

مقایسه‌ی پیش‌بینی شاخص سهام با استفاده از مدل‌های ترکیبی مبتنی بر الگوریتم ژنتیک و جستجوی هارمونی با شبکه‌ی عصبی معمولی

* مریم دولو * و تکتم حیدری *

تاریخ وصول: ۱۳۹۶/۰۵/۱۱ تاریخ پذیرش: ۱۳۹۷/۰۸/۰۶

چکیده

هدف پژوهش حاضر، مقایسه‌ی پیش‌بینی شاخص سهام با استفاده از مدل‌های ترکیبی مبتنی بر الگوریتم ژنتیک و جستجوی هارمونی با شبکه‌ی عصبی معمولی است. مربوط‌ترین نماگرها تکنیکی، به عنوان متغیرهای ورودی و تعداد بهینه نرون لایه‌ی پنهان شبکه‌ی عصبی مصنوعی با استفاده از الگوریتم‌های فراابتکاری ژنتیک و جستجوی هارمونی تعیین شده است. مقادیر روزانه‌ی شاخص قیمت بورس اوراق بهادار تهران از تاریخ ۹۱/۱۰/۱ الی ۹۴/۹/۳۰ جهت پیش‌بینی شاخص قیمت و آزمون آن، استفاده شده است. دقت پیش‌بینی سه مدل شبکه‌ی عصبی معمولی، شبکه‌ی عصبی هیبریدی مبتنی بر الگوریتم ژنتیک و شبکه‌ی عصبی هیبریدی مبتنی بر جستجوی هارمونی بر اساس میزان خطای پیش‌بینی ارزیابی شده است. نتایج این پژوهش، نشان می‌دهد که دقت پیش‌بینی مدل‌های فراابتکاری ژنتیک و جستجوی هارمونی در دوره‌ی آزمون بالاتر از شبکه‌ی عصبی عادی است؛ همچنین پیش‌بینی مدل شبکه‌ی عصبی هیبریدی مبتنی بر جستجوی هارمونی در دوره‌ی آزمون نسبت به مدل شبکه‌ی عصبی مصنوعی هیبریدی مبتنی بر الگوریتم ژنتیک از دقت بالاتری برخوردار است.

G17:JEL طبقه‌بندی

واژه‌های کلیدی: الگوریتم ژنتیک، جستجوی هارمونی، شبکه‌ی عصبی مصنوعی

* استادیار، دانشکده‌ی مدیریت و حسابداری، دانشگاه شهید بهشتی، تهران، ایران. (نویسنده مسئول).

(ma_davallou@yahoo.com)

** دانشجوی کارشناسی ارشد مدیریت مالی، دانشگاه ارشاد دماوند، تهران، ایران.

۱- مقدمه

بازار سهام، همواره نقشی مهم در توسعه‌ی اقتصادی کشورها ایفا می‌کند. شاخص بازار، نشانگر سطح کلی و نیز تغییرات بازار سهام است. این شاخص از دیدگاه کلان، مبنای تصمیمات ملّی و از دیدگاه خرد، اساس استراتژی سرمایه‌گذاران قرار می‌گیرد (جیان و سانگ^۱. ۲۰۱۷). پیش‌بینی بازار سهام، چالش اصلی حوزه‌های عملی و نظری مدیریت نوین ریسک است؛ از جمله ویژگی‌های تأیید شده سری‌های زمانی مالی، شامل خوشبندی نوسان‌پذیری^۲، خودهمبستگی و پدیده نوسان‌پذیری نامتقارن^۳ است (گورینین^۴ و همکاران، ۲۰۱۷).

بسیاری از پژوهش‌گران، پیش‌بینی بازده بازار سهام را با استفاده از روش‌های تحلیل تکنیکی^۵، تحلیل بنیادی^۶، سری‌های زمانی کلاسیک^۷ و روش‌های هوشمند^۸ مورد بررسی قرار داده‌اند (پراسانا و اژilmaran^۹. ۲۰۱۳). تحلیل‌گران تکنیکی، سعی می‌کنند از طریق دنبال‌کردن الگوهای موجود و استفاده از اطلاعات گذشته‌ی مربوط به بازار، روند بازده آتی بازار را پیش‌بینی کنند. این گروه، معتقد‌ند محاسبه‌ی ارزش ذاتی سهام، باید بر اساس الگوی تاریخی رفتار قیمت سهام و اطلاعات مالی شرکت‌ها انجام گیرد. تحلیل‌گران بنیادی، رفتار قیمت سهام را دارای حرکت تصادفی دانسته‌اند و با توجه به ارزش واقعی و ذاتی سهام، اقدام به پیش‌بینی می‌کنند. روش سری زمانی با تحلیل اطلاعات و داده‌های گذشته و با استفاده از ترکیب خطی قیمت‌ها، ارزش آتی سری زمانی را تخمین می‌زنند.

در پیش‌بینی مبتنی بر روش‌های کلاسیک، فرض بر آن است که مقادیر آینده‌ی قیمت، سیر خطی مقادیر گذشته را می‌پیماید. این روش در علم اقتصاد به رگرسیون ساده و چند متغیره شهرت دارد. روش‌های هوشمند، الگوهای خطی و غیرخطی موجود در داده‌های مربوط به بازار را دنبال می‌کند تا بدین وسیله فرایند ایجاد آن‌ها را حدس بزند. بر این اساس، تاکنون الگوریتم‌ها و نرم‌افزارهای زیادی با پیچیدگی‌ها

¹ Jian and Song

² Volatility Clustering

³ Asymmetric Volatility

⁴ Gorynin

⁵ Technical Analysis

⁶ Fundamental Analysis

⁷ Traditional Time Series

⁸ Machine Learning

⁹ Prasanna and Ezhilmaran

و ساختارهای متفاوت برای این منظور پیشنهاد شده است. در این میان الگوریتم‌های مختلف شبکه‌ی عصبی مصنوعی^{۱۰}، با توجه به ویژگی‌های منحصر به فرد آن، به عنوان ابزاری قدرتمند برای پیش‌بینی و تحلیل داده‌های بازار سهام مورد توجه قرار گرفت و بسیاری از محققان از مدل‌های شبکه‌ی عصبی به عنوان پیشگو استفاده می‌کنند. چندین سال است که از روش شبکه‌ی عصبی مصنوعی برای پیش‌بینی بازده قیمت سهام استفاده می‌شود. روش مذکور، نسبت به سایر روش‌ها رضایت‌بخش بوده است؛ اما در عین حال دارای برخی نقاط ضعف است. تعیین مجموعه‌ی بهینه متغیرهای ورودی، یکی از مشکلات اصلی ساختار شبکه‌ی عصبی مصنوعی است؛ زیرا انتخاب متغیرهای ورودی به‌طور مستقیم بر دقت پیش‌بینی اثرگذار است. یکی دیگر از اشکالات شبکه‌ی عصبی مصنوعی، نبود روشی منحصر به فرد برای تعیین تعداد نرون‌ها^{۱۱} در لایه‌ی پنهان است؛ بنابراین پژوهشگران به‌صورت تجربی و آزمون و خطا این تعداد را مشخص می‌کنند. جهت رفع این نقیصه، در پژوهش حاضر همانند گوچن^{۱۲} و همکاران (۲۰۱۶) از دو روش هیبریدی^{۱۳} برای انتخاب متغیرهای ورودی بهینه و تعداد بهینه نرون‌های لایه‌ی پنهان استفاده شده است. روش‌های هیبریدی موردنظر، ماحصل ترکیب شبکه‌ی عصبی مصنوعی با الگوریتم ژنتیک^{۱۴} و جستجوی هارمونی^{۱۵} است. الگوریتم ژنتیک^{۱۶} و جستجوی هارمونی^{۱۷} به‌عنوان ابزارهایی برای بهبود پیش‌بینی شبکه‌ی عصبی مصنوعی به کار می‌رود. در این پژوهش با استفاده از

¹⁰ Artificial Neural Network

¹¹ Neurons

¹² Göçken

¹³ Hybrid

¹⁴ Genetic Algorithm

¹⁵ Harmony Search

^{۱۶} الگوریتم ژنتیک از طریق شبیه‌سازی فرایندهای ژنتیک طبیعی می‌کشد تا مسائل دنیای واقعی را حل کند. امروزه الگوریتم ژنتیک جای خود را در میان روش‌های بهینه‌سازی حل مسائل پیچیده به خوبی باز کرده است. این الگوریتم از لحاظ محاسباتی ساده‌امان قدرتمند است و فرضیات محدود کننده در خصوص فضای جستجو، آن را محدود نمی‌نماید (منجمی، ایزرا و رعیتی شوازی، ۱۳۸۸).

^{۱۷} جستجوی هارمونی یک روش جستجوی هوشمندانه است که در حل مسائل بهینه‌سازی استفاده می‌شود. این الگوریتم جزء الگوریتم‌های تکاملی است که با شروع از یک حالت اولیه و با یک روش مرحله‌ای جواب یافته شده را مرحله به مرحله بهبود می‌دهد (گیم، ۲۰۰۹).

نمایگرها تکنیکی^{۱۸} بازار سهام ایران و مدل‌های شبکه عصبی هیبریدی مبتنی بر الگوریتم ژنتیک و شبکه عصبی هیبریدی مبتنی بر جستجوی هارمونی به پیش‌بینی شاخص قیمت سهام پرداخته شده است. با استفاده از این دو مدل، مربوطترین (بهینه‌ترین) متغیرهای ورودی (نمایگرها تکنیکی) تعیین می‌شود؛ علاوه بر این، به صورت همزمان مناسب‌ترین تعداد نرون لایه‌ی پنهان شبکه‌ی عصبی مصنوعی به دست می‌آید؛ سپس دو مدل هیبریدی مذکور با مدل شبکه‌ی عصبی عادی و نیز با یکدیگر از حیث معیارهای خطای آماری مقایسه شده و مدل حائز بالاترین دقت پیش‌بینی مشخص می‌شود. بهبود پیش‌بینی، باعث می‌شود ریسک سرمایه‌گذاران کاهش یافته و سرمایه‌گذاران به سرمایه‌گذاری بیشتری گرایش یابند. در این پژوهش، برای نخستین بار در بورس اوراق بهادار تهران از جستجوی هارمونی برای انتخاب متغیرهای ورودی بهینه و تعداد بهینه نرون‌های لایه‌ی پنهان شبکه عصبی مصنوعی و از الگوریتم ژنتیک برای تعیین تعداد نرون‌های بهینه لایه پنهان شبکه عصبی مصنوعی استفاده شده است. در پژوهش‌های پیشین از الگوریتم ژنتیک صرفاً برای انتخاب بهینه ویژگی‌ها (متغیرها) و همچنین تعیین وزن بهینه مدل‌های ترکیبی و شبکه عصبی مصنوعی استفاده شده است.

۲- مبانی نظری و پیشینه پژوهش

علوی (۱۳۸۵) به دلیل ماهیت غیرخطی رفتار قیمت سهام، از مدل‌های غیرخطی شاخه‌های هوش مصنوعی شامل الگوریتم ژنتیک، شبکه‌ی عصبی فازی و شبکه‌ی عصبی مصنوعی برای پیش‌بینی قیمت سهام استفاده کرده است. وی با ترکیب تحلیل تکنیکی و هوش مصنوعی به پیش‌بینی پرداخت. ورودی مدل شامل نمایگرهای تکنیکی است که به دلیل تعداد زیاد، هشت نمایگر ویلیام، (MFI)^{۱۹}، اسیلاتور قیمت، میانگین متحرک همگرایی/واگرایی (MACD)^{۲۰}، قدرت نسبی (RSI)^{۲۱}، نرخ تغییر (ROC)^{۲۲}، میانگین متحرک و اسیلاتور تصادفی مورد استفاده قرار گرفت. نتایج حاصل از مدل‌ها بر اساس اطلاعات ۳۰ شرکت، نشان داده است که بدون نظر گرفتن

¹⁸ Technical Indicators

¹⁹ Money Flow Index

²⁰ Moving Average Convergence Divergence

²¹ Relative Strength Index

²² Rate-of-Change

هزینه‌های معاملاتی، بین روش‌های مورد آزمون تفاوت معناداری وجود ندارد؛ اما در صورت احتساب هزینه‌های معاملاتی، میانگین بازده روش شبکه‌ی عصبی مصنوعی و روش تحلیل تکنیکی با یکدیگر برابر بوده و نسبت به دو روش دیگر، یعنی الگوریتم ژنتیک و شبکه‌ی عصبی فازی برتر است.

منجمی، ابزری و رعیتی شوازی (۱۳۸۸) به پیش‌بینی قیمت سهام با استفاده از شبکه‌ی عصبی فازی، الگوریتم ژنتیک و شبکه‌ی عصبی مصنوعی عادی پرداخته‌اند. نتایج به دست آمده از پژوهش ایشان نشان داد که مدل ترکیبی شبکه‌های عصبی فازی و الگوریتم ژنتیک، پیش‌بینی مناسب‌تری داشته و نسبت به شبکه‌ی عصبی عادی، از توان تقریب قوی‌تری جهت پیش‌بینی قیمت سهام برخوردار است.

استیری (۱۳۹۲) برای پیش‌بینی شاخص بورس اوراق بهادار تهران و به منظور شناسایی الگوهای خطی و غیرخطی، سری زمانی شاخص از مدل‌های خطی هموارسازی نمایی، خودتوضیح میانگین متحرک انباسته (ARIMA)^{۲۳} و مدل غیرخطی شبکه‌ی عصبی مصنوعی استفاده کرده است. وی روش الگوریتم ژنتیک را به عنوان روش تکاملی بهینه‌سازی برای تعیین اوزان بهینه‌ی هریک از سه روش مذکور به کار گرفته است. پیش‌بینی با استفاده از مدل‌های هموارسازی نمایی، خودتوضیح میانگین متحرک انباسته (ARIMA) و شبکه‌ی عصبی مصنوعی در مرحله‌ی اول با وزن برابر و سپس با اوزان بهینه حاصل از الگوریتم ژنتیک انجام شده است. نتایج به دست آمده از پژوهش وی، حاکی از برتری توان پیش‌بینی مدل ترکیبی پیشنهادی (که اوزان بهینه آن توسط الگوریتم ژنتیک تعیین شده است) نسبت به روش‌های دیگر است.

کاربرد شبکه‌های عصبی در اقتصاد از اواخر دهه‌ی ۸۰ با مطالعه‌ی وايت^{۲۴} (۱۹۸۸) در بازارهای مالی و پیش‌بینی قیمت سهام شرکت IBM آغاز شد. هوانگ، یانگ و چوانگ^{۲۵} (۲۰۰۸) جهت پیش‌بینی روند بازار سهام از روش‌های پوششی برای انتخاب متغیرهای مدل و ترکیب روش‌های هوش مصنوعی برای طبقه‌بندی مدل استفاده کردند. آن‌ها از روش پوششی برای انتخاب زیرمجموعه بهینه متغیرهای مدل استفاده کردند که متشکل از ۲۳ نماگر تکنیکی است. آن‌ها با

²³ AutoRegressive Integrated Moving Average

²⁴ White

²⁵ Huang, Yang & Chuang

استفاده از یک طرح انتخاب متغیر پیشنهادی که ترکیب الگوریتم‌های طبقه‌بندی رایج است، جهت تغییرات روزانه شاخص بازار سهام کره و تایوان را پیش‌بینی کردند؛ بدین‌گونه که اگر شاخص روز بعد نسبت به روز قبل با افزایش مواجه بود، با "۱" و در صورت کاهش با "-۱" مشخص می‌شد. نمونه‌ی پژوهش شامل ۳۶۵ روز معاملاتی بود که ۲۹۴ مشاهده برای آموزش مدل و ۷۱ مشاهده برای آزمون استفاده شده است.^{۲۶} نتایج به دست آمده نشان می‌دهد رویکرد پوششی می‌تواند عملکرد بهتری نسبت به فیلترهای معمول داشته باشد.

وانگ^{۲۷} و همکاران (۲۰۱۲) با استفاده از مدل هموارسازی نمایی، خودتوضیح میانگین متحرک انباسته، شبکه‌ی عصبی و مدل ترکیبی پیشنهادی به پیش‌بینی شاخص بورس شانگهای و شاخص داو جونز پرداخته‌اند. مدل پیشنهادی آن‌ها ترکیبی از وزن‌های بهینه مدل هموارسازی نمایی، خودتوضیح میانگین متحرک انباسته و شبکه عصبی است که وزن‌های بهینه از طریق الگوریتم ژنتیک به دست آمده است. ایشان از معیارهای میانگین قدر مطلق خطأ (MAE)^{۲۸}، ریشه‌ی میانگین مربعات خطأ (RMSE)^{۲۹} و میانگین قدر مطلق درصد خطأ (MAPE)^{۳۰} برای ارزیابی عملکرد مدل‌های مذکور استفاده کرده و نشان می‌دهند مدل ترکیبی در مقایسه با مدل هموارسازی نمایی، خودتوضیح میانگین متحرک انباسته و شبکه‌ی عصبی از عملکرد بهتری برخوردار است.

لابویسیر، فرناندز و لاغ^{۳۱} (۲۰۱۵) با استفاده از شبکه‌ی عصبی مصنوعی به پیش‌بینی بیشترین و کمترین قیمت روزانه سهام شرکت‌های توزیع برق بزرگ پرداخته‌اند. در این پژوهش از تجزیه و تحلیل همبستگی برای انتخاب متغیرهای ورودی استفاده شده است. ساختارهای متفاوت شبکه‌ی عصبی مصنوعی به صورت تجربی (آزمون و خطأ) مورد بررسی قرار گرفته و مشخص شده است که شبکه‌ی عصبی مصنوعی با یک لایه پنهان و پنج نرون در آن، قادر است بهترین پیش‌بینی را ارائه کند.

^{۲۶} یعنی حدود ۸۰ درصد داده‌ها برای آموزش مدل و ۲۰ درصد برای آزمون مدل منظور گردید.

²⁷ Wong

²⁸ Mean Absolute Error

²⁹ Root-Mean-Square Error

³⁰ Mean Absolute Percent Error

³¹ Laboissiere, Fernandes and Lage

گوچن و همکاران (۲۰۱۶) با استفاده از نماگرهای تحلیل تکنیکی و شبکه‌ی عصبی مصنوعی هیبریدی مبتنی بر الگوریتم ژنتیک و جستجوی هارمونی به پیش‌بینی شاخص قیمت بازار سهام ترکیه پرداخته‌اند. نتایج به‌دست آمده از پژوهش آنان نشان می‌دهد که خطای پیش‌بینی مدل‌های هیبریدی فرا ابتکاری از شبکه‌ی عصبی مصنوعی پایین‌تر است. آن‌ها با مقایسه‌ی معیارهای خطای مدل شبکه‌ی عصبی هیبریدی مبتنی بر الگوریتم ژنتیک و شبکه عصبی هیبریدی مبتنی بر جستجوی هارمونی از مدل هیبریدی مبتنی بر الگوریتم ژنتیک پایین‌تر است.

معماری یا ساختار شبکه‌ی عصبی مصنوعی، دارای اهمیّت بسیاری است و به‌طور مستقیم بر عملکرد آن مؤثر است؛ به همین دلیل، بسیاری از پژوهش‌های پیشین، بر بهبود معماری شبکه‌ی عصبی مصنوعی، متمرکز شده بود. از جمله موارد مهم معماری شبکه‌ی عصبی، انتخاب متغیرهای ورودی و تعیین تعداد نرون‌های لایه‌ی پنهان است. وجه تمایز پژوهش حاضر، انتخاب مربوط‌ترین متغیرهای ورودی و تعیین تعداد نرون‌های لایه‌ی پنهان با تغییر ساختار شبکه‌ی عصبی مصنوعی از طریق روش‌های ابتکاری مبتنی بر الگوریتم ژنتیک و جستجوی هارمونی است که برای نخستین بار در بورس اوراق بهادار تهران انجام شده است.

۳- روش‌شناسی

پژوهش حاضر، با هدف ارزیابی توان پیش‌بینی مدل‌های ترکیبی مبتنی بر الگوریتم ژنتیک و جستجوی هارمونی با شبکه‌ی عصبی معمولی در پی پاسخ به پرسش‌های ذیل است:

- ✓ آیا مدل‌های شبکه‌ی عصبی مصنوعی هیبریدی مبتنی بر الگوریتم ژنتیک و جستجوی هارمونی، نسبت به مدل شبکه‌ی عصبی عادی از دقت بالاتری برخوردار است؟
- ✓ آیا مدل شبکه‌ی عصبی مصنوعی هیبریدی مبتنی بر الگوریتم ژنتیک نسبت به مدل شبکه‌ی عصبی مصنوعی هیبریدی مبتنی بر جستجوی هارمونی از دقت بالاتری برخوردار است؟

پژوهش حاضر، شامل دو بخش اصلی است: اول، محاسبه‌ی نماگرهای تکنیکی و انتخاب بهینه‌ی آن‌ها توسط الگوریتم ژنتیک و جستجوی هارمونی. دوم، پیش‌بینی شاخص قیمت سهام با استفاده از شبکه‌ی عصبی ایجاد شده و مقایسه‌ی خطای پیش‌بینی مدل‌ها. برای این منظور، مقادیر روزانه شاخص قیمت بورس اوراق بهادار

تهران در بازه‌ی زمانی ۱۳۹۱/۱۰/۱ الی ۱۳۹۴/۹/۳۰ به دو قسمت برآش و آزمون تقسیم شده است تا با الگوریتم‌های هوش مصنوعی مورد تحلیل قرار گرفته و شاخص روز بعد را پیش‌بینی کند. با توجه به اینکه همه‌ی مدل‌های این پژوهش از شبکه‌ی عصبی مصنوعی استفاده شده است، همانند گوچن و همکاران (۲۰۱۶) برای دوره‌ی برآش از ۷۰ درصد و برای آموزش از ۱۵ درصد مشاهدات استفاده شده است. ۱۵ درصد باقیمانده‌ی مشاهدات نیز، جهت تأیید و اعتبارسنجی مدل استفاده شده است. مدل‌ها با ۹ معیار خطای پیش‌بینی مقایسه شده‌است.

نهاده‌ی ورودی مدل‌ها، مشتمل بر ۴۲ نماگر تکنیکی است. با استفاده از الگوریتم ژنتیک و الگوریتم جستجوی هارمونی از بین ۴۲ متغیر ورودی، بهترین متغیرها انتخاب شده و با استفاده از شبکه‌ی عصبی مصنوعی، شاخص قیمت روز بعد پیش‌بینی شده است. متغیرهای مذکور، برای آن که بتوانند به عنوان ورودی مدل‌ها منظور شوند، مستلزم نرمال شدن بین ۰ تا ۱ هستند. تأثیر متغیرهای با مقادیر بزرگ بر تابع خطا، ممکن است بزرگ‌تر از متغیرهای با مقادیر کوچک باشد؛ در صورتی که این امر، لزوماً مفهوم نسبی متغیرها را در طراحی پیش‌بینی کننده انعکاس نمی‌دهد. این مسأله با نرمال کردن متغیرها، مرتفع می‌شود؛ به طوری که مقادیر آن در محدوده‌ی مشابهی قرار می‌گیرد. برای اینکه داده‌های ورودی در یک محدوده قرار گیرد، با استفاده از یک رابطه‌ی خطی داده‌ها در فاصله‌ی صفر و یک قرار می‌گیرد؛ به طوری که بزرگترین مقدار عددی برابر یک و کوچکترین آن معادل صفر است (عاملی و رمضانی، ۱۳۹۴). نرمال کردن داده‌های ورودی با استفاده از نرم‌افزار متلب و بر اساس رابطه‌ی (۱) انجام شده است.

$$\tilde{S}_i = \frac{(S_i - S_{\min})}{S_{\max} - S_{\min}}, \quad i = 1, \dots, 663 \quad (1)$$

مدل شبکه‌ی عصبی عادی: در ابتدا مدل شبکه‌ی عصبی مصنوعی عادی، بدون استفاده از الگوریتم‌های انتخاب متغیر طراحی شده و در ادامه به ترکیب الگوریتم‌های انتخاب ویژگی (متغیر) و شبکه‌ی عصبی مصنوعی پرداخته می‌شود. در این پژوهش، همانند گوچن و همکاران (۲۰۱۶) از مدل شبکه‌ی عصبی پیش‌خور پرسپترون^{۳۲} سه لایه با دو لایه‌ی ورودی و خروجی و یک لایه‌ی پنهان استفاده شده است. لایه‌ی ورودی، شامل ۴۲ متغیر ورودی است؛ یعنی ۴۲ نرون در لایه‌ی ورودی شبکه‌ی

^{۳۲} Perceptron

عصبی وجود دارد. لایه‌ی خروجی نیز از آنجا که شامل یک متغیر است؛ دارای یک نرون است. تعیین تعداد نرون‌های لایه‌ی پنهان، توان شبکه در تشخیص پیچیدگی‌های مدل را افزایش می‌دهد. اگر تعداد نرون‌های لایه‌ی پنهان، بیش از اندازه زیاد شود، شبکه به جای یادگیری حفظ می‌کند؛ بنابراین یکی از مهمترین و حساس‌ترین بخش‌ها در مدل‌سازی شبکه‌ی عصبی، انتخاب تعداد نرون‌ها در لایه‌ی پنهان شبکه است.

در این پژوهش، نرون‌های لایه‌ی پنهان مدل شبکه‌ی عصبی عادی از طریق آزمون و خطا به دست آمده است؛ بدین‌نحو که در لایه‌ی پنهان از یک تا ۳۲ نرون، مورد بررسی قرار گرفته و تعداد نرون‌هایی که بهترین عملکرد را ارائه کند، به عنوان مدل اصلی شبکه‌ی عصبی انتخاب شده است. برای آموزش مدل از الگوریتم پسانشان خطا^{۳۳} استفاده شده است. الگوریتم کمینه‌سازی^{۳۴} مورد استفاده در یادگیری شبکه، الگوریتم لونبرگ - مارکوات^{۳۵} است، که برای پیدا کردن نقطه‌ی مینیمم خطا از آن استفاده می‌شود (حقیقت منفرد، علی نژاد و متقالچی، ۱۳۹۱). تعداد تکرار آموزش ۱۰۰۰ و نرخ آموزش در ابتدا ۰/۱ فرض شده که با تکرار آموزش به صورت نزولی تا ۰/۰۰۱ کاهش می‌یابد تا نتایج دقیق‌تری به دست آید.تابع خروجی لایه‌ی پنهان، تائزانت سیگموئیت^{۳۶} و تابع آستانه‌گذاری لایه‌ی خروجی، تابع خطی ساده^{۳۷} منظور شده است.

مدل هیبریدی الگوریتم ژنتیک و شبکه‌ی عصبی مصنوعی: در این مدل از الگوریتم ژنتیک به عنوان تعیین‌کننده‌ی متغیرهای ورودی و از شبکه‌ی عصبی مصنوعی به عنوان تابع ارزیابی استفاده می‌شود. کدگذاری^{۳۸} استفاده شده در این مدل، از نوع کدگذاری دودویی^{۳۹} است. کروموزم مورد استفاده از ۴۷ بیت تشکیل شده که ۴۲ بیت آن نمایانگر وجود یا عدم وجود متغیر (نمایگر تکنیکی) است. همانند گوچن و همکاران (۲۰۱۶)، در صورتی که بیت "۰" باشد، نشانه‌ی عدم وجود و در

^{۳۳} Error Backpropagation

^{۳۴} Minimization

^{۳۵} Marquarlt-Levenberg

^{۳۶} Sigmoid

^{۳۷} Purline

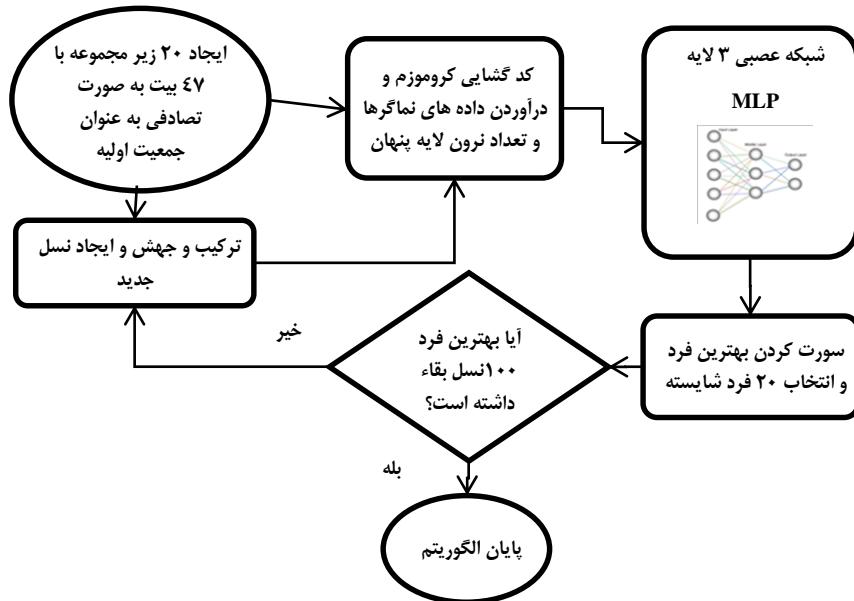
^{۳۸} Coding

^{۳۹} Binary Coding

صورتی که "۱" باشد، نشانه‌ی وجود متغیر و تشکیل نرون در لایه‌ی ورودی است.^۵ بیت دیگر کروموزوم معادل مقدار ۱ تا ۳۲ است ($2^5 = 32$) که نشان‌دهنده‌ی تعداد نرون‌های لایه‌ی پنهان شبکه‌ی عصبی است. اندازه‌ی جمعیت الگوریتم ژنتیک، ۲۰ عدد است که هر کدام یک کروموزوم با زیرمجموعه‌ای از ویژگی‌ها (نمایگر تکنیکی و تعداد نرون‌های لایه‌ی پنهان) را در بر می‌گیرد. جمعیت اولیه، به صورت تصادفی تولید شده است.تابع ارزیابی شایستگی در این مدل، همان شبکه‌ی عصبی مصنوعی است که ورودی آن نمایگرهای انتخاب شده و تعداد نرون لایه‌ی پنهان و خروجی آن میزان خطای پیش‌بینی MSE^{۴۰} است کمترین مقدار MSE در بین مجموعه‌های تواند بهترین جواب برای پیش‌بینی شاخص قیمت روز بعد باشد. برای افزایش سرعت آموزش الگوریتم شبکه‌ی عصبی مصنوعی، تعداد تکرار آموزش معادل ۱۰۰ منظور شده است. در دوره‌ی برازش از ۷۰ درصد مشاهدات متغیرهای انتخاب شده توسط الگوریتم ژنتیک، برای آموزش شبکه عصبی مصنوعی استفاده شده است. ۳۰ درصد دیگر، برای آزمون و اعتبارسنجی استفاده شد. نرخ آموزش در ابتدا ۰/۰۱ فرض شد که با تکرار آموزش به صورت نزولی تا ۰/۰۱ کاهش یافت تا نتایج دقیق‌تری به دست آید. آخرین زیرمجموعه‌ی به دست آمده با الگوریتم ژنتیک (که بهینه است) دوباره با یک شبکه‌ی عصبی با تعداد تکرار آموزش بیشتر (۱۰۰۰ تکرار)، آموزش داده شده است. جزئیات مربوط به مدل پیشنهادی الگوریتم ژنتیک و شبکه عصبی در شکل (۱) نشان داده شده است.

^{۴۰} Mean Square Error

شکل ۱: روندnamای مدل پیش‌بینی هیبریدی الگوریتم ژنتیک و شبکه عصبی



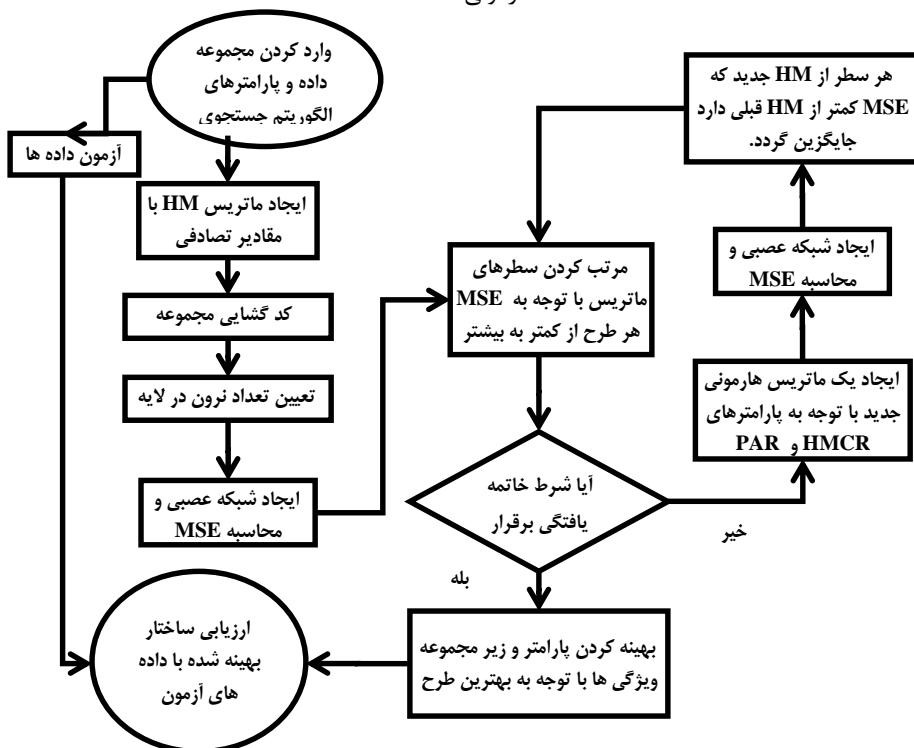
همانند گوچن و همکاران (۲۰۱۶) برای انتخاب والدین از چرخ رولت استفاده می‌شود و درصد ترکیب^{۴۱} برابر ۸۰ درصد است. برای ترکیب از ترکیب تک نقطه‌ای استفاده شده و برای همه‌ی آن‌هاتابع ارزیابی اجرا شده است. برای جهش^{۴۲} کروموزوم‌ها از جهش دودویی استفاده شده و درصد جهش ۲۰ درصد است. از میان ۲۰ والد و ۲۰ فرزند (۱۶ فرد حاصل ترکیب تک نقطه‌ای و ۴ فرد حاصل جهش دودویی است)، ۲۰ فرد شایسته به عنوان نسل جدید انتخاب شده است. نسل‌های جدید با تکرار روش بالا ادامه یافته تا شرایط خاتمه‌یافتگی ایجاد شود. یکی از شرایط خاتمه‌یافتگی، آن است که شایسته‌ترین فرد در ۱۰۰ نسل تکرار شود. اگر این شرط برقرار نشود، شرط حداکثر نسل بررسی می‌شود. حداکثر تعداد تولید نسل در این پژوهش برابر ۲۰۰۰ نسل است.^{۴۳}

مدل هیبریدی الگوریتم هارمونی و شبکه‌ی عصبی مصنوعی: در این مدل از الگوریتم هارمونی به عنوان تعیین‌کننده متغیر (ویژگی) و از شبکه عصبی مصنوعی

⁴¹ Crossover⁴² Mutation⁴³ این تعداد بصورتی انتخاب شده که هزینه زمان افزایش نیابد و زمان جستجو منطقی و مقرر به صرفه باشد.

به عنوان تابع ارزیابی استفاده می‌شود. با توجه به این که وزن‌های انتخاب شده برای الگوریتم در هر بار اجرا با وجود متغیرهای ورودی یکسان (راه حل نمونه)، MSE متفاوتی می‌دهد، برای این منظور، هر راه حل نمونه را برای ۵ مرتبه در شبکه‌ی عصبی مورد بررسی قرار داده و متوسط MSE محاسبه می‌شود. به حداقل رساندن این خطا توسط جستجوی هارمونی صورت می‌گیرد. جزئیات مربوط به مدل پیشنهادی، جستجوی هارمونی و شبکه‌ی عصبی در شکل (۲) نشان داده شده است.

شکل ۲: روندnamای شبکه‌های عصبی مصنوعی مبتنی بر سیستم انتخاب متغیر به روش جستجوی هارمونی



در این مدل ۴۳ متغیر وجود دارد که ۴۲ متغیر آن، نشانگر وجود/عدم وجود نماگر تکنیکی است (به صورت ۰ یا ۱ نمایش داده می‌شود) و یک متغیر که نشانگر تعداد نرون‌های لایه‌ی پنهان است و مقدار آن عدد صحیح در محدوده‌ی ۱ تا ۳۲ است؛ علاوه بر این، سایر پارامترهای الگوریتم جستجوی هارمونی نیز بایستی مشخص شود.

این پارامترها، عبارتند از: حجم حافظه‌ی هارمونی^{۴۴} (HMS) که برابر ۱۰۰، احتمال انتخاب از حافظه‌ی هارمونی^{۴۵} (HMCR) که معادل ۰/۹۵، نرخ تنظیم گام^{۴۶} یا احتمال تغییر جزئی مقدار انتخاب شده از حافظه‌ی هارمونی (PAR) که برابر ۰/۳ و^{۴۷} bw^{۴۸} برابر ۰/۲ منظور شده است. حافظه جستجوی هارمونی HM^{۴۹} با اندازه‌ی $(N + 1) \times N$ را می‌توان با یک ماتریس، به صورت زیر نمایش داد. که در این پژوهش N برابر ۴۳ است.

$$HM = \begin{pmatrix} x_1^1 & \dots & \dots & x_n^1 & f(x^1) \\ \vdots & \ddots & & \vdots & \\ x_1^{HMS} & \dots & \dots & x_n^{HMS} & f(x^{hms}) \end{pmatrix} \quad (2)$$

هر سطر ماتریس HM نشان‌دهنده‌ی یک راه حل یا به‌عبارت دیگر، یک روش پیش‌بینی است. مقدار نخست هر سطر، تعداد نرون‌های لایه‌ی پنهان را نشان می‌دهد. مقدار دوم تا یکی مانده به آخر سطر، نشان‌گر آن است که نماگر تکنیکی متناظر انتخاب شده است یا خیر. آخرین مقدار هر ردیف، مقدار تابع هدف آن ردیف را نشان می‌دهد. هارمونی جدید با ماهیت الگوریتم جستجوی هارمونی ساخته می‌شود؛ به‌عبارت ساده‌تر، جستجوی هارمونی یک بردار هارمونی جدید x' x'_N, x'_2, x'_1, \dots با استفاده از قوانین بررسی حافظه^{۴۹}، تنظیم گام^{۵۰} و انتخاب تصادفی^{۵۱} تولید می‌کند. جزئیات تولید ماتریس جدید در) نشان داده می‌شود.

⁴⁴ Harmony Memory Size

⁴⁵ Harmony Memory Considering Rate

⁴⁶ Pitch Adjusting Rate

⁴⁷ Bandwidth

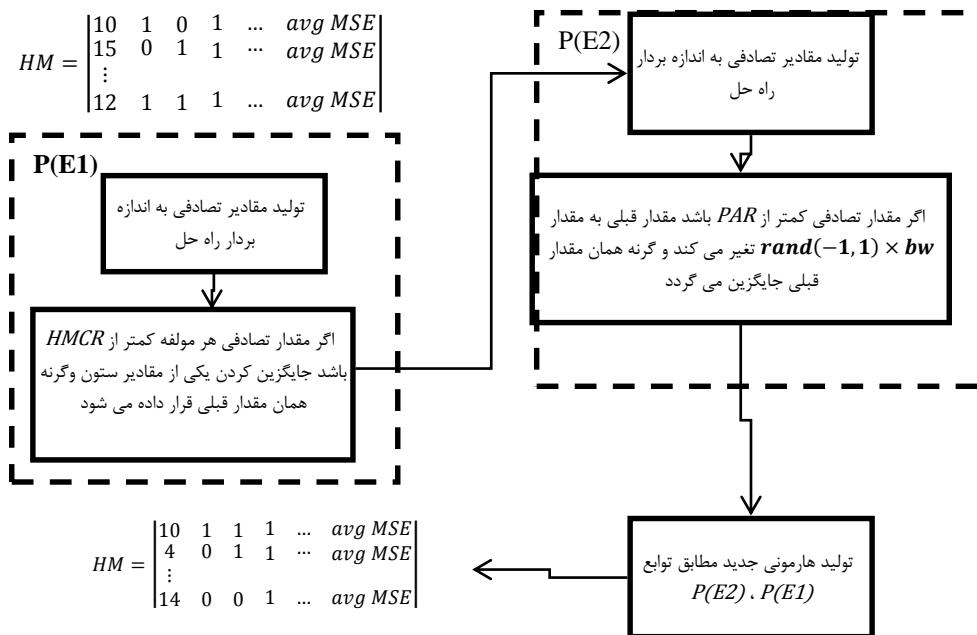
⁴⁸ Harmony Matrix

⁴⁹ Memory consideration

⁵⁰ Pitch Adjustment

⁵¹ Random Selection

شکل ۳: مفهوم ایجاد هارمونی جدید برای مدل پیش‌بینی پیشنهادی



پس از انتخاب مقادیر جدید، مقدار تابع هدف برای بردار هارمونی جدید محاسبه می‌شود؛ اگر این مقدار بهتر از بدترین بردار هارمونی در ماتریس هارمونی باشد، آن‌گاه در ماتریس قرار گرفته و مقدار بدتر از ماتریس مورد نظر حذف می‌شود. پس از آن، ماتریس حافظه‌ی هارمونی به ترتیب صعودی مقدار تابع هدف طبقه‌بندی می‌شود. این روند تا زمانی ادامه می‌یابد که شرایط خاتمه یافتنی ایجاد شود. شرط خاتمه یافتنی نخست، عدم تغییر بهترین مقدار تابع هدف برای بیش از ۱۰۰ بار و در صورتی که شرط اول برقرار نگردد، تکرار الگوریتم بیش از ۱۰۰۰ بار است. با خاتمه یافتن الگوریتم، آن ردیف ماتریس که دارای کمترین MSE است، به عنوان بهترین راه حل انتخاب می‌شود. معیارهای سنجش خطای پیش‌بینی: برای هر سه مدل مورد نظر، با استفاده از شبکه‌ای که ایجاد می‌شود و با استفاده از نماگرهای تکنیکی روز-t-1 به پیش‌بینی شاخص قیمت روز t برای دوره آزمون پرداخته می‌شود؛ سپس خطای خروجی پیش‌بینی شده و خروجی واقعی با استفاده از معیارهای سنجش خطای آماری محاسبه می‌شود. معیارهای ارزیابی عملکرد پیش‌بینی در جدول (۱) ارائه شده است.

جدول ۱: معیارهای سنجش خطای پیش‌بینی

معیار خطای	فرمول معیار خطای
میانگین قدر مطلق خطای (MAE)	$MAE = \frac{1}{n} \sum_{i=1}^n e_i $
میانگین مجذور خطای پیش‌بینی (MSE)	$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2$
ریشه میانگین مربعات خطای (RMSE)	$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2}$
میانگین نسبی قدر مطلق خطای (MARE)	$MARE = \frac{1}{n} \sum_{i=1}^n \frac{ e_i }{ a_i }$
میانگین مربع خطای نسبی (MSRE)	$MSRE = \frac{1}{n} \sum_{i=1}^n \left \frac{e_i}{a_i} \right ^2$
ریشه میانگین مربع خطای نسبی (RMSRE)	$RMSRE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left \frac{e_i}{a_i} \right ^2}$
میانگین قدر مطلق درصد خطای (MAPE)	$MAPE = \frac{100}{n} \sum_{i=1}^n \left \frac{e_i}{a_i} \right $
میانگین درصد مربع خطای (MSPE)	$MSPE = \frac{100}{n} \sum_{i=1}^n \left \frac{e_i}{a_i} \right ^2$
درصد ریشه میانگین مربع خطای (RMSPE)	$RMSPE = \sqrt{\frac{100}{n} \sum_{i=1}^n \left \frac{e_i}{a_i} \right ^2}$

e_i خطای پیش‌بینی و a_i مقدار واقعی روز i می‌باشد.

در نهایت با توجه به مقادیر به دست آمده برای معیارهای خطای هریک از مدل‌های ارائه شده به مقایسه‌ی دقت آن‌ها پرداخته می‌شود.

۱-۳- جامعه و نمونه‌ی آماری

جامعه‌ی آماری پژوهش، شامل بورس اوراق بهادار تهران است. با عنایت به این‌که پیش‌بینی شاخص قیمت، موضوع پژوهش حاضر است؛ لذا نمونه‌آماری شامل کل جامعه‌ی مورد نظر طی ۱۳۹۱/۰۱/۳۰ الی ۱۳۹۴/۹/۳۰ است.

داده‌های پژوهش، شامل مقادیر روزانه‌ی شاخص قیمت بورس اوراق بهادار تهران (TEPIX^{۵۲})، داده‌های شاخص قیمت سهام شامل قیمت ابتدایی، پایین‌ترین قیمت،

^{۵۲} Tehran Exchange Price Index

بالاترین قیمت، قیمت پایانی و حجم معامله از سایت رسمی بورس اوراق بهادار تهران و نرمافزار TSE Client گردآوری شده است.

۲-۳- اندازه‌گیری متغیرها

متغیرهای پژوهش حاضر به شرح جدول (۲) اندازه‌گیری شده است.

جدول ۲: نماگرهای تحلیل تکنیکی

روش اندازه‌گیری نماگر	توصیف نماگر
$\text{Diff} = \text{Close}_{\text{today}} - \text{Close}_{\text{yesterday}}$	تفاوت قیمت پایانی امروز و دیروز
Close	قیمت پایانی قبلی
High	بالاترین قیمت قبلی
Low	پایین‌ترین قیمت قبلی
Open	قیمت ابتدایی قبلی
$SMA(5) = \frac{(\text{Close}_1 + \text{Close}_2 + \dots + \text{Close}_5)}{5}$	میانگین متحرک قیمت پایانی ۵ روز
$SMA(6) = \frac{(\text{Close}_1 + \text{Close}_2 + \dots + \text{Close}_6)}{6}$	میانگین متحرک قیمت پایانی عروز
$SMA(10) = \frac{(\text{Close}_1 + \text{Close}_2 + \dots + \text{Close}_{10})}{10}$	میانگین متحرک قیمت پایانی ۱۰ روز
$SMA(20) = \frac{(\text{Close}_1 + \text{Close}_2 + \dots + \text{Close}_{20})}{20}$	میانگین متحرک قیمت پایانی ۲۰ روز
$EMA(5)_{\text{today}} = \frac{\text{Close}_{\text{today}} * K + EMA(5)_{\text{yesterday}} * (1 - K)}{5}, EMA(5)_0 = SMA(5)$	میانگین متحرک نمایی قیمت پایانی ۵ روز
$EMA(6)_{\text{today}} = \frac{\text{Close}_{\text{today}} * K + EMA(6)_{\text{yesterday}} * (1 - K)}{6}, EMA(6)_0 = SMA(6)$	میانگین متحرک نمایی قیمت پایانی ۶ روز
$EMA(10)_{\text{today}} = \frac{\text{Close}_{\text{today}} * K + EMA(10)_{\text{yesterday}} * (1 - K)}{10}, EMA(10)_0 = SMA(10)$	میانگین متحرک نمایی قیمت پایانی ۱۰ روز
$EMA(20)_{\text{today}} = \frac{\text{Close}_{\text{today}} * K + EMA(20)_{\text{yesterday}} * (1 - K)}{20}, EMA(20)_0 = SMA(20)$	میانگین متحرک نمایی قیمت پایانی ۲۰ روز
$TMA(5) = \frac{(SMA(1) + SMA(2) + \dots + SMA(5))}{5}$	میانگین متحرک مثاثی قیمت پایانی ۵ روز
$TMA(6) = \frac{(SMA(1) + SMA(2) + \dots + SMA(6))}{6}$	میانگین متحرک مثاثی قیمت پایانی ۶ روز
$TMA(10) = \frac{(SMA(1) + SMA(2) + \dots + SMA(10))}{10}$	میانگین متحرک مثاثی قیمت پایانی ۱۰ روز
$TMA(20) = \frac{(SMA(1) + SMA(2) + \dots + SMA(20))}{20}$	میانگین متحرک مثاثی قیمت پایانی ۲۰ روز

$AccDist = AccDist_{yesterday} + volume^{53} * CLV$	نوسان نسبت انباشتگی به پراکندگی
$CLV = \frac{[(Close - Low) - (High - Close)]}{(High - Low)}$	میانگین متحرک ساده سود قیمت پایانی برای روز گذشته N
$MACD = EMA(12) - EMA(26)$	همگرایی/ واگرایی میانگین متحرک قیمت پایانی
$Signal_{MACD} = EMA(MACD, 9)$ $= MACD_{today} * 0.2 + (Signal_{MACD}_{yesterday} * (0.8))$	میانگین متحرک نمایی دوره ۹ تایی از MACD
$MOpen = Open_{today} - Open_{yesterday}$	گشتاور قیمت ابتدایی
$MHigh = High_{today} - High_{yesterday}$	گشتاور بالاترین قیمت
$MLow = Low_{today} - Low_{yesterday}$	گشتاور پایین‌ترین قیمت
$MCclose = Close_{today} - Close_{yesterday}$	گشتاور قیمت پایانی
$ACCOpen = MOpen_{today} - MOpen_{yesterday}$	شتاب قیمت ابتدایی
$ACCClose = MCclose_{today} - MCclose_{yesterday}$	شتاب قیمت پایانی
$ACCHigh = MHigh_{today} - MHigh_{yesterday}$	شتاب بالاترین قیمت
$ACCLow = MLow_{today} - MLow_{yesterday}$	شتاب پایین‌ترین قیمت
$Fast \%K = \frac{(Close - Low)}{(High - Low)} \times 100$	استوکاستیک سریع K%
$Fast \%D = SMA(Fast \%K, 3)$	استوکاستیک سریع D%
$Slow \%K = Fast \%D$	استوکاستیک کند K%
$Slow \%D = SMA(Slow \%K, 3)$	استوکاستیک کند D%
$William's \%R = \frac{(Highest High^{54} - Close)}{(Highest High - Lowest Low^{55})}$	R% ولیام
$RSI = 100 - \frac{100}{(1 + RS)}, \quad RS = \frac{SMA(U)^{56}}{SMA(D)^{57}}$	شاخص قدرت نسیی
$Middle Band = SMA(20)$	باند میانی بولینگر
$Upper Band = SMA(20) + dev(20)^{58} * 2$	باند بالایی بولینگر
$Lower Band = SMA(20) - dev(20) * 2$	باند پایینی بولینگر
$MP = \frac{(High + Low)}{2}$	میانه قیمت
$ROC = \frac{(Close_{today} - Close_{نوزدهم})}{Close_{نوزدهم}}$	نرخ تغییر قیمت
$Typical Price = \frac{(High + Low + Close + Opening)}{4}$	قیمت معمول
$Weighted Close = \frac{((Close * 2) + High + Low)}{4}$	وزن قیمت پایانی
$WA/D = CurA/D + WA/D_{yesterday}$ $If (Close today > Close yesterday) CurA/D = Close_{today} - TRL$	نسبت انباشتگی به پراکندگی و ولیامز

٣٣ حجم معاملات^{۵۴} بالاترین قیمت روز متوالی ۱۰^{۵۵} کمترین قیمت روز متوالی ۱۰^{۵۶} میانگین متحرک ساده سود قیمت پایانی برای N روز گذشته^{۵۷} میانگین متحرک ساده زیان قیمت پایانی برای N روز گذشته^{۵۸} dev(20) = انحراف معیار روزه قیمت پایانی

$\begin{aligned} \text{If } (\text{Close today} \leq \text{Close yesterday}) \quad \text{CurA/D} \\ = \text{Close}_{\text{today}} - \text{TRH} \\ \text{TRH} = \text{MAX}(\text{HIGH}_{\text{today}} \text{Close}_{\text{yesterday}}) \\ \text{TRL} = \text{MIN}(\text{LOW}_{\text{today}} \text{Close}_{\text{yesterday}}) \end{aligned}$	
--	--

مأخذ: محاسبات تحقیق

در جدول (۵) مشاهده می‌شود که مدل شبکه‌ی عصبی هیبریدی مبتنی بر الگوریتم ژنتیک و جستجوی هارمونی به ترتیب با میانگین قدر مطلق درصد خطای (MAPE)^{۵۹} برابر ۰/۳۵۴ و ۰/۱۸۷ در دوره‌ی آزمون حائز خطای پیش‌بینی پایین‌تری نسبت به شبکه‌ی عصبی (سؤال اول پژوهش)، همچنین همه‌ی توابع خطای پیش‌بینی مدل هیبریدی مبتنی بر الگوریتم ۰/۵۰۷ است. این بدان مفهوم است که دقت پیش‌بینی مدل‌های مذکور، بالاتر از شبکه‌ی عصبی عادی است، هارمونی در دوره‌ی آزمون، پایین‌تر از شبکه‌ی هیبریدی مبتنی بر الگوریتم ژنتیک است. به‌این معنی که دقت پیش‌بینی شبکه‌ی عصبی هیبریدی مبتنی بر الگوریتم ژنتیک پایین‌تر از شبکه‌ی عصبی هیبریدی مبتنی بر جستجوی هارمونی است (سؤال دوم پژوهش).

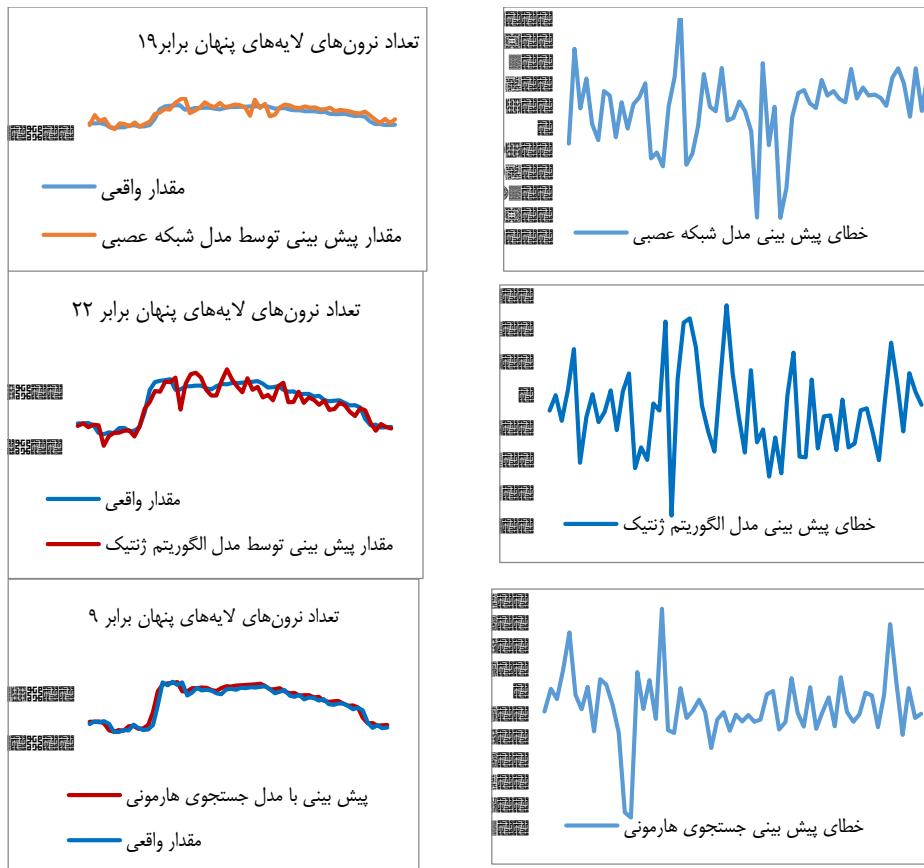
یافته‌ی دیگری که در جدول (۵) مشاهده می‌شود، آن است که مقدار توابع خطای پیش‌بینی مدل هیبریدی مبتنی بر الگوریتم ژنتیک در دوره‌ی برآش از همتای مبتنی بر الگوریتم هارمونی خود پایین‌تر است؛ اما در دوره‌ی آزمون، این رابطه معکوس شده و مقدار خطای شبکه‌ی عصبی هیبریدی مبتنی بر الگوریتم هارمونی پایین‌تر است. به‌نحوی که در دوره‌ی برآش MAPE مدل هیبریدی مبتنی بر الگوریتم ژنتیک و جستجوی هارمونی به ترتیب برابر ۰/۵۲۰ و ۰/۵۷۴ است؛ در حالی که خطای پیش‌بینی مورد نظر، در دوره‌ی آزمون برابر ۰/۳۵۴ و ۰/۱۸۷ است. این بدان مفهوم است که مدل هیبریدی مبتنی بر الگوریتم هارمونی از توان تعیین بالاتری برخوردار است. خطای پیش‌بینی مدل شبکه‌ی عصبی عادی در دوره‌ی برآش پایین‌تر از سایر مدل‌های است؛ اما در دوره‌ی آزمون، نسبت به هر دو مدل فروزنی می‌یابد. یافته‌ی اخیر، متضمن این واقعیت است که شبکه‌ی عصبی عادی، داده‌های مجموعه برآش را حفظ می‌کند؛ به‌همین دلیل، در دوره‌ی برآش، حائز پایین‌ترین

^{۵۹} در بین توابع خطای آماری نیز، تابع خطای MAPE چون میزان خطأ بر حسب درصد را نشان می‌دهد، مورد اقبال بیشتر سرمایه‌گذاران است.

میزان خطاست؛ اما به دلیل عدم برخورداری از قابلیت تعمیم مناسب، دارای بالاترین خطای دوره‌ی آزمون است.

نمودارهای مقایسه شاخص قیمت سهام و پیش‌بینی آن و همچنین خطای پیش‌بینی هر سه مدل در شکل (۴) ارائه شده است.

شکل ۴: نمودارهای پیش‌بینی شاخص قیمت برای سه مدل ارائه شده در پژوهش



در یک نمودار پیش‌بینی کامل، مقدار خطا باید حدود صفر باشد. بر اساس نمودارهای معنکس در شکل (۴)، ملاحظه می‌شود که مدل شبکه عصبی مصنوعی هیبریدی مبتنی بر الگوریتم هارمونی نسبت به دو مدل دیگر به خط صفر نزدیک‌تر بوده و دارای خطای پیش‌بینی پایین‌تری است.

۵- بحث و نتیجه‌گیری

با استفاده از نماگرهای تکنیکی بازار سهام، جهت پیش‌بینی شاخص قیمت در بورس اوراق بهادار تهران، دو مدل شبکه‌ی عصبی هیبریدی آزمون شد. شبکه‌ی عصبی هیبریدی مورد نظر، حاصل ترکیب شبکه‌ی عصبی مصنوعی و الگوریتم ژنتیک و همچنین ترکیب شبکه‌ی عصبی مصنوعی و جستجوی هارمونی است. با استفاده از الگوریتم ژنتیک و جستجوی هارمونی متغیرهای ورودی بهینه به دست می‌آید؛ علاوه بر این، به صورت همزمان مناسب‌ترین تعداد نرون در لایه‌ی پنهانی شبکه‌ی عصبی مصنوعی نیز از طریق الگوریتم‌های مذکور حاصل می‌شود. با این شیوه، ایرادات اصلی شبکه‌ی عصبی مصنوعی در خصوص متغیرهای ورودی و تعداد نرون‌های لایه‌ی پنهان تا حدود زیادی مرتفع می‌شود. با توسعه‌ی شبکه‌ی عصبی مصنوعی هیبریدی، می‌توان ادعا کرد که ساختار شبکه‌ی عصبی مصنوعی در مرحله اجرا تسهیل می‌شود؛ زیرا مدل‌های پیشنهادی الگوریتم ژنتیک و جستجوی هارمونی از توان بالایی جهت انتخاب متغیر ورودی و تعیین تعداد نرون لایه‌ی پنهان برخوردار است. از بین ۴۲ نماگر تکنیکی از پیش تعیین شده، ۲۰ نماگر توسط الگوریتم ژنتیک و ۱۴ نماگر توسط جستجوی هارمونی به عنوان متغیرهای بهینه انتخاب شده است. بدان مفهوم که با استفاده از الگوریتم‌های مورد نظر، تعداد متغیرهای ورودی مدل، تقریباً به کمتر از نصف کاهش پیدا می‌کند؛ همچنین تعداد نرون‌های شبکه‌ی عصبی مصنوعی ۱۹ است که به روش آزمون و خطا حاصل شد؛ اما در مدل‌های هیبریدی ذکر شده، تعداد نرون‌های لایه‌ی پنهان توسط الگوریتم مورد نظر به صورت بهینه تعیین می‌شود. تعداد نرون لایه‌ی پنهان در مدل شبکه‌ی عصبی مصنوعی هیبریدی مبتنی بر الگوریتم ژنتیک ۲۲ و در مدل شبکه‌ی عصبی مصنوعی هیبریدی مبتنی بر جستجوی هارمونی ۹ نرون به دست آمد. شواهد حاصل از پژوهش، نشان می‌دهد که مدل شبکه‌ی عصبی هیبریدی مبتنی بر الگوریتم ژنتیک و جستجوی هارمونی حائز خطای پیش‌بینی پایین‌تری در دوره‌ی آزمون بوده و نسبت به مدل شبکه‌ی عصبی عادی از دقت بالاتری برخوردار است؛ لذا یافته گوچن و همکاران (۲۰۱۶) را تأیید می‌کند. شواهد تجربی ارائه شده توسط منجمی، ابزری و رعیتی شوازی (۱۳۸۸)، وانگ و همکاران (۲۰۱۲) و استیری (۱۳۹۲) نیز حاکی از برتری مدل‌های ترکیبی شبکه‌ی عصبی مبتنی بر الگوریتم ژنتیک نسبت به شبکه‌ی عصبی عادی و مؤید نتایج این تحقیق است شواهد حاصل از این پژوهش نشان می‌دهد که همه‌ی توابع

خطای پیش‌بینی در مدل هیبریدی مبتنی بر الگوریتم هارمونی در دوره‌ی آزمون از مدل هیبریدی مبتنی بر الگوریتم ژنتیک پایین‌تر است. این بدان معنی است که دقت پیش‌بینی مدل شبکه‌ی عصبی هیبریدی مبتنی بر الگوریتم هارمونی در دوره‌ی آزمون بالاتر از مدل شبکه‌ی عصبی هیبریدی مبتنی بر الگوریتم ژنتیک است. این نتیجه مطابق یافته‌ی گوچن و همکاران (۲۰۱۶) است.

اگرچه مدل‌های هیبریدی مطرح شده در این پژوهش از نظر پیش‌بینی، نتایج دقیق‌تری ارائه می‌دهد؛ اما چند محدودیت دارد: اول، یک لایه‌ی پنهان در نظر گرفته شده است. با وجود افزایش تعداد لایه‌های پنهان، آموزش شبکه، بسیار زمان بر می‌شود؛ اما عملکرد مدل با تغییر لایه‌های پنهان می‌تواند تغییر کند. دوم، توابع آموزش و انتقال از پیش‌ تعیین شده است. ترکیب توابع آموزش و انتقال می‌تواند بر کیفیت مدل شبکه‌ی عصبی مؤثر باشد. مدل‌های هیبریدی مطرح شده، جهت پیش‌بینی شاخص بازار سهام را می‌توان با منظور کردن چند پارامتر مؤثر بر ساختار شبکه‌ی عصبی گسترش داد. تغییر نوع توابع آموزش و انتقال، استفاده از انواع دیگر الگوریتم جستجوی هارمونی و استفاده از اشکال دیگر در فرایند انتخاب، ترکیب و عملگرهای جهش در الگوریتم ژنتیک از آن جمله است و می‌تواند موضوع پژوهش‌های بیشتر باشد.

فهرست منابع

- استیری، علی. (۱۳۹۲). «پیش‌بینی شاخص بورس اوراق بهادار تهران با استفاده از مدل ترکیبی». *پایان‌نامه کارشناسی ارشد*. دانشگاه تهران.
- حقیقت منفرد، جلال، محمود احمدعلی‌نژاد و سارا متقالچی. (۱۳۹۱). « مقایسه مدل‌های شبکه عصبی با مدل سری زمانی باکس-جنکینز در پیش‌بینی شاخص کل قیمت سهام بورس اوراق بهادار تهران ». *مهندسی مالی و مدیریت اوراق بهادار*, ۱(۱): ۱-۱۶.
- عاملی، احمد و مليحه رمضانی. (۱۳۹۴). «پیش‌بینی قیمت سهام با استفاده از شبکه عصبی فازی مبتنی بر الگوریتم ژنتیک و مقایسه با شبکه عصبی فازی ». *تحقیقات مدل‌سازی اقتصادی*, ۲۲(۶): ۹۱-۶۱.
- علوی، جعفر. (۱۳۸۵). «ترکیب تحلیل تکنیکی با هوش مصنوعی (هوش محاسباتی) و مقایسه آن با روش تحلیل تکنیکی پیش‌بینی قیمت سهام ». *پایان‌نامه کارشناسی ارشد*. دانشگاه تهران.
- منجمی، سیدامیرحسین، مهدی ابرزی و علیرضا رعیتی شوازی. (۱۳۸۸). «پیش‌بینی قیمت سهام در بازار بورس اوراق بهادار با استفاده از شبکه عصبی فازی و الگوریتم‌های ژنتیک و مقایسه آن با شبکه عصبی مصنوعی ». *اقتصاد مقداری (بررسی‌های اقتصادی سابق)*, ۳(۶): ۲۶-۱.
- Geem, Z.W. (2009). *Music-Inspired Harmony Search Algorithm: Theory and Applications*. Springer Publishing Company, Berlin.
 - Gocüken, M., M. Ozçüalçö, A. Boru & A. Dosdoğru. (2016). *Integrating Metaheuristics and Artificial Neural Networks for Improved Stock Price Prediction*. Expert Systems with Applications, Vol. 44, pp: 320-331.
 - Gorynin, I., E. Monfrini & W. Pieczynski. (2017). Pairwise Markov Models for Stock Index Forecasting. 25th European Signal Processing Conference (EUSIPCO), IEEE.
 - Huang, C., D. Yang & Y. Chuang. (2008). Application of Wrapper Approach and Composite Classifier to the Stock Trend Prediction. *Expert System with Application*, Vol.34(4), pp: 2870-2878.
 - Jian, Z. & L. Song. (2017). Financial Time Series Analysis Model for Stock Index Forecasting. *International Journal of Simulation Systems, Science & Technology*, Vol.17, pp: 12.1-12.6.
 - Laboissiere, L.A., R.A.S. Fernandes & G.G. Lage. (2015). Maximum And Minimum Stock Price Forecasting of Brazilian Power Distribution Companies Based on Artificial Neural Networks. *Applied Soft Computing*, Vol.35, pp: 66-74.

- Prasanna, S. & D. Ezhilmaran. (2013). An Analysis on Stock Market Prediction Using Data Mining Techniques. International Journal of Computer Science & Engineering Technology, Vol.4(2), pp: 49-51.
- Wang, J.Z., J.J. Wang, Z.G. Zhang & S.P. Guo. (2012). Forecasting Stock Indices with Back-Propagation Neural Network. Expert Systems with Applications, Vol.38(11), pp: 14346-14355.
- White, H. (1988). Economic Prediction Using Neural Networks: The Case of IBM Daily Stock Returns. IEEE International Conference on Neural Networks.