیچ پیش‌فرضی نیز در مورد نوع این روابط وجود ندارد، مدل هیبریدی مذکور می‌تواند نتایج مطلوبتری ارائه نماید. بنابراین سرمایه‌گذاران و تحلیلگران می‌توانند به کمک این مدل پیش‌بینی‌های بهتری داشته باشند.

موضوع تحقیقات آتی می‌تواند بررسی امکان ترکیب سایر ابزارها و مدل‌های پیش‌بینی و یا استفاده از سایر روش‌های موجود برای ترکیب و وزن‌دهی به مدل‌های مختلف باشد. همچنین می‌توان نتایج حاصل از روش‌های کیفی که اهمیت و توجه بیشتری برای تجربیات و قضاوت‌های افراد کاردان و خیره قائل می‌شود را با روش‌های کمی ترکیب کرده تا بدین ترتیب بتوان به نوعی بر محدودیت‌های روش‌های کمی در این زمینه غلبه کرد و نهایتاً پیش‌بینی‌های بهتری انجام داد.

منابع و مآخذ

۱. خاشعی، مهدی و بیجاری، مهدی (۱۳۸۷)، "بهبود عملکرد پیش‌بینی‌های مالی با ترکیب مدل‌های خطی و غیرخطی خودرگرسیون متحرک انباشته و شبکه‌های عصبی مصنوعی"، فصلنامه پژوهش‌های اقتصادی، شماره دوم.
۲. سعیدی، حسین و محمدی، شاپور (۱۳۹۱)، "پیش‌بینی نوسانات بازده بازار با استفاده از مدل‌های ترکیبی گارچ - شبکه عصبی"، فصلنامه بورس اوراق بهادار، شماره ۱۶.
۳. سلیمی فر، مصطفی و شیرزور، زهرا (۱۳۸۹)، "بررسی کارایی اطلاعاتی بورس اوراق بهادار به روش آزمون نسبت واریانس"، مجله مهندسی مالی و مدیریت پرتفوی، شماره پنجم.
۴. سوری، علی (۱۳۹۲). اقتصاد سنجی، تهران، نشر فرهنگ شناسی.
۵. محمدی، شاپور، راعی، رضا و کرمی، حسین (۱۳۹۴)، "پیش‌بینی قیمت هفتگی نفت خام از طریق مدل ترکیبی ماشین بردار پشتیبان و خودرگرسیو میانگین متحرک انباشته"، فصلنامه علمی پژوهشی دانش سرمایه‌گذاری، شماره چهاردهم.

6. Anderson, D. R., Sweeney, D. J. & Williams, T. A. (1998). Quantitative Methods for Business. Cincinnati, south-western educational publishing.
7. Bates J. M., & Granger C. W. J. (1969). "The Combination of Forecasts". Operational Research Society, 20(4): 451-468.
8. Eiben, A. E. & Smith, J. E. (2003). Introduction to Evolutionary Computing, New York, SpringerVerlag ©2003, New York.
9. Gibbs, C. (2013). "Forecast Combination in the Macroeconomy". University of Oregon. 1-52.
10. Hwang, B. (2001). "Insights into Neural-Network Forecasting Time Series Corresponding to ARMA (p,q) Structures". Omega, 29: 273-289.
11. Khashei, M. & Bijari, M. (2010) "An artificial neural network (p,d,q) model for time series forecasting" Expert Systems with Applications, 37: 479-489.
12. Nazarian, R., Alikhani, N., Naderi, E. & Amiri, A. (2013). "Forecasting Stock Market Volatility: A Forecast Combination Approach". Munich Personal RePEc Archive. Online at <http://mpra.ub.uni-muenchen.de/46786/>.
13. Stock, J. & Watson, M. (2006). "Forecasting With Many Predictors". Handbook of Economic Forecasting, Elsevier B.V. 1: 516-550.
14. Tashman, L. (2000). "Out-of-sample tests of forecasting accuracy: an analysis and review". International Journal of Forecasting, 16: 437-450.

15. Teräsvirta, T. (2006). "Univariate time series models". Palgrave Handbook of Econometrics, (Econometric Theory): 1: 396-424.
16. Timmermann, A (2006) "Forecast Combinations", Handbook of Economic Forecasting, Elsevier B.V. 1: 135-196.
17. Wang, J. J, Wang, J. Z, Zhang, Z. G. & Guo, S. P. (2012). "Stock index forecasting based on a hybrid model". Omega, 40: 758–766.
18. Zhao, W., Wang, J. & Lu, H. (2014). "Combining forecasts of electricity consumption in China with time-varying weights updated by a high-order Markov chain model". Omega, 45: 80-91.
19. Zhang, G. P. (2003). "Time series forecasting using a hybrid ARIMA and neural network model". Neurocomputing, 50: 159–175.

Archive of SID