

چشم‌انداز مدیریت صنعتی

شماره ۲۸ - زمستان ۱۳۹۶

صص ۱۳۵ - ۱۰۷

بررسی کارایی و پیش‌بینی‌پذیری کالاهای صنعتی با رویکردهای بنیادین و تکنیکال

سمیه رافعی*، مجید اسماعیلیان**، محمود بت‌شکن***

چکیده

هدف این پژوهش، بررسی پیش‌بینی‌پذیری قیمت سرب و کارایی این بازار در سطح ضعیف و معرفی یک الگوی مناسب برای پیش‌بینی قیمت سرب در بازار جهانی است. به این منظور مجموعه‌ای از روش‌های خطی و غیرخطی در دو رویکرد کلی تکنیکال و بنیادین استفاده شده است. بررسی کارایی بازار سرب در سطح ضعیف نشان می‌دهد که این بازار در این سطح نیز کارا نیست و امکان پیش‌بینی قیمت وجود دارد. داده‌های استفاده‌شده در این پژوهش به صورت هفتگی جمع‌آوری شده و شامل بازه زمانی هفته اول ۲۰۰۵ الی هفته آخر ۲۰۱۵ است. این داده‌ها از سایت‌های مختلف، از جمله سایت LME، USGS و ILZSG جمع‌آوری شده است. یافته‌های این پژوهش نشان می‌دهد که در رویکرد تکنیکال، مدل شبکه عصبی مصنوعی GMDH ترکیب‌شده با الگوریتم ژنتیک بر اساس معیارهای میانگین درصد خطای مطلق (MAPE) و جذر میانگین مجذور خطا (RMSE) دارای عملکرد بهتری نسبت به مدل‌های دیگر است؛ همچنین در رویکرد بنیادین بر اساس معیارهای خطای پیش‌بینی، شبکه عصبی مصنوعی GMDH بهترین عملکرد را داشته است. پیش‌بینی‌پذیری تغییرات قیمت سرب در بازار با الگوهای تکنیکال، نشان‌دهنده کارایی بازار در سطح ضعیف است.

کلیدواژه‌ها: کارایی بازار؛ روش سازمان‌دهی گروهی داده‌ها (GMDH)؛ شبکه عصبی پرسپترون چندلایه (MLP)؛ الگوریتم ژنتیک؛ تحلیل بنیادین؛ تحلیل تکنیکال.

تاریخ دریافت مقاله: ۱۳۹۵/۱۱/۲۸، تاریخ پذیرش مقاله: ۱۳۹۶/۰۹/۱۲.

* کارشناس ارشد، دانشگاه اصفهان.

** استادیار، دانشگاه اصفهان (نویسنده مسئول).

Email: M.Esmaelian@ase.ui.ac.ir

*** استادیار، دانشگاه اصفهان.

۱. مقدمه

پیش‌بینی یکی از پایه‌های اصلی در تصمیم‌گیری و برنامه‌ریزی است. بنگاه‌های تولیدی برای برنامه‌ریزی‌های مربوط به تولید و فروش، تجزیه و تحلیل پروژه‌ها، طرح‌های اقتصادی و بررسی سرمایه‌گذاری‌های جدید برای توسعه، همواره با ریسک‌ها و نوسانات ناشی از تغییر قیمت بازار مواد اولیه و محصولات نهایی مواجه هستند؛ از این رو یکی از دغدغه‌های همیشگی فعالان اقتصادی یافتن راه‌هایی برای پیش‌بینی قیمت‌های آتی و کاهش عدم‌اطمینان ناشی از تغییر قیمت‌ها بوده است. افزایش رقابت، جهانی‌شدن بازارها و تغییرات سریع فناوری نیز عواملی هستند که ضرورت برنامه‌ریزی و پیش‌بینی را در دنیای امروز دوچندان کرده‌اند. واضح است که عدم‌اطمینان از قیمت‌های آتی، برنامه‌ریزی برای تولید و فروش را بسیار دشوار می‌سازد و گاهی اوقات باعث بی‌میلی فعالان اقتصادی برای ورود به بازار یا سرمایه‌گذاری در پروژه‌های جدید می‌شود؛ بنابراین به‌طور طبیعی، تلاش سرمایه‌گذاران در جهت کاهش عدم‌اطمینان ناشی از تغییر قیمت‌ها است. یکی از ابزارهای مهمی که برای این کار استفاده می‌شود، روش‌های مختلف پیش‌بینی است [۱]. به این ترتیب یک پیش‌بینی دقیق تا حد زیادی باعث کاهش تصمیم‌های غلط می‌شود و توانایی رقابتی سازمان را ارتقا می‌دهد [۱۷]؛ از طرف دیگر فعالان بازارهای مالی و کالا نیز که به انگیزه کسب سود از طریق خرید و فروش وارد این بازارها می‌شوند، همواره به دنبال روش‌هایی برای پیش‌بینی قیمت‌های آتی هستند؛ در واقع هدف آن‌ها از این پیش‌بینی کسب بیشترین بازده از سرمایه‌گذاری است.

برای پیش‌بینی قیمت سهام یا کالاها، تکنیک‌های مختلفی در مبانی نظری پژوهش پیشنهاد شده است؛ اما قبل از انتخاب نوع تکنیک برای پیش‌بینی، باید بررسی شود که آیا امکان پیش‌بینی قیمت در بازارهای مالی وجود دارد؛ به عبارت دیگر باید پیش‌بینی‌پذیر بودن سری زمانی قیمت بررسی شود. پیش‌بینی‌پذیری قیمت‌ها در بازارهای مالی یا کالاها با مفهوم کارایی اطلاعاتی^۱ بازار، ارتباط نزدیکی دارد. مفهومی که از کارایی در اینجا مدنظر است، نشان می‌دهد تا چه میزان بازار در پردازش اطلاعات موجود برای تعیین قیمت کالاها و اوراق بهادار موفق عمل کرده است و اینکه تا چه حد قیمت‌ها به‌طور پیوسته منعکس‌کننده اطلاعات جدید هستند. فاما (۱۹۷۰)، برای نخستین بار فرضیه بازار کارا را معرفی کرد. این فرضیه بیان می‌کند، وجود رقابت بین فعالان بازار به همراه ورود آزاد همگان به بازار و سرمایه‌گذارانی که تلاش دارند از هرگونه مزیت اطلاعاتی برای کسب سود بیشتر استفاده کنند، موجب می‌شود اطلاعات مناسب برای پیش‌بینی قیمت در دوره بعد، با توجه به رقابت فعالان بازار، بر قیمت‌های این دوره نیز تأثیر بگذارد. به این ترتیب اثر هرگونه مزیت اطلاعاتی به‌سرعت خود را در عرضه و تقاضای سهام یا

1. Information Efficiency

کالا نشان می‌دهد و باعث ایجاد سطح جدیدی از قیمت می‌شود. این قیمت منعکس‌کننده آن اطلاعات خاص است. با این وجود در بازار کارا، قیمت‌ها همواره منعکس‌کننده آخرین اطلاعات منتشره هستند [۸].

با توجه به اطلاعاتی که انتظار می‌رود در قیمت‌ها منعکس شده باشند، سه سطح از کارایی تعریف می‌شود. این سه سطح شامل کارایی ضعیف، کارایی نیمه‌قوی و کارایی قوی است. در سطح کارایی ضعیف، فرض می‌شود قیمت‌ها منعکس‌کننده همه اطلاعات موجود در قیمت‌های گذشته هستند؛ بنابراین نمی‌توان با استفاده از اطلاعات موجود در قیمت‌های گذشته و بررسی مسیرهای گذشته قیمت، به پیش‌بینی دست یافت؛ به نحوی که این پیش‌بینی باعث ایجاد بازده اضافی شود؛ زیرا هرگونه قابلیت پیش‌بینی از طریق بررسی قیمت‌های گذشته، به سرعت در قیمت‌ها منعکس می‌شود. در سطح کارایی نیمه‌قوی، قیمت‌های گذشته، منعکس‌کننده همه اطلاعات عام و منتشره شده در اوراق و کالا هستند. در این سطح، اطلاعات محدود به قیمت‌های گذشته نیست؛ بلکه در برگیرنده همه اطلاعات و اخبار اقتصادی است که بر قیمت کالا یا اوراق بهادار تأثیرگذار هستند. در اصطلاح به این نوع اطلاعات، «اطلاعات بنیادی» گفته می‌شود. در سطح کارایی قوی، تمام اطلاعات، از جمله اطلاعات محرمانه و اطلاعات در دسترس عموم، در قیمت اوراق بهادار انعکاس دارد. این اطلاعات بیشتر در بازار سهام بررسی می‌شوند؛ جایی که ممکن است مدیران و سهامداران عمده شرکت، اطلاعاتی داشته باشند که در دسترس عموم سرمایه‌گذاران قرار نگیرد.

با توجه به سطح‌های معرفی شده برای کارایی، روش‌های پیش‌بینی قیمت سهام و کالاها به دسته‌های مختلفی تقسیم می‌شوند. به این ترتیب کلیه روش‌هایی که تمرکز آن‌ها بر استفاده از اطلاعات موجود در قیمت‌های گذشته است در حوزه روش‌های ارزیابی کارایی ضعیف بازار دسته‌بندی می‌شوند. مجموعه این روش‌ها، «تحلیل‌های تکنیکال»^۱ نامیده می‌شوند. این نوع تحلیل‌ها بسیار رایج است و در همه بازارها متخصصان زیادی در حوزه تحلیل تکنیکال وجود دارد. این متخصصان تلاش می‌کنند با بررسی روندهای قیمت در گذشته، به الگوهای تکراری دست یابند که قابلیت پیش‌بینی قیمت‌های آتی را داشته باشند. همان‌طور که بیان شد، اگر بازار در سطح ضعیف، کارا باشد، استفاده از هر روش پیش‌بینی یا استراتژی سرمایه‌گذاری که بر مبنای اطلاعات گذشته قیمتی استوار است، باعث کسب بازده اضافه برای سرمایه‌گذار نمی‌شود. از طرف دیگر، روش‌هایی که تلاش دارند با استفاده از اطلاعات بنیادی تغییر قیمت را پیش‌بینی و استراتژی سرمایه‌گذاری خود را بر این اساس تنظیم کنند، به نوعی در حوزه روش‌هایی دسته‌بندی می‌شوند که کارایی بازار را در سطح نیمه‌قوی ارزیابی می‌کنند. اطلاعات بنیادی شامل

1. Technical Analysis

کلیه اخبار و اطلاعات اقتصادی منتشره در بازار و اطلاعات منتشره در صنایع، شرکت‌ها و متغیرهای اقتصادی است. این روش‌ها در حوزه تحلیل‌های بنیادی^۱ دسته‌بندی می‌شوند. تحلیل‌های بنیادی به دنبال شناخت عوامل بنیادی هستند که بر قیمت دارایی یا کالا تأثیر دارند و با استفاده از مدل‌های اقتصادی تلاش می‌کنند تغییرات قیمت کالاها و اوراق بهادار را پیش‌بینی کنند. در اینجا نیز در صورتی که بازار در سطح نیمه‌قوی کارا باشد، استفاده از روش‌های بنیادی برای پیش‌بینی تغییرات قیمت، باعث افزایش بازده، نسبت به بازده تعادلی معمول برای سرمایه‌گذار نمی‌شود.

هرچند کارایی بازار سهام به شکل گسترده‌ای در مطالعات و پژوهش‌های علمی بررسی شده است، سطح کارایی بازارهای جهانی فلزات و به‌خصوص کارایی در سطح نیمه‌قوی، کمتر بررسی شده است. یکی از چالش‌های اصلی در ارتباط با سنجش کارایی در سطح نیمه‌قوی، ارائه مدلی برای بازده موردانتظار در بازار فلزات است. سنجش کارایی بازار در این سطح بر این مفهوم تمرکز دارد که آیا می‌توان با استفاده از اطلاعات منتشره در رابطه با سهام یا کالا، استراتژی سرمایه‌گذاری طراحی کرد که بازده‌ای بیشتر از بازده تعادلی موردانتظار سرمایه‌گذار در اختیار وی قرار دهد؟ در بازار سهام، مدل‌های متعددی برای تعیین بازده تعادلی موردانتظار طراحی شده است؛ اما در بازار فلزات این مدل‌ها توسعه نیافته‌اند.

با وجود این مدل‌های زیادی برای سنجش کارایی در سطح ضعیف، توسعه یافته است. یکی از مفاهیم کاربردی در این زمینه، «نظریه گام تصادفی»^۲ است. اگر قیمت‌ها همواره منعکس‌کننده آخرین اطلاعات منتشره در بازار باشند، فعالان بازار از اطلاعاتی استفاده می‌کنند که تغییرات قیمت آتی را پیش‌بینی کند؛ در نتیجه استفاده از این اطلاعات باعث تغییرات قیمت در زمان حال می‌شود؛ بنابراین تغییرات آتی قیمت تنها در اثر ورود اطلاعات جدید یا اخبار در طی دوره آتی انجام می‌شود. با توجه به تعریف این نظریه، چون این اخبار به صورت تصادفی ایجاد می‌شوند، تغییرات قیمت‌های آتی نیز تصادفی خواهد بود.

در این پژوهش از مفهوم نظریه گام تصادفی استفاده شده است. قبل از اینکه بهترین مدل پیش‌بینی قیمت سرب با دو رویکرد تکنیکال و بنیادی، شناسایی شود، کارایی در سطح ضعیف سنجیده می‌شود. نتایج این بخش نشان می‌دهد که تغییرات هفتگی قیمت سرب دارای خودهمبستگی معنادار در گام یک و چهار است. به این ترتیب، سری زمانی قیمت از فرضیه گام تصادفی پیروی نمی‌کند. آماره‌ای که لیون و باکس^۳ (۱۹۷۸)، توسعه داده‌اند، نشان می‌دهد سری زمانی قیمت از فرآیند گام تصادفی پیروی نمی‌کند و در نتیجه بازار در سطح ضعیف کارا نیست.

1. Fundamental Analysis
2. Random Walk
3. Ljung-Box Test Statistics

این آماره تا پنج و ده گام برای آزمون خودهمبستگی به صورت هم‌زمان استفاده می‌شود. یک نتیجه کاربردی از این بخش این است که سری زمانی قیمت پیش‌بینی‌پذیر است و با استفاده از اطلاعات قیمتی گذشته (یعنی با استفاده از کلیه روش‌هایی که در رویکرد تکنیکال از آن‌ها استفاده می‌شود)، قیمت پیش‌بینی می‌شود. این پیش‌بینی با استفاده از مجموعه‌ای از روش‌های خطی و غیرخطی پیش‌بینی، بررسی می‌شود و نتایج آن نشان می‌دهد، نتیجه‌گیری در ارتباط با کارایی ضعیف بازار سرب در سطح پایینی است [۱۶].

فلز سرب از جمله فلزاتی است که فرایند تولید آن یکی از شاخص‌های اصلی رشد اقتصادی است. این فلز یکی از مهم‌ترین فلزات در جهان است و با فعالیت‌های صنعتی و اقتصادی ارتباط دارد. برای پیش‌بینی قیمت سرب علاوه بر روش‌های معمول، از جمله مدل‌های سری زمانی و مدل‌های رگرسیون، از مجموعه‌ای از روش‌های غیرخطی نیز استفاده می‌شود. اخیراً با رشد الگوریتم‌های فراابتکاری و هوش مصنوعی، اقتصاددانان به این روش‌ها برای پیش‌بینی توجه زیادی دارند. از جمله این روش‌ها، شبکه‌های عصبی و منطق فازی هستند. این روش‌ها ابزارهای قدرتمندی برای تجزیه و تحلیل داده‌ها هستند و به این دلیل مدل‌های مختلفی برای پیش‌بینی متغیرهای اقتصادی پیشنهاد شده است. برخی از قابلیت‌های این روش‌ها، مانند ظرفیت استفاده از روابط پیچیده و غیرخطی، انگیزه استفاده از این روش‌ها را در مسائل اقتصادی و مالی، به‌ویژه پیش‌بینی قیمت، تقویت کرده است. از آنجاکه عوامل مختلفی در رفتار بازار فلزات، از جمله بازار سرب، مؤثر هستند، تصور می‌شود استفاده از الگوهای غیرخطی، رفتار این بازارها را بهتر پیش‌بینی کند؛ به همین دلیل مجموعه‌ای از روش‌های غیرخطی از جمله، شبکه‌های عصبی و ترکیب آن‌ها با الگوریتم‌های ژنتیک برای پیش‌بینی قیمت در این پژوهش استفاده شده است؛ بنابراین در بخش تحلیل تکنیکال، علاوه بر مدل‌های خطی سری زمانی، از الگوهای غیرخطی نیز برای پیش‌بینی قیمت استفاده می‌شود. در بخش تحلیل بنیادی نیز ابتدا سعی می‌شود عوامل مؤثر بر قیمت در بازار سرب شناسایی و پس از تعیین یک مدل مفهومی، قیمت آن با استفاده از تکنیک‌های مختلف بنیادین (مانند رگرسیون و شبکه‌های عصبی)، پیش‌بینی شود.

۲. مبانی نظری و پیشینه پژوهش

مطالعات متعددی برای پیش‌بینی قیمت فلزات اساسی و فلزات قیمتی انجام شده است. در این قسمت برخی از این پژوهش‌ها تشریح می‌شود:

حجازی و صابری کمرپشتی (۱۳۹۵)، در پژوهش خود، روش جدیدتری نسبت به سایر روش‌های متداول پیش‌بینی ارائه داده‌اند. در این پژوهش با استفاده از مدل شبکه عصبی

سازمان‌دهی گروهی داده‌ها (GMDH)^۱، اثر متغیرهای کلان اقتصادی بر قیمت سکه الگوسازی و پیش‌بینی شده است. این الگوریتم تأثیرگذارترین متغیرها را شناسایی و رتبه‌بندی می‌کند. زیوری پایدار و صابری‌کمرپشتی (۱۳۹۵)، به این نتیجه رسیدند که به‌علت نوسانات شدید موجود در داده‌های قیمت سهام «شرکت ایران خودرو»، شبکه عصبی، پیش‌بینی بهتری از قیمت سهام ارائه می‌دهد.

پرچمی و همکاران (۱۳۹۵)، تلاش کردند تا تأثیر متغیرهای مالی را بر بازده سهام شرکت‌های پذیرفته‌شده در «بورس اوراق بهادار تهران» برای دوره زمانی ۱۳۸۲ تا ۱۳۹۲ مشخص کنند. هدف این پژوهش پیش‌بینی بازده سهام با استفاده از متغیرهای مالی با رویکرد شبکه عصبی بود. در این پژوهش برای پیش‌بینی بازده سهام از دو روش رگرسیون حداقل مربعات و شبکه عصبی مصنوعی استفاده شد. نتایج نشان داد که شبکه عصبی مصنوعی بهتر از روش رگرسیون حداقل مربعات بازده سهام را پیش‌بینی می‌کند.

معنوی و کریمی (۱۳۹۳)، بهترین وزن‌های شبکه عصبی را تنظیم کردند. آن‌ها با حداقل‌سازی تابع خطا، دقت پیش‌بینی را حداکثر کردند. نتایج نشان می‌دهد، پیش‌بینی سری زمانی قیمت فلز مس با استفاده از شبکه عصبی مصنوعی و الگوریتم کرم شب‌تاب، خطای برآورد قیمت را نسبت به روش شبکه عصبی کاهش می‌دهد.

ابریشمی همکاران (۱۳۹۳)، از سامانه خبره تلفیقی برای پیش‌بینی قیمت نفت استفاده کردند. در سامانه خبره، قوانین حاصل از سامانه مبتنی بر پایگاه قواعد و میانگین‌های متحرک قیمت نفت، به‌عنوان ورودی‌های شبکه عصبی وارد جریان مدل‌سازی می‌شود و برای پنج زیردوره دربرگیرنده سال‌های ۲۰۰۴-۲۰۰۸، پیش‌بینی انجام شد. مقایسه نتایج این سامانه با نتایج حاصل از پیش‌بینی با ARIMA^۲ و شبکه عصبی GMDH نشان می‌دهد که به‌کارگیری روش‌های ترکیبی و سامانه خبره، عملکرد پیش‌بینی را بهبود داده و نتایج دقیق‌تر و مطمئن‌تری ارائه می‌دهد.

شریف‌آبادی و خوانچه‌مهر (۱۳۹۳) در پژوهشی نشان دادند که شبکه عصبی مصنوعی که با استفاده از روش طراحی آزمایشات تاگوچی طراحی شده‌اند، نسبت به سایر شبکه‌ها عملکرد بهتری دارند.

نتایج پژوهش نظری، طباطبایی و احراری (۱۳۹۲) حاکی از آن است که شبکه‌ی عصبی مصنوعی GMDH با کمترین خطا، تابع قیمت را برآورد می‌کند.

فان و همکاران (۲۰۱۶) در پژوهشی، قیمت زغال‌سنگ را در بازه کوتاه‌مدت پیش‌بینی کردند. آن‌ها پس از شناسایی خصوصیات آشوبناکی قیمت زغال‌سنگ، برای پیش‌بینی قیمت از

1. Group Method of Data Handing

2. Auto Regressive Integrated Moving Average

شبکه پرسپترون چندلایه استفاده کردند. نتیجه این پژوهش نشان داد که توپولوژی-3 MLP^۱ از نظر معیارهای درصد میانگین خطای مطلق و ریشه میانگین مربعات خطا در مقایسه با مدل میانگین متحرک خودرگرسیون انباشته (ARIMA) و مدل MLP، الگو و خصوصیات غیرخطی سری زمانی قیمت زغال‌سنگ را بهتر تشخیص می‌دهد.

آنسالاکیس (۲۰۱۶)، سه روش هوش محاسباتی را برای پیش‌بینی‌های دقیق برای تغییرات در قیمت کربن ارائه داد. این سه روش شامل یک ترکیب جدید فازی-عصبی به نام PATSOS؛ شبکه عصبی مصنوعی (ANN) و یک شبکه انطباقی استنتاج فازی (ANFIS) است. مشاهده قیمت روزانه کربن و نتایج نشان می‌دهد که PATSOS بهترین و دقیق‌ترین روش را برای پیش‌بینی قیمت کربن، ارائه می‌دهد. این پژوهش، نخستین تلاش برای ثبت اعمال یک کنترلر فازی-عصبی هیبریدی (ترکیبی) برای پیش‌بینی قیمت کربن است.

منفرد و انکه (۲۰۱۴)، یک مدل ترکیبی شبکه عصبی را برای پیش‌بینی نوسانات ارائه دادند و به این نتیجه رسیدند که مدل ترکیبی، پیش‌بینی خوبی در رویدادهای بی‌نهایت دارد. آزاده و همکاران (۲۰۱۲)، از یک الگوریتم انعطاف‌پذیر بر اساس شبکه‌های عصبی و رگرسیون فازی برای پیش‌بینی قیمت نفت استفاده کردند و به این نتیجه رسیدند که مدل ANN بهترین پیش‌بینی را از نظر میانگین درصد خطای مطلق^۲ (MAPE) دارد. باتوجه به پژوهش‌های خارجی و داخلی بررسی‌شده، تفاوت این پژوهش با پژوهش‌های بالا به شرح زیر است:

پژوهشی در زمینه پیش‌بینی قیمت سرب انجام نشده و در پژوهش‌های انجام‌شده خطای پیش‌بینی رویکردهای مختلف علت و معلولی و سری زمانی با هم مقایسه نشده است؛ به عبارت دیگر پژوهشی که مبنای آن رویکرد تکنیکال و بنیادی در رابطه با قیمت سرب باشد، وجود نداشته و رویکرد تکنیکال استفاده‌شده که ترکیب شبکه عصبی GMDH و MLP با الگوریتم ژنتیک باشد، آن‌گونه که در پژوهش حاضر ارائه شده، انجام نشده است. خلاصه‌ای از مطالعات پیشین در جدول ۱، ارائه شده است.

1. Multi Layer Perceptron
2. Mean Square Absolut Error

جدول ۱. خلاصه‌ای از مطالعات پیشین

سال	نام پژوهشگر	عنوان پژوهش	هدف و شرح پژوهش	روش پژوهش
۱۳۹۵	حجازی و صابری کمرپشتی	پیش‌بینی قیمت سکه طلا (تمام بهار آزادی) با رویکرد شبکه عصبی GMDH	شناسایی متغیرهای کلان اقتصادی تأثیرگذار بر قیمت طلا، پیش‌بینی قیمت و رتبه‌بندی تأثیرگذارترین متغیرها	GMDH
۱۳۹۵	زیوری پایدار و صابری کمرپشتی	تأثیر تغییرات تورم و نرخ فولاد به تغییرات بازار سهام خودرو با استفاده از تکنیک شبکه‌های عصبی مصنوعی مدل GMDH	پیش‌بینی بهتر تغییرات بازار سهام خودرو با در نظر گرفتن نوسانات شدید موجود در قیمت سهام شرکت ایران خودرو	شبکه عصبی مصنوعی و مدل GMDH
۱۳۹۵	پرچمی و همکاران	پیش‌بینی بازده سهام با متغیرهای مالی با رویکرد شبکه‌های عصبی	تأثیر متغیرهای مالی بر بازده سهام شرکت‌های پذیرفته‌شده در «بورس اوراق بهادار تهران» و پیش‌بینی بازده سهام	رگرسیون حداقل مربعات OLS شبکه عصبی مصنوعی
۱۳۹۳	معنوی و کریمی	رویکرد نوین در داده‌کاوی برای پیش‌بینی قیمت فلزات پایه بر مبنای الگوریتم ترکیبی کرم شب‌تاب و شبکه عصبی	تعیین بهترین وزن‌های شبکه عصبی و حداقل‌سازی تابع خطا و پیش‌بینی سری زمانی قیمت مس	شبکه عصبی مصنوعی الگوریتم فرامکاشفه‌ای کرم شب‌تاب
۱۳۹۳	ابریشمی و همکاران	پیش‌بینی قیمت نفت با استفاده از سامانه خبره تلفیقی	به کارگیری روش‌های ترکیبی و سامانه خبره برای بهبود پیش‌بینی	ARIMA GMDH سامانه خبره
۲۰۱۶	آتسالاکیس	استفاده از هوش محاسباتی برای پیش‌بینی قیمت کربن	پیش‌بینی دقیق برای تغییرات قیمت کربن	کنترل فازی - عصبی PATSOS سیستم تطبیقی استنتاج عصبی - فازی (ANFIS) شبکه عصبی مصنوعی (ANN)
۲۰۱۴	منفرد و انکه	پیش‌بینی نوسانات با استفاده از ترکیب مدل شبکه عصبی GJR-GARCH	پیش‌بینی نوسانات با مدل ترکیبی	مدل ترکیبی GJR-GARCH
۲۰۱۲	آزاده و همکاران	الگوریتم برنامه‌نویسی ریاضی انعطاف‌پذیر شبکه‌های عصبی فازی برای بهبود و پیش‌بینی برآورد قیمت نفت	ارائه الگوریتم انعطاف‌پذیر بر اساس شبکه‌های عصبی و رگرسیون فازی برای پیش‌بینی قیمت نفت	رگرسیون فازی ANN

۳. روش‌شناسی پژوهش

روش‌های پیش‌بینی استفاده‌شده در پژوهش. مدل‌های استفاده‌شده در پژوهش به دو شکل مدل‌های سری زمانی (رویکرد تکنیکال) و علت‌ومعلولی (رویکرد بنیادین) هستند. مدل سری زمانی استفاده‌شده در این پژوهش، مدل ARIMA است. این مدل، یک مدل خطی است. مدل‌های ترکیبی شامل ترکیب شبکه عصبی MLP و GMDH با الگوریتم ژنتیک است و جزو مدل‌های غیرخطی هستند. مدل‌های علت‌ومعلولی نیز شامل رگرسیون حداقل مربعات گام‌به‌گام^۱ و یک مدل خطی است. شبکه عصبی MLP و شبکه عصبی GMDH جزو مدل‌های غیرخطی هستند.

در رویکرد تکنیکال تلاش می‌شود از اطلاعات نهفته در معاملات گذشته برای پیش‌بینی حرکت آینده قیمت استفاده شود. پیروان تحلیل تکنیکی با استفاده از اطلاعاتی مانند، حجم معاملات و قیمت سهام، روند حرکتی قیمت سهام را بررسی می‌کنند [۲۲]. آن‌ها معتقدند، همه اطلاعات لازم درخصوص یک سهم در قیمت آن متبلور است. این ایده اساسی، آن‌ها را از جمع‌آوری اطلاعات گسترده‌ای، مانند عملکرد شرکت، صنعتی که شرکت در آن قرار دارد، مباحث کلان اقتصادی و سیاسی، بی‌نیاز می‌کند [۲۸]. مهم‌ترین اصل تحلیل تکنیکال این است که «همه چیز در قیمت لحاظ شده است». یک تحلیل‌گر تکنیکی معتقد است قیمت فعلی، همه اطلاعات را درباره یک سهم دربردارد؛ زیرا تمام اطلاعات تأثیر خود را قبلاً بر نمودار قیمت گذاشته‌اند. دومین اصل تحلیل تکنیکال این است که قیمت‌ها بر اساس روندها حرکت می‌کنند؛ به عبارت دیگر قیمت‌ها دوست دارند به‌جای تغییر جهت، روند فعلی خود را حفظ کنند. سومین اصل تحلیل تکنیکال می‌گوید: «تاریخ تکرار می‌شود». بر پایه این عقیده تاریخچه قیمت، مطالعه می‌شود؛ زیرا مانند کلیدی برای پیش‌بینی آینده است؛ درواقع می‌گوید: «آینده چیزی جز تاریخ گذشته نیست» [۱۴].

در روش‌های علت‌ومعلولی یا رویکرد بنیادین، ابتدا تلاش می‌شود عوامل بنیادین و اقتصادی مؤثر بر قیمت شناسایی شود؛ سپس در یک مدل خطی یا غیرخطی شدت و نحوه تأثیر این متغیرها در تغییرات قیمت، بررسی می‌شود؛ درنهایت مدلی که بهترین برازش را با اطلاعات گذشته دارد، برای پیش‌بینی به‌کار می‌رود. تحلیل بنیادی به‌صورت گسترده در تحلیل قیمت سهام شرکت‌ها استفاده می‌شود. در این روش فرض می‌شود سرمایه‌گذار بر اساس تجزیه‌وتحلیل‌های چهارگانه، عوامل بنیادین مؤثر بر قیمت را شناسایی کرده و از آن‌ها برای محاسبه قیمت استفاده می‌کند [۱۳]. تجزیه‌وتحلیل چهارگانه شامل، تجزیه‌وتحلیل شرایط اقتصادی کشور، تجزیه‌وتحلیل وضعیت صنعت مربوطه، تجزیه‌وتحلیل شرکت و تجزیه‌وتحلیل

1. Stepwise Least Squares

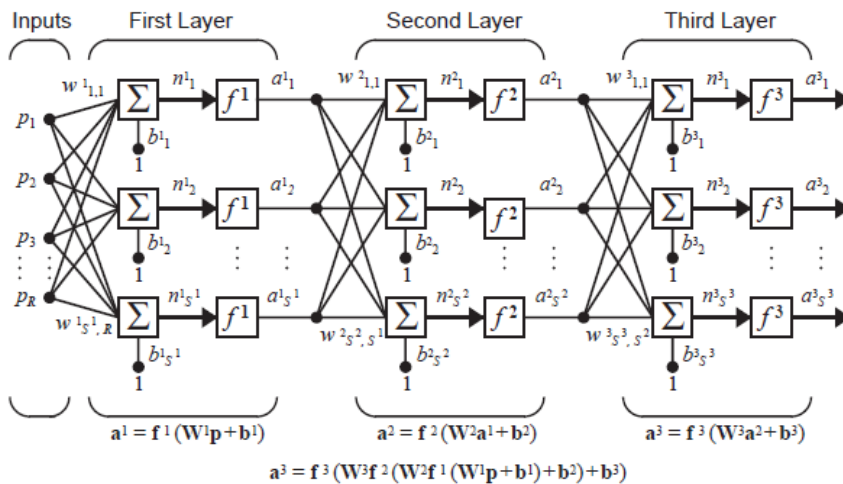
صورت‌های مالی شرکت است. به‌طور طبیعی این روش صرفاً مخصوص بازار سهام نیست و در هر بازار دیگری، برای پیش‌بینی تغییرات قیمت کالاها می‌توان از این روش استفاده کرد. در ادامه روش‌های مختلف خطی و غیرخطی استفاده‌شده در دو رویکرد کلی تکنیکال و بنیادی برای پیش‌بینی قیمت سرب، تشریح می‌شوند.

روش‌های استفاده‌شده در رویکرد بنیادی

روش رگرسیون گام‌به‌گام (SLS)^۱. تحلیل رگرسیون از رایج‌ترین مدل‌های خطی برای تعیین وابستگی یک متغیر وابسته، مانند قیمت، به مجموعه‌ای از عوامل مستقل و تأثیرگذار بر قیمت، است؛ اما زمانی که تعداد زیادی از متغیرهای بالقوه مؤثر در قیمت وجود داشته باشد، انتخاب متغیرهایی که بیشترین تأثیر را بر متغیر وابسته دارند، چالش‌برانگیز خواهد بود. به‌دلیل هم‌پوشانی احتمالی اطلاعات بین این متغیرها، نیازی به وجود همه آن‌ها به‌صورت هم‌زمان در مدل نیست. ازجمله روش‌های انتخاب متغیر در اجرای یک رگرسیون، استفاده از روش‌های رگرسیون گام‌به‌گام یا حداقل مربعات گام‌به‌گام است. در این روش، ورود متغیرهای مستقل به مدل رگرسیونی به‌صورت گام‌به‌گام انجام می‌شود؛ یعنی ابتدا متغیری انتخاب می‌شود که بیشترین همبستگی را با متغیر وابسته دارد. دومین متغیری که وارد تحلیل می‌شود، متغیری است که پس از تفکیک متغیر مقدم بر آن، موجب بیشترین افزایش در مقدار ضریب تعیین تعدیل یافته می‌شود؛ به‌گونه‌ای که آزمون F برای تفاوت دو مدل به‌صورت معناداری برتری مدل جدید نسبت به مدل قبلی را نشان دهد؛ همچنین در هر گام کنترل می‌شود که با وجود متغیر اضافه‌شده، آیا متغیری یافت می‌شود که اهمیت خود را در برآزش از دست داده باشد؟ در صورت پاسخ مثبت به این سؤال، متغیر حذف می‌شود. ورود متغیرها به این ترتیب ادامه می‌یابد تا بهترین مدل برآزش‌شده، یافت شود.

شبکه عصبی پرسپترون چندلایه (MLP). شبکه عصبی پرسپترون چندلایه شامل یک لایه ورودی، حداقل یک لایه میانی و یک لایه خروجی است. نرون‌ها از هر لایه به‌صورت اتصال کامل^۲ به نرون‌های لایه بعدی متصل شده‌اند. نرون‌ها در MLP دارای مقادیر پیوسته ورودی و خروجی، توابع جمع وزنی مقادیر ورودی و توابع فعال‌سازی خطی هستند. از مهم‌ترین الگوریتم‌های یادگیری MLP، الگوریتم پس‌انتشار خطا^۳ است [۱۵]. ساختار شبکه‌های MLP به‌صورت شکل ۱، است.

1. Stepwise Least Squares
2. Fully-Connected
3. Error Back Propagation



شکل ۱. شبکه عصبی پرسپترون چندلایه (MLP) (هاگان، ۲۰۱۴)

الگوریتم سازمان‌دهی گروهی داده‌ها. شبکه عصبی GMDH را ایواخنکو (۱۹۶۶) معرفی کرده است [۱۰]. شبکه GMDH، دربرگیرنده مجموعه‌ای از نرون‌ها است که به صورت زوجی از طریق یک چندجمله‌ای درجه دوم به وجود می‌آید. این شبکه با استفاده از ترکیب چندجمله‌ای‌های درجه دوم برای یک مجموعه از ورودی‌های $X = (x_1, x_2, \dots, x_m)$ مقدار \hat{Y} را برای مقدار واقعی Y تقریب می‌زند. در شبکه GMDH شکل عمومی تابع اتصال بین ورودی‌ها و خروجی Y با استفاده از چندجمله‌ای مراتب بالا مانند رابطه ۱، بیان می‌شود. این چندجمله‌ای، «چندجمله‌ای ایواخنکو» نامیده می‌شود.

$$\tilde{y} = a_0 + \sum_{i=1}^m a_i x_i + \sum_{i=1}^m \sum_{j=1}^m a_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijk} x_i x_j x_k + \dots \quad (1)$$

بنیای ریاضی شبکه GMDH بر اساس تجزیه چندجمله‌ای ایواخنکو به چندجمله‌ای‌های دومتغیره درجه دوم پایه‌ریزی شده است.


$$\hat{Y} = F(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i^2 + a_4 x_j^2 + a_5 x_i x_j \quad (2)$$

در این الگوریتم، ساختار نرون‌ها با شبکه‌های عصبی پرسپترون چندلایه کاملاً متفاوت است و هر نرون یک دوجمله‌ای درجه دوم مانند رابطه ۱، است. هدف، تخمین پارامترهای مجهول

با استفاده از روش رگرسیونی حداقل مربعات (LS) است؛ به‌گونه‌ای که میانگین مربعات خطا (MSE) حداقل شود.

$$MSE = \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n} \quad (3)$$

با توجه به اینکه هدف از ارائه این الگوریتم چیزی جز الگوسازی سیستم اولیه نیست، با ترکیب سیستم‌های جزئی (معادله ۲) و تکرار این عمل الگوی اصلی سیستم به‌دست می‌آید. این الگو به‌شکل رابطه ۱، است. در شبکه GMDH همه ترکیب‌های دوتایی از m متغیر ورودی ساخته شده است و به‌ازای هر نرون، ضرایب مجهول دوجمله‌ای رابطه ۲، با استفاده از روش حداقل مربعات خطا به‌دست می‌آید. بعد از تجزیه سیستم اصلی به تعداد C_m^2 سیستم جزئی، الگو با دو متغیر ورودی برای هر یک از آن‌ها محاسبه می‌شود؛ سپس الگوهای جزئی ایجادشده دوبه‌دو با هم ترکیب می‌شوند. حاصل این ترکیب، تعداد $\frac{C_m^2(C_m^2 - 1)}{2}$ سیستم جزئی (نرون) جدید است (شکل ۲).



شکل ۲. ساختار شبکه‌های عصبی GMDH

تعداد متغیرهای وابسته به الگو یا تعداد ورودی‌های سیستم مهم نیست و تنها چیزی که اهمیت دارد دقت تخمین سیستم است. میزان دقت تخمین با الگوها تعیین می‌شود؛ بنابراین با در نظر گرفتن این قاعده، الگوهایی که دارای دقت بالاتر و قدرت تخمین بهتر هستند، انتخاب شده و بقیه الگوها حذف می‌شوند. این فرایند انتخاب الگو، برای کاهش محاسبات زائد، افزایش بازه و دقت الگوسازی، مناسب است. در دومین مرحله ترکیب، الگوهای جزئی انتخاب شده یا به عبارت دیگر سیستم‌های ایده‌آل شکل گرفته در مرحله قبلی، مانند مرحله قبلی دوبه‌دو ترکیب می‌شوند و سیستم‌های جزئی جدیدی با حداقل پنج و حداکثر شش متغیر ورودی تشکیل می‌شوند. به همین طریق در مراحل بعدی نیز با انتخاب و حذف تعدادی از الگوهای ایجاد شده، عمل ترکیب آن‌ها ادامه می‌یابد تا در نهایت الگوی نسبتاً ایده‌آلی به دست آید [۱۹].

روش‌های استفاده‌شده در رویکرد تکنیکال

مدل میانگین متحرک خودهمبسته یکپارچه^۱. در این دسته از مدل‌های سری زمانی که به مدل *ARIMA* نیز مشهور هستند، تنها بر اساس ارزش و مقادیر گذشته یک سری زمانی، ارزش و مقادیر آتی سری زمانی مزبور پیش‌بینی می‌شود. در این مدل برای رسیدن به الگوی برای داده‌ها، داده‌های مربوط به گذشته تجزیه و تحلیل می‌شود و یک الگوی مناسب خطی به داده‌ها برازش می‌شود؛ سپس با فرض اینکه الگوی به دست آمده قابل تعمیم به آینده است، از آن برای پیش‌بینی استفاده می‌شود. فرآیند *ARIMA* به صورت زیر تعریف می‌شود:

به ازای $q, d, p \geq 0$ ، سری زمانی Y_t (قیمت سرب) یک فرآیند $ARIMA(p, d, q)$ است اگر:

$$\phi(L)(1-L)^d Y_t = \theta(L)u_t \quad (۴)$$

در این حالت، فرآیند خودتوضیح میانگین متحرک از درجه (p, d, q) است که در آن q, d, p به ترتیب تعداد جملات خودتوضیح، مرتبه تفاضل‌گیری و تعداد جملات میانگین متحرک این سری زمانی هستند. در این رابطه، L عملگر وقفه است؛ به طوری که $L Y_t = Y_{t-1}$ و $L^k Y_t = Y_{t-k}$. این فرآیند به صورت رابطه ۵، نوشته می‌شود:

$$Y_t = \sum_{i=1}^p \phi_i Y_{t-i} + \sum_{j=1}^q \theta_j u_{t-j} + u_t \quad (۵)$$

1. Auto-Regressive Integrated Moving Average (ARIMA)

اگر d امین تفاضل Y_t یک فرآیند $ARMA$ مرتبه p و q داشته باشد، در این صورت Y_t یک فرآیند $ARIMA(p, d, q)$ نامیده می‌شود؛ در واقع مقدار فعلی متغیر، تابعی از مقادیر قبلی و مقادیر اخلاص (یا خطا) در گام‌های قبل است. به این ترتیب در استفاده از این مدل، روند قیمت سرب صرفاً تابعی از مقادیر گذشته آن است و مقادیر خطای پیش‌بینی در گام‌های قبل در نظر گرفته می‌شود. الگوی پیش‌بینی قیمت سرب در حالت کلی به صورت زیر نوشته می‌شود:

$$SP_t = C + \alpha_1 SP_{t-1} + \dots + \alpha_p SP_{t-p} + \beta_0 U_t + \beta_1 U_{t-1} + \dots + \beta_q U_{t-q} \quad (۶)$$

بنابراین مسئله مهم در این روش، تعیین تعداد وقفه‌های بهینه قیمت سرب و تشخیص ساختار متغیر تصادفی در مدل است. معمولاً برای تخمین الگوهای $ARMA$ و $ARIMA$ از روش باکس-جنکینز استفاده می‌شود. این روش دارای چهار مرحله اصلی تشخیص، تخمین، کنترل و پیش‌بینی است^۱. استفاده از روش باکس-جنکینز، نیازمند در دسترس بودن یک سری مانا^۲ است. در صورتی که یک سری زمانی، غیرمانا باشد، باید با تفاضل‌گیری به سری مانا تبدیل شود. چون سری زمانی قیمت از یک فرآیند مانا تبعیت نمی‌کند، در استفاده از این مدل از ابتدا تفاضل مرتبه اول محاسبه شده و برای پیش‌بینی با استفاده از این مدل استفاده می‌شود.

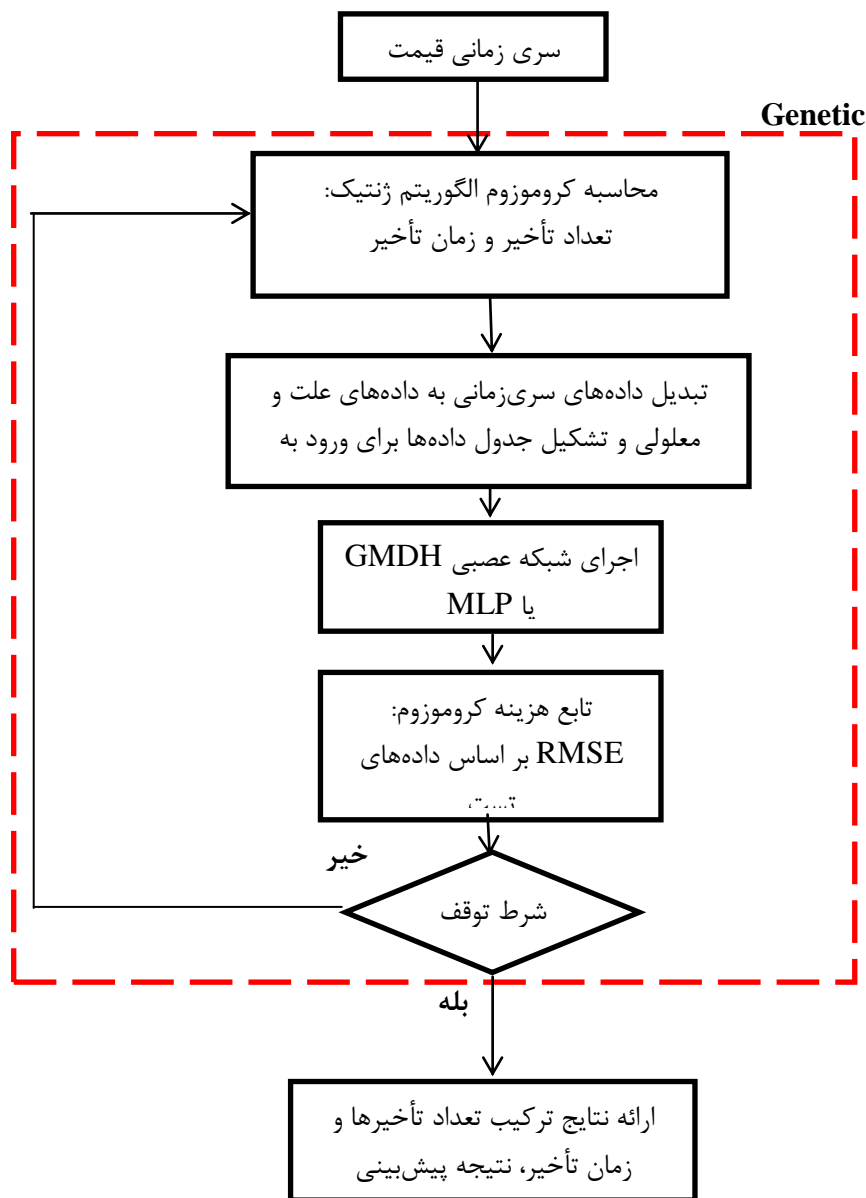
ترکیب شبکه‌های عصبی MLP و GMDH با الگوریتم ژنتیک. شبکه‌های عصبی در بسیاری از زمینه‌ها، از جمله پیش‌بینی قیمت سهام یا کالاها استفاده می‌شود؛ با وجود این دستیابی به نتایج مطلوب، تنها زمانی ممکن است که منبع غنی داده‌ها با مشاهدات فراوان در اختیار باشد. وقتی داده‌ها برای آموزش شبکه مقدار اندکی باشد، این تکنیک‌ها کارایی بالایی ندارند و این نقص، کاربردهای آن‌ها را به شدت محدود می‌کند [۲]. تکنیک‌های هوشمندی برای برطرف شدن مسئله محدودیت داده‌های آموزش ارائه شده است. از جمله این تکنیک‌ها، ایجاد نمونه‌های آموزشی هوشمند، انتخاب ویژگی، تنظیم مناسب پارامترهای مدل استنباطی و دسته‌بندی گروهی داده‌ها است که در پژوهش‌های رانگفو و همکاران (۲۰۰۶)، لی و لیو (۲۰۰۹)، هوانگ و مورگا (۲۰۰۴)، مورگا (۲۰۰۴)، تسای و لی (۲۰۰۸) و سهرابی وفا و همکاران (۱۳۹۱)، مشاهده می‌شود. هر یک از این پژوهش‌ها با رویکردی خاص تلاش می‌کنند تا مسئله محدودیت‌ها را حل کنند؛ اما هر یک از تکنیک‌های پیشنهادی در این زمینه نقاط ضعف متعددی دارد. امکان‌پذیر نبودن ایجاد نمونه‌های هوشمند و نبود نمونه‌هایی در واقعیت، اندک بودن متغیرها در واقعیت برای انتخاب ویژگی، انتخاب مدل نامناسب، محدودیت در ترکیب متغیرهای ورودی و استفاده از

۱. برای توضیح بیشتر مراجعه کنید به اکانل (۱۳۸۷)

تکنیک‌های خطی در تنظیم پارامترهای مدل غیرخطی، از جمله نقاط ضعف این تکنیک‌ها است [۲۶].

مدل‌های ترکیبی همان‌طور که از نامشان مشخص است، ترکیبی از راهکارهای هوش محاسباتی هستند. هدف از ارائه این مدل‌های ترکیبی، استفاده از قابلیت‌های یکدیگر برای حل مسئله و بهبود راه‌حل‌ها است. در این نوع سیستم‌ها معمولاً راهکارهای مختلف با هم ترکیب شده یا در کنار هم استفاده می‌شوند. به‌طور معمول استفاده از یک سیستم در داخل سیستم دیگر باعث می‌شود این سیستم‌ها نقاط ضعف یکدیگر را پوشش دهند، بر قدرت هم بی‌افزایند یا هم‌زمان در هر دو بخش بهبود یابند [۶]. شبکه‌های عصبی برای مدل‌های پیش‌بینی علت‌ومعلولی قابل‌استفاده هستند؛ زیرا در این نوع مسائل، ورودی‌ها و خروجی‌های شبکه قابل‌تعریف است. در مورد پیش‌بینی داده‌های سری زمانی با شبکه‌های عصبی لازم است داده‌های سری زمانی به داده‌های علت‌ومعلولی تبدیل شوند. این کار با استفاده از تعریف مقادیر تأخیر قابل‌انجام است. برای مثال، اگر مقادیر تأخیر برابر با $\{2, 5, 6\}$ در نظر گرفته شود، بدین مفهوم است که قیمت در لحظه t $[x_t]$ (متغیر پاسخ) به مقادیر قیمت در $[x_{t-2}, x_{t-5}, x_{t-6}]$ (متغیرهای توضیحی) وابسته است. در این پژوهش هدف از ترکیب شبکه عصبی و الگوریتم ژنتیک، یافتن بهترین تعداد تأخیرها و زمان هر کدام از تأخیرها است؛ به‌طوری‌که خطای شبکه عصبی به‌ازای آن‌ها حداقل شود. در الگوریتم ژنتیک تعداد تأخیرها و زمان هر کدام از تأخیرها به‌صورت تصادفی مقداردهی و داده‌های سری زمانی در قالب متغیرهای توضیحی تبدیل به داده‌های علت‌ومعلولی می‌شوند. پس از این مرحله، داده‌ها وارد شبکه عصبی GMDH و MLP می‌شوند و مجذور حداقل مربعات خطا (RMSE) محاسبه می‌شود، در مرحله تکرار، هر عضو جمعیت که شامل تأخیرها است با عملگرهای جهش و تقاطع الگوریتم ژنتیک تغییر یافته و مجدداً مقدار RMSE آن ارزیابی می‌شود. تکرار این فرایند تا برآورده شدن شرایط خاتمه، ادامه می‌یابد. بهترین جواب، عضوی است که معیار خطای شبکه عصبی (RMSE) به‌ازای آن از بقیه اعضای جمعیت کمتر باشد.

شکل ۳، فلوچارت الگوریتم ترکیبی پیش‌بینی‌کننده قیمت سرب را نشان می‌دهد.



شکل ۳. فلوجارت الگوریتم ترکیبی پیش‌بینی‌کننده قیمت سرب

۴. تحلیل داده‌ها و یافته‌های پژوهش

بررسی کارایی اطلاعاتی بازار سرب در سطح ضعیف. نخستین گام برای بررسی پیش‌بینی‌پذیری قیمت در بازارهای مختلف، بررسی کارایی اطلاعاتی این بازارها است. در این پژوهش نیز ابتدا کارایی اطلاعاتی بازار سرب در سطح ضعیف بررسی می‌شود. برای سنجش

کارایی در این سطح، از نظریه گام تصادفی استفاده می‌شود. این نظریه بیان می‌کند، اگر قیمت‌ها همواره منعکس‌کننده آخرین اطلاعات منتشره در بازار باشند، تغییرات آتی قیمت تنها در اثر ورود اطلاعات جدید یا اخبار در طی دوره آتی انجام می‌شود. بنا بر تعریف، چون این اخبار به صورت تصادفی ایجاد می‌شوند، تغییرات قیمت‌های آتی، فرآیندی تصادفی است. در این صورت هیچ رابطه خطی یا غیرخطی بین تغییرات متوالی قیمت وجود نخواهد داشت و در ضعیف‌ترین شکل، حداقل انتظار این است که تغییرات قیمت همبسته نباشند. بخش مهمی از آزمون‌هایی که برای بررسی کارایی ضعیف بازار در مبانی نظری مالی توسعه پیدا کرده است، مبتنی بر این مفهوم (بررسی خودهمبستگی سری زمانی تغییرات قیمت) در گام‌های مختلف توسعه یافته‌اند.

به این ترتیب در نخستین گام می‌توان خودهمبستگی سری زمانی تغییرات قیمت را در گام‌های مختلف آزمون کرد تا معین شود مقادیر خودهمبستگی تفاوت معناداری با صفر دارند یا خیر؟ نتایج این محاسبات تا گام پنج در جدول ۲، ارائه شده است. در ستون آخر هر سطر، احتمال فرض برابری مقدار همبستگی با صفر محاسبه می‌شود. همان‌طور که مشاهده می‌شود، این فرض در گام‌های یک و چهار رد می‌شود. برای آزمون اینکه آیا مقادیر همبستگی هم‌زمان برابر صفر هستند، از آماره آزمون استفاده می‌شود که لیون و باکس (۱۹۷۸)، توسعه داده‌اند. این آماره از توزیع کای - دو با K درجه آزادی تبعیت می‌کند و K برابر با تعداد گام‌های بررسی شده است. با توجه به جدول ۲، این آماره در دو گام ۵ و ۱۰ محاسبه شده است و فرض برابری هم‌زمان مقادیرهای همبستگی با صفر تا این دو گام رد می‌شود.

جدول ۲. بررسی خودهمبستگی سری زمانی تغییرات قیمت

احتمال	$\rho(k)^2 / (T - K)$	$\rho(k)^2$	$\rho(k)$	گام (K)
۰	۰/۰۰۰۰۸	۰/۰۴۵۶	۰/۲۱۴	۱
۰/۲۰۱	۰	۰/۰۰۱	-۰/۰۳۵	۲
۰/۲۵۹	۰	۰/۰۰۱	-۰/۰۲۷	۳
۰/۰۳۶	۰	۰/۰۰۵	۰/۰۷۵	۴
۰/۳۶۹	۰	۰	-۰/۰۱۴	۵
	احتمال	مقدار آماره	شرح	
	۰/۰۰۰۶۴	۳۰/۷۶	آماره لیون باکس گام ۵	
	۰/۰۰۰۰۳	۳۸/۲۹	آماره لیون باکس گام ۱۰	
		۵۷۲	تعداد مشاهدات	

بر اساس بررسی انجام شده در این بخش می‌توان نتیجه گرفت که بازار سرب لندن در سطح ضعیف کارا نیست و قیمت، حداقل با مدل‌های تکنیکال، پیش‌بینی می‌شود. این موضوع در

بخش بعدی بررسی می‌شود. در مدل‌های خطی برازش شده برای پیش‌بینی تغییرات قیمت، ضرایب عواملی چون تغییرات گذشته قیمت برای مدل‌سازی تغییرات فعلی، معنادار هستند. این نتیجه‌گیری عدم کارایی بازار سرب را در سطح ضعیف نشان می‌دهد. در مجموع نتیجه گرفته می‌شود که بازار سرب لندن در سطح ضعیف کارا نیست و قابلیت پیش‌بینی قیمت با استفاده از اطلاعات گذشته قیمتی، وجود دارد.

نتایج مدل‌های استفاده شده در رویکرد تکنیکال

نتایج مدل خودرگرسیون میانگین متحرک انباشته. فرآیند شناسایی و برازش بهترین مدل ARIMA برای پیش‌بینی یک سری زمانی به روش باکس-جنکینز معروف است. این روش شامل پنج مرحله به شرح زیر است. در پژوهش حاضر برای برازش مدل از نرم‌افزار EViews-9 استفاده شده است.

الف) ماناکردن سری زمانی. در مدل‌های ARIMA مانایی فرآیند تولید داده‌ها مهم است و باید قبل از مدل‌سازی بررسی شود. در اینجا برای شناسایی مانایی سری زمانی قیمت سرب از آزمون دیکی-فولر، استفاده شده است که نتایج این آزمون در جدول ۳، مشاهده می‌شود. این نتایج نشان می‌دهد، سری زمانی قیمت، مانا نیست؛ اما سری تفاضل مرتبه اول، مانا است و به همین دلیل از سری تفاضل مرتبه اول برای مدل‌سازی استفاده شده است.

جدول ۳. آزمون دیکی-فولر بر روی قیمت سرب با یک مرتبه تفاضل‌گیری

% Critical Value 10	-۲/۶۹۴۲۳	% Critical Value 1	-۳/۴۴۱۶۵۴
PP Test Statistic	-۱۹/۲۹۸۵۵	% Critical Value 5	-۲/۸۶۶۴۱۹

ب) مرحله تشخیص^۱. در این مرحله، مقدار اولیه q, d, p تعیین می‌شود. با توجه به اینکه با استفاده از شکل همبستگی و خودهمبستگی جزئی سری زمانی، یک حدس اولیه از مقادیر p و q ارائه می‌شود، با برازش این مدل و مدل‌های شبیه به آن، مدلی انتخاب می‌شود که بهترین برازش را ایجاد کند و باقیمانده مدل برازش شده بیشترین شباهت را با نوفه سفید داشته باشند. به این منظور، مدل‌های مختلف ARIMA اجرا می‌شود تا به کمترین مقدار از لحاظ معیارهای AIC، SBC و HQC رسید. در نهایت بر اساس معیار اطلاعات، ضریب تعیین مدل‌ها، ضریب دوربین واتسون و معناداری ضرایب مدل‌ها، مدل (۳، ۱، ۳) ARIMA در میان مدل‌ها، دارای بهترین شرایط است.

1. Identification

ج) تخمین. با توجه به اینکه الگوی نهایی پیش‌بینی قیمت سرب در این روش، مدل (۳، ۱، ۳) ARIMA است، جدول ۴، نتایج مربوط به این مدل را نشان می‌دهد.

جدول ۴. نتایج برآوردی مدل خطی $ARIMA(3, 1, 3)$ برای سری زمانی قیمت سرب

R-Squared	۹۸۰۴/۰
Akaike info criterion	۰۴۳۳۸/۱۲
Schwarz criterion	۱۲۸۶۸/۱۲
Hannan-Quinn criter	۰۷۷۰۲۷/۱۲
Durbin-Watson stat	۹۸۹۳۵/۱

از آنجا که مقدار آماره آزمون دوربین-واتسون در این مدل برابر ۱/۹۸۹۳۵ است، مدل مشکل خودهمبستگی ندارد و ضریب تعیین الگوی برآوردشده، ۰/۹۸ است. بر اساس نتایج ارائه شده مطلوب بودن برازش تأیید می‌شود.

د) کنترل: برای اطمینان از درستی مدل انتخاب شده بعد از تخمین، مدل کنترل می‌شود و از شکل همبستگی پسماند استفاده می‌شود. با توجه به شکل همبستگی پسماندها، شکل‌های خودهمبستگی و خودهمبستگی جزئی حاکی از آن است که مدل پژوهش حاضر دارای شرایط بهینه است و ملاحظه می‌شود، مقادیر خودهمبستگی باقیمانده‌ها در هر یک از وقفه‌ها در فاصله اطمینان یک انحراف معیار قرار گرفته‌اند.

ه) پیش‌بینی: در مرحله آخر، پیش‌بینی روند قیمت سرب با استفاده از اطلاعات موجود انجام شده است. در این مدل، مشاهدات قیمت سرب از ۲۰۰۵ تا ۲۰۱۵ به کار رفته که از سال ۲۰۱۲ تا ۲۰۱۵ برای پیش‌بینی خارج از نمونه استفاده شده است. نتایج حاصل از روش ARIMA در جدول ۵، مشاهده می‌شود.

جدول ۵. نتایج خروجی ARIMA

RMSE	۵۵/۹۸۰۰۵
MAPE	۲/۱۴۷۹۵۸
Bias Proportion	۰/۰۰۱۶۳۸

نتایج ترکیب شبکه عصبی MLP و الگوریتم ژنتیک. در این بخش شبکه عصبی پرسپترون با دو لایه پنهان آزمون می‌شود. مدل به صورت سری زمانی است و برای بهبود نتایج با الگوریتم ژنتیک ترکیب شده است. مراحل آن مانند مراحل شبکه عصبی پرسپترون است، با این تفاوت که

ورودی به صورت سری زمانی قیمت سرب است و به آن تأخیرهای بین ۱ تا ۱۰ داده می‌شود. الگوریتم ژنتیک بهترین تأخیر با کمترین خطای پیش‌بینی را تعیین می‌کند. پس از اجرای الگوریتم، کمترین خطا از شبکه با ۶ دوره تأخیر {۷ ۵ ۱ ۳ ۵ ۶}، ۹ نرون در لایه پنهان اول و ۷ نرون در لایه پنهان به دست می‌آید. خطای RMSE آن برابر با $58/73151$ و خطای MAPE برابر $2/299353$ است.

ترکیب شبکه عصبی GMDH و الگوریتم ژنتیک. سری زمانی قیمت سرب، داده‌های ورودی الگوریتم ژنتیک است. الگوریتم ژنتیک تعداد و طول تأخیرها را مشخص می‌کند؛ سپس داده‌های سری زمانی به داده‌های علت و معلولی تبدیل شده و به شبکه GMDH وارد و مقدار خطای پیش‌بینی RMSE محاسبه می‌شود. شبکه ترکیبی GMDH و الگوریتم ژنتیک با ۱۰ لایه، ۱۰۰ نرون و دوره تأخیر {۴ ۹ ۱ ۷ ۲ ۶ ۵ ۸} کمترین خطا را دارد و خطای RMSE آن، $31/839$ است.

نتایج مدل‌های استفاده شده در رویکرد بنیادی. در رویکرد بنیادین (روش‌های علت و معلولی)، ابتدا لازم است عوامل بنیادین و اقتصادی مؤثر بر قیمت شناسایی شود؛ سپس با استفاده از یک مدل خطی یا غیرخطی شدت و نحوه تأثیر این متغیرها در تغییرات قیمت بررسی می‌شود. به این منظور با مطالعه مقاله‌ها و گزارش‌های منتشر شده توسط «گروه بین‌المللی مطالعات سرب و روی (ILZSG)» و مصاحبه با متخصصان و صاحب‌نظران این فلز و همچنین با توجه به در دسترس بودن اطلاعات لازم، متغیرهای تأثیرگذار بر قیمت سرب، شامل متغیرهای مرتبط با اقتصاد آمریکا (نرخ تورم، میزان پرداخت به شغل‌های غیرکشاورزی، شاخص مدیران بخش خرید، تولید صنعتی، تولید ناخالص داخلی، شاخص قیمت مصرف‌کننده، نرخ بهره فدرال رزرو، نرخ بیکاری)، متغیرهای مرتبط با اقتصاد اروپا (نرخ بیکاری، شاخص قیمت مصرف‌کننده، رشد اقتصادی و تولید ناخالص داخلی)، اقتصاد جهان (نرخ تورم و رشد تولید ناخالص داخلی)، متغیرهای مرتبط با اقتصاد چین (شاخص قیمت تولیدکننده، تعادل تجارت، ذخایر ارز خارجی چین، تولید صنعتی و شاخص قیمت مصرف‌کننده).

سایر متغیرها (ارزش یورو در برابر دلار، ارزش یوان در برابر دلار، ارزش روپیه هند در برابر دلار، قیمت نفت، قیمت روی، قیمت طلا و میزان تولید سرب اولیه و سرب ثانویه) هستند. در ادامه بهترین مدل برای بررسی نحوه تأثیر این متغیرها بر قیمت شناسایی و برای پیش‌بینی استفاده می‌شود.

پیش‌بینی با استفاده از رگرسیون حداقل مربعات گام‌به‌گام. یکی از رویکردهای خطی در بخش تحلیل بنیادی، تکنیک حداقل مربعات گام‌به‌گام است. در این پژوهش برای تحلیل پیش‌بینی‌پذیری تغییرات قیمت با استفاده از متغیرهای بنیادی، از این تکنیک استفاده شده است. در این روش متغیرهای توضیحی به ترتیب اهمیت وارد مدل می‌شوند و برخی متغیرها که تأثیری بر مدل ندارند از مدل حذف می‌شوند. در پایان، ۱۹ متغیر به‌عنوان تأثیرگذارترین متغیرها انتخاب شده‌اند. در جدول ۶، نتایج حاصل از این مدل نشان داده شده است. در این تحلیل متغیر وابسته، تغییر قیمت سرب است و سایر متغیرها توضیحی هستند. برای اجتناب از امکان پیش‌بینی کاذب به دلیل وجود متغیرهای غیرمانا، کلیه متغیرهای مدل در صورت غیرمانا بودن، با استفاده از تفاوت مرتبه اول تبدیل به متغیرهای مانا شده‌اند. دوره زمانی برای پیش‌بینی درون‌نمونه‌ای، سال ۲۰۰۵ تا ۲۰۱۱ در نظر گرفته شده است. در این رگرسیون، به دلیل تغییرات شدید قیمت در سال‌های قبل از بحران سال ۲۰۰۸ و بلافاصله بعد از آن، دو متغیر موهومی نیز در مدل در نظر گرفته شده است. متغیر موهومی نخست مربوط به تغییرات افزایشی قیمت در دوره ژوئن ۲۰۰۶ تا اکتبر ۲۰۰۷ و متغیر دوم مربوط به کاهش شدید قیمت از نوامبر ۲۰۰۷ تا انتهای سال ۲۰۰۸ در اثر بحران مالی سال ۲۰۰۸ است. از آنجاکه تغییرات شدید این دو دوره متأثر از شرایط قبل و بعد از بحران سال ۲۰۰۸ است و قابلیت تعمیم به دوره‌های بعد را ندارد، دو متغیر موهومی موجود برای کنترل تغییرات خاص این دو دوره در نظر گرفته شده است. نتایج مربوط به برقراری رگرسیون خطی و تحلیل رگرسیون در جدول ۶ نشان داده شده است. همان‌طور که مشاهده می‌شود P-Value آماره F نشان‌دهنده معنادار بودن کل رگرسیون است. دو آزمون برای تشخیص خودهمبستگی انجام شده است، با توجه به مقدار عددی آماره دوربین-واتسون، همبستگی معناداری بین باقیمانده‌های مدل وجود ندارد؛ همچنین برای بررسی وجود خودهمبستگی در باقیمانده‌ها، آزمون LM (آزمون بروش گادفری^۱) با دو وقفه انجام شده است و با توجه به اینکه آماره F بزرگتر از ۵ درصد بود، در این رگرسیون مشکل خودهمبستگی وجود ندارد. با توجه به آزمون همبستگی که بین قیمت سرب و متغیرهای مستقل انجام شد، قیمت سرب بیشترین همبستگی را با قیمت نفت دارد. برای بررسی ناهمسانی واریانس، آزمون بروش-پاگان^۲ بر روی باقیمانده انجام شده است. مقدار آماره $0/000142$ دارای توزیع F است و با توجه به اینکه مقدار آن از مقدار بحرانی توزیع کای دو با درجه آزادی ۱۱ کمتر است، فرض صفر که دلالت بر همسانی واریانس دارد، رد نمی‌شود. برای سنجش امکان هم‌خطی بین متغیرهای مستقل، همبستگی دوجه‌دو بین متغیرها انجام شده است. بیشترین همبستگی مشاهده شده بین نرخ بهره فدرال رزرو و تولید صنعتی چین با $0/34$ است؛ همچنین با توجه به سطح همبستگی موردانتظار،

1. Breusch-Godfrey Test

2. Breusch-Pagan Test

هم‌خطی معناداری بین متغیرهای مستقل وجود ندارد.

جدول ۶. نتایج خروجی رگرسیون

متغیرها	ضرایب	انحراف معیار	آماره t	احتمال
تغییر قیمت نفت	۵/۴۷۴	۱/۰۵۳	۵/۱۹۷	۰/۰۰۰۰
تغییر قیمت روی	۰/۴۹۰	۰/۰۸۶	۵/۶۸۰	۰/۰۰۰۰
DUMMY1	۳۴/۴۶۲	۱۲/۲۸۳	۲/۸۰۵	۰/۰۰۵۲
DUMMY2	-۱۱۳/۴۶۹	۲۱/۹۵۲	-۵/۱۶۸	۰/۰۰۰۰
CPI چین	۲۴/۱۶۴	۶/۰۰۷	۴/۰۲۲	۰/۰۰۰۱
GDP اروپا	-۴/۳۱۲	۰/۹۸۶۶۱۱	-۴/۳۷۰	۰/۰۰۰۰
GDP هند	۲/۱۷۳	۲/۱۳۰	۱/۰۱۹	۰/۳۰۸۲
PMI چین	-۰/۹۹۵	۰/۳۳۹	-۲/۸۴۵	۰/۰۰۴۶
نرخ بهره آمریکا	۷۱/۳۴۴	۱۷/۲۷۳	۴/۱۳۰	۰/۰۰۰۰
ذخیره سرب LME	-۰/۰۰۸۷۵	۰/۰۰۵	-۱/۶۶۲	۰/۰۹۷۰
ADP آمریکا	۰/۴۰۳	۰/۱۸۱	۲/۲۲۶	۰/۰۲۶۴
GDP چین	۳۷۰/۶۸۲	۱۹۶/۳۱۱	۱/۸۸۸	۰/۰۵۹۵
تجارت چین	-۰/۷۸۱	۰/۲۸۲	-۲/۷۶۳	۰/۰۰۵۹
PPI اروپا	-۸۸/۳۹۵	۴۰/۱۸۲	-۲/۱۹۹	۰/۰۲۸۲
رشد اقتصادی اروپا	-۴۶/۸۹۳	۴۴/۴۵۱	-۱/۰۵۴	۰/۲۹۱۹
تولید صنعتی چین	۱۲/۷۴۲	۷/۲۸۲	۱/۷۴۹	۰/۰۰۸۰۷
نرخ ارز خارجی چین	-۰/۰۳۶۴	۰/۰۳۸۱	-۰/۹۵۳	۰/۳۴۱۰
نرخ بهره فدرال رزرو	-۳۱/۸۶۵	۳۲/۴۷۴	-۰/۹۸۱	۰/۳۲۶۹
تغییر قیمت طلا	۰/۱۳۶	۰/۱۰۶	۱/۲۸۲	۰/۲۰۰۱
نرخ تورم آمریکا	-۲۶/۷۰۸	۳۹/۰۱۵	-۰/۹۲۰	۰/۳۵۷۷
GDP جهانی	-۳۶۹/۹۹۷	۱۸۴/۶۵۴۷	-۲/۰۰۳	۰/۰۴۵۶
نرخ تورم جهانی	۴۱۲/۷۶۲	۲۱۰/۹۳۶	۱/۹۵۶۸۱۰	۰/۰۵۰۹
$\bar{R}^2 = 0.229 \quad F = 6.917 \quad (0.000) \quad R^2 = 0.267 \quad DW = 1.76$				
$Chi - Square(2,351) = 0.2067$ آماره برش-گادفری برای تشخیص خودهمبستگی				
$Chi - Square(11,351) = 0.0001$ آماره برش-پاگان برای تشخیص ناهمسانی واریانس				

با توجه به جدول ۶ مقدار ضریب تعیین تعدیل شده برابر با ۲۲ درصد است. این مقدار نشان می‌دهد تغییرات قیمت با استفاده از متغیرهای اقتصادی قدرت پیش‌بینی‌پذیری زیادی دارند. با توجه به این نکته، ضروری است که برای اجتناب از پدیده رگرسیون کاذب کلیه متغیرها (اعم از وابسته و مستقل) به متغیرهای مانا تبدیل شوند. به همین دلیل از تغییرات قیمت و نه خود قیمت، به‌عنوان متغیر وابسته استفاده شده است. میزان ضریب تعیین برای رگرسیون‌هایی که

متغیر وابسته مانا هستند (برای مثال، بازده قیمت) معمولاً مقادیر کوچکی است؛ همچنین بیشتر متغیرها دارای ضرایب معنادار هستند که نشان‌دهنده تأثیرگذاری این متغیرها در پیش‌بینی تغییرات قیمت است. بررسی ضرایب متغیرها در تحلیل رگرسیون امکان تعبیر اقتصادی نحوه تأثیرگذاری این متغیرها را فراهم می‌سازد. برای مثال، افزایش قیمت نفت نشانه‌ای از رونق در اقتصاد جهانی است؛ در نتیجه افزایش تقاضای ناشی از رونق اقتصادی، به افزایش قیمت سرب منجر می‌شود؛ همچنین تغییرات مثبت قیمت روی به‌عنوان فلزی که معمولاً به‌همراه سرب کاربرد صنعتی دارد، باعث افزایش قیمت سرب در دوره خواهد شد. افزایش تورم در چین به نشانه رونق اقتصادی (افزایش تقاضا) باعث افزایش قیمت سرب در دوره بعد می‌شود؛ از طرف دیگر افزایش ذخیره سرب در LME به‌طور طبیعی باعث کاهش قیمت می‌شود. افزایش نرخ بهره آمریکا و افزایش تورم در آمریکا که معمولاً به تقویت دلار منجر می‌شود، باعث کاهش قیمت سرب خواهد شد. با استفاده از ضرایب تخمین‌زده‌شده در دوره ۲۰۰۵ تا ۲۰۱۱، پیش‌بینی خارج از نمونه در طی دوره زمانی ۲۰۱۲ تا ۲۰۱۵ انجام می‌شود. خطاهای به‌دست آمده از این رگرسیون در دوره خارج از نمونه در جدول ۷، ارائه شده است. پایین بودن نسبت اریب^۱ نشان می‌دهد که مدل به‌خوبی برازش شده است.

با انجام آزمون بروش-گادفری که مقدار آن کمتر از ۰/۵ شده است مشخص شده که خودهمبستگی بین داده‌ها وجود ندارد؛ همچنین با اعمال آزمون بروش-پاگان که برای تشخیص ناهمسانی واریانس است و مقدار به‌دست‌آمده کمتر از ۰/۰۵ مشخص شده که ناهمسانی واریانس وجود ندارد.

جدول ۷. عملکرد روش SLS

RMSE	۳۷/۰۶۷۲۵
MAPE	۱/۵۹۵۷۰۶
Bias Proportion	۰/۰۰۰۰۰۱

پیش‌بینی با استفاده از مدل شبکه عصبی پرسپترون چندلایه. شبکه عصبی که در این بخش استفاده شده است، شبکه عصبی پرسپترون است. در این نوع شبکه، ابتدا داده‌های جمع‌آوری‌شده به‌عنوان ورودی‌ها، به لایه اول داده می‌شود و خروجی (قیمت سرب)، از لایه آخر به‌دست می‌آید. گره‌های لایه اول برابر با تعداد متغیرهای مستقل (در این پژوهش ۳۴ متغیر) هستند. در این قسمت به ترتیب مراحل طراحی و انتخاب شبکه توضیح داده خواهد شد و سپس نتایج حاصل از بهترین شبکه در پیش‌بینی با استفاده از نرم‌افزار MATLAB نشان داده می‌شود.

1. Bias Proportion

مرحله اول: نخستین مرحله، شناسایی نوع شبکه و آزمون آن است. در این پژوهش از شبکه‌های عصبی پیشرو استفاده می‌شود. برای تقریب توابع، شبکه‌های پیشرو نسبت به شبکه‌های دیگر بهتر عمل می‌کنند. در این نوع شبکه، خروجی هر لایه، ورودی لایه بعدی است و جزو بهترین شبکه‌ها از نوع یادگیری با ناظر است. آموزش این نوع شبکه روبه‌جلو، آموزش پس‌انتشار خطا است که در این شبکه از تابع آموزش پس‌انتشار تنظیم بیزی^۱ (BRB) استفاده شده است.

مرحله دوم: دومین مرحله، انتخاب ورودی‌های مدل یا همان واحدهای لایه ورودی (متغیرهای مستقل) است.

مرحله سوم: در این مرحله، ابتدا داده‌ها به سه دسته آموزش، اعتبارسنجی و آزمون تقسیم می‌شوند. به‌طور کلی هرچه تعداد نمونه‌های آموزشی بیشتر باشد، فرآیند آموزش شبکه بهتر انجام می‌گیرد. به این منظور از کل نمونه بررسی‌شده، به‌صورت تصادفی تعداد ۴۰۱ نمونه (۷۰ درصد) به‌عنوان داده‌های آموزشی، ۸۶ نمونه (۱۵ درصد) داده‌های اعتبارسنجی و ۸۶ نمونه (۱۵ درصد) به‌عنوان داده‌های آزمون انتخاب می‌شود.

مرحله چهارم: در این مرحله، تعداد لایه‌های شبکه انتخاب می‌شود. شبکه‌ای که برای این پژوهش انتخاب شده است، چهار لایه دارد: لایه ورودی، دو لایه پنهان و لایه خروجی. تعداد بیشتر لایه‌ها، شبکه را پیچیده می‌کند و تنها در صورتی که خروجی‌های بهتری از شبکه دریافت شود باید لایه‌ها را افزایش داد. تعداد لایه‌های بیشتر از ۴ در این شبکه، خطای پیش‌بینی را تا حد زیادی بالا می‌برد؛ به همین علت با ۴ لایه، پیش‌بینی انجام شده است.

مرحله پنجم: در این مرحله، توابع محرک که در بخش سوم توضیح داده شده‌اند برای لایه‌های شبکه انتخاب می‌شوند. در لایه پنهان از تابع تانژانت سیگنویید و در لایه خروجی از تابع خطی^۲ استفاده شده است.

مرحله ششم: در این مرحله، تعداد نرون‌های لایه پنهان تعیین می‌شوند. تعداد نرون‌ها باید با دقت کافی تعیین شود تا مشکل برازش بیش از حد ایجاد نشود. اگرچه تعداد زیاد نرون‌ها در لایه مخفی باعث پایین‌آمدن خطای آموزش می‌شود، اما خطای آزمون را افزایش می‌دهد؛ بنابراین معمولاً از تعداد کم نرون‌ها شروع می‌کنند و در صورت بهبود جواب، نرون‌ها افزایش می‌یابد. در این پژوهش تعداد نرون‌ها از ۱ تا ۲۰ برای لایه پنهان اول و دوم آزمایش شده است؛ در نهایت ۱۰ نرون در لایه پنهان اول و ۸ نرون در لایه پنهان دوم در نظر گرفته شده است و با توجه به آزمون و خطاهای انجام‌شده، کمترین خطای آزمون را دارد.

مرحله هفتم: در این مرحله، دوره یادگیری برابر ۱۰۰۰ انتخاب شده است، این مقدار، خطا را

1. Bayesian Regularization Backpropagation

2. Linear

کاهش می‌دهد. میزان خطای پیش‌بینی، مجذور میانگین مربعات خطا و خطای مطلوب صفر در نظر گرفته شده است. با توجه به مراحل بالا، حدود ۲۰۰ شبکه، طراحی و هر کدام چندین بار آزمون شده‌اند؛ در نهایت شبکه عصبی پرسپترون با چهار لایه و ۱۰ نرون در لایه پنهان اول، ۸ نرون در لایه پنهان دوم، یک نرون در لایه خروجی و ۳۴ داده در لایه ورودی انتخاب شده است که خطای RMSE آن بر روی داده‌های آزمون، برابر با ۵۱/۵۲۰۶۵ و خطای MAPE برابر با ۱/۸۰۵۸۶۷ است.

تخمین با استفاده از شبکه عصبی GMDH. هدف از طراحی شبکه عصبی GMDH، جلوگیری از رشد واگرایی شبکه و مرتبط کردن شکل و ساختار شبکه‌ای به یک یا چند پارامتر عددی است؛ به گونه‌ای که با تغییر این پارامتر، ساختار شبکه‌ها نیز تغییر کند. ورودی‌ها در دو دسته داده‌های آموزش (شامل ۹۰ درصد داده‌ها) و آزمون (شامل ۱۰ درصد داده‌ها)، تقسیم شده‌اند. نتایج حاصل از شبکه GMDH بر روی داده‌های آزمون، به شرح جدول ۸، است.

جدول ۸. نتایج تخمین الگو از طریق الگوریتم GMDH

مدل	تعداد نرون	تعداد لایه	RMSE
۱	۵۰	۵	۹۵/۸۵۰۴
۲	۵۰	۱۰	۷۵/۰۹۶
۳	۵۰	۲۰	۶۴/۹۷۶۸
۴	۵۰	۲۵	۷۴/۵۵۵۷
۵	۱۰۰	۵	۸۸/۷۱۲۱
۶	۱۰۰	۱۰	۶۰/۷۵۹۳
۷	۱۰۰	۲۰	۵۵/۳۶۵۷
۸	۲۰۰	۱۰	۴۹/۱۳۲۷
۹	۲۰۰	۲۰	۷۱/۵۳۲۲

با توجه به نتایج ارائه‌شده در جدول ۸، مدل ۸ با ۱۰ لایه و ۲۰۰ نرون، بهترین مدل است و خروجی‌های آخرین مرحله ۲۱ متغیر هستند که عبارت‌اند از: ذخایر ارز خارجی چین؛ نرخ بهره فدرال رزرو؛ شاخص قیمت مصرف‌کننده آمریکا؛ تولید صنعتی آمریکا؛ شاخص خدمات مدیران بخش خرید آمریکا؛ نرخ تورم آمریکا؛ بخش غیرکشاورزی آمریکا؛ میزان پرداخت به شغل‌های غیرکشاورزی در آمریکا؛ شاخص قیمت مصرف‌کننده اتحادیه اروپا؛ تولید ناخالص داخلی اروپا؛ شاخص قیمت تولیدکننده اروپا؛ نسبت یورو به دلار؛ نسبت یوان به دلار؛ نسبت روپیه هند به دلار؛ تولید سرب اولیه؛ قیمت نفت؛ قیمت روی؛ قیمت طلا و ذخیره سرب بورس فلزات لندن.

مقایسه کارایی روش‌ها. در این بخش نتایج و میزان خطای روش‌های پیش‌بینی با معیارهای جذر میانگین مربعات خطا و درصد میانگین مطلق خطا مقایسه می‌شود تا در نهایت بهترین روش برای پیش‌بینی انتخاب شود. برای این منظور نتایج نهایی مدل‌ها در جدول‌های ۹ و ۱۰، نشان داده شده است.

جدول ۹. مقایسه میزان خطای روش‌های رویکرد تکنیکال

	MAPE	RMSE
ARIMA(۳,۱,۳)	۲/۱۴۷۹۵۶	۵۵/۹۸۰۰۵
MLP+GA	۲/۲۹۹۳۵۳	۵۸/۷۳۱۵۱
GMDH+GA	۱/۴۹۷۶۷	۳۱/۸۵۳۹

جدول ۱۰. مقایسه میزان خطای روش‌های رویکرد بنیادی

	MAPE	RMSE
SLS	۱/۴۴۳۲۹۷	۳۱/۶۰۳۴۸
MLP	۱/۸۰۵۸۶۷	۵۱/۵۲۰۶۵
GMDH	۱/۷۹۲۳۵۴	۴۹/۱۳۲۷

با توجه به نتایج جدول‌های ۸ و ۹، خطای پیش‌بینی در روش GMDH در مجموعه روش‌های رویکرد تکنیکال به مراتب کمتر از سایر روش‌ها است؛ به طوری که خطا با معیار RMSE، ۳۱/۸۵۳۹ و با معیار MAPE، ۱/۴۹۷۶۷ است؛ در نتیجه بر طبق این معیارها کارایی و دقت روش GMDH سری زمانی در پیش‌بینی بیشتر است. در مدل‌های رویکرد بنیادی نیز روش SLS کمترین خطا را دارد. در مقایسه روش‌های رویکرد تکنیکال با روش‌های رویکرد بنیادی، رویکردهای بنیادی با توجه به اطلاعات بیشتری که در فرایند پیش‌بینی قیمت استفاده می‌کنند، نسبت به رویکرد تکنیکال ارجحیت دارند؛ ضمن اینکه این روش‌ها قابلیت تفسیر و تحلیل نحوه تأثیر متغیرها را امکان‌پذیر می‌کنند.

۵. نتیجه‌گیری و پیشنهادها

در این پژوهش قابلیت پیش‌بینی‌پذیری قیمت سرب در بازار فلزات لندن با دو رویکرد تکنیکال و بنیادی و با مجموعه‌ای از روش‌های خطی و غیرخطی در هر رویکرد، بررسی شده است. قابلیت پیش‌بینی در بازار سرب به معنای پیروی نکردن قیمت از گام تصادفی است و به معنای عدم کارایی در بازار سرب خواهد بود. بررسی کارایی بازار سرب نشان داد که این بازار در سطح ضعیف کارا نیست و سری زمانی قیمت از گام تصادفی پیروی نمی‌کند؛ بنابراین تغییرات

قیمت پیش‌بینی‌پذیر هستند. در ادامه تلاش شد بهترین مدل پیش‌بینی در دو رویکرد تکنیکال و بنیادی شناسایی شود. در رویکرد تکنیکال، مدل‌های سری زمانی شبکه عصبی GMDH ترکیب‌شده با الگوریتم ژنتیک دارای خطای کمتری بودند. در رویکرد بنیادی نیز روش رگرسیون جزءبه‌جزء عملکرد خارج از نمونه بهتری نسبت به سایر روش‌های پیش‌بینی داشت. نتایج نشان می‌دهد که روش‌های استفاده‌شده در رویکرد بنیادی برای پیش‌بینی‌های بلندمدت بهتر هستند؛ زیرا علاوه بر تغییرات قیمت‌های گذشته، سایر عوامل تأثیرگذار بر قیمت را در نظر می‌گیرند. در مجموعه روش‌های غیرخطی بررسی‌شده، عملکرد پیش‌بینی شبکه عصبی GMDH نسبت به سایر روش‌ها بهتر است؛ زیرا در این روش متغیرهایی استخراج می‌شوند که بیشترین تأثیر را بر پیش‌بینی دارند و از این نظر دارای اهمیت ویژه‌ای است.

پیشنهاد می‌شود، روش‌های ارائه‌شده در این پژوهش برای پیش‌بینی قیمت سهام یا فلزات دیگر در کنار سایر الگوهای متداول سنتی استفاده شود. بررسی کارایی بازار فلزات در سطح نیمه‌قوی و با در نظر گرفتن مدل‌هایی برای تعیین نرخ بازده سرمایه‌گذار در این بازارها، موضوع مناسبی برای پژوهش‌های آتی است. سؤال مشخصی که مطرح می‌شود این است که آیا سرمایه‌گذاران می‌توانند از پیش‌بینی‌پذیری قیمت برای طراحی استراتژی‌های سرمایه‌گذاری سودآور استفاده کنند؟ در بخش روش‌های پیش‌بینی، پژوهشگران می‌توانند در مطالعات آتی از شبکه عصبی فازی برای بهبود نتایج استفاده کنند؛ زیرا با توجه به پژوهش‌های انجام‌شده در این زمینه، روش‌های ترکیبی دقت بالاتری در پیش‌بینی دارند. سیستم استنتاج تطبیقی عصبی - فازی از الگوریتم‌های شبکه عصبی و منطق فازی به‌منظور طراحی نگاشت غیرخطی بین فضای ورودی و خروجی استفاده می‌کند. این سیستم از قدرت زبانی سیستم فازی با قدرت عددی یک شبکه عصبی در مدلسازی فرآیندهای پیچیده بسیار قدرتمند است؛ همچنین پیشنهاد می‌شود که مقایسه کارایی روش‌های غیرخطی پیش‌بینی در زمانی که متغیر سطح قیمت (به‌عنوان یک متغیر نامانا) و متغیر تغییر قیمت یا بازده (به‌عنوان یک متغیر مانا) به‌کار می‌روند، در یک پژوهش مستقل بررسی شود.

منابع

1. Abbaspour, M. (2002). Iran Khodro Stock Price Prediction using Neural Network, *Tehran University of Technology*, Faculty of Engineering, Shahid Beheshti University (in Persian).
2. Andonie, R. (2010). Extreme Data Mining: Inference from small Datasets. *International Journal of Computers Communication & Control*, 5, 280-291.
3. Atsalakis, G. S. (2016). Using computational intelligence to forecast carbon prices. *Applied Soft Computing*, 43, 107-116.
4. Azadeh A., Moghaddam, M., Khakzad, M., & Ebrahimipour, V. (2012). A flexible neural network-fuzzy mathematical programming algorithm for improvement of oil price estimation and forecasting. *Computers & Industrial Engineering*, 62(2), 421-430.
5. Demuth, H. B., Beale, M. H., De Jess, O., & Hagan, M. T. (2014). *Neural network design*. Martin Hagan.
6. Eberhart, R. C., & Kennedy, J. (1995). A new optimizer using particle swarm theory. In *Proceedings of the sixth international symposium on micro machine and human science*, 1, 39-43.
7. Fakhraei, H. (2007). Comparison of water demand forecasting using structural patterns, time series and, neural networks. *Master's thesis, Faculty of Economics, University of Tehran* (In Persian).
8. Fama, E. F. (1970). Efficient Capital Market: A Review of Theory and Empirical Work. *The Journal of Finance*, 25(2), 383-417.
9. Fan, X., Wang, L., & Li, S. (2016). Predicting chaotic coal prices using a multi-layer perceptron network model. *Resources Policy*, 50, 86-92.
10. Farlow, S. J. (1981). The GMDH algorithm of Ivakhnenko. *The American Statistician*, 35(4), 210-215.
11. Fathabadi, Zahra and Basiri, Mohammad Hossein (2012). Copper price forecasting using the neural network, *the first conference of Iranian Mining Technologies* (in Persian).
12. Hejazi, S. H., & Saberi Ghamarposhti, M. (2016). Prediction Bahar Azadi full bodied gold coin price with neural network GMDH model, *The First International Conference on the New Paradigms of Business Intelligence and Organizational Management*, Tehran, Shahid Beheshti University (in Persian).
13. JahanKhani, A., & Parsaiyan, A. (1996). *Tehran Stock Exchange*. Tehran: Tehran University Press Faculty Publishing (In Persian).
14. Jones, C. P. (1996). *Investment Analysis and Management*, 4th Edition, John Willey and Sons. Inc, New York.
15. Kasabov, N. K. (1996). *Foundations of neural networks, fuzzy systems, and knowledge engineering*. Marcel Alencar.
16. Ljung, G. M. & Box, G. E. P. (1978). On a Measure of Lack of Fit in Time Series Models. *Biometrika*, 65(2): 297-303.
17. Manavi, S. E., & Karimi, A. (2014). A New Approach in Data Mining to Forecasting metals Prices Based on Firefly Algorithm and Neural Network. *National Conference on Computer Engineering Research* (In Persian).
18. Mansourfar, Karim. (2006). *Statistical Progress with Computer Programs*.

Tehran, University of Tehran: 173 (in Persian).

19. Moeini, A., Abrishami, H., & Ahrari M. (2015). *GMDH Neural Network Application in Energy Economics*. Azar Barzzin, First Printing, Tehran (In Persian).

20. Monfared, Soheil Almasi, and David Enke. (2014). Volatility Forecasting Using a Hybrid GJR-GARCH Neural Network Model, *Procedia Computer Science*, 36, 246-253.

21. Morovvati Sharifabadi, A., & Khanche mehr, R. (2014). Find the most suitable artificial neural network structure using the Taguchi experiments design method. *Journal of Industrial Management Perspective*, 13: 121-142 (In Persian).

22. Murphy, J. J. (1999). *Technical analysis of the financial markets: A comprehensive guide to trading methods and applications*. New York: Institute of Finance.

23. Nazari, M., Tabatabaei Kaljahi, S. V., & Ahrari, M. (2013). Comparison of three methods of estimating the price of a computer in the Tehran market: pleasure regression (hedonic), Recursive neural network and GMDH neural network. *Journal of Business Management Perspective*, 13, 45-60 (In Persian)

24. Okanel baverman (2008). *Time series prediction*". Translation by Reza Shiva. Tehran: Institute of Business Studies and Research (in Persian).

25. Parchami, B., Nematzadeh, H., & Shahverdi, R. (2016). Prediction of stock return based on financial variables with the approach of neural networks, *International Conference on Computer Engineering and Information Technology*, Tehran, Permanent Secretariat of the Conference (In Persian).

26. Sadeghi, H., Sohrabi Vafa, H. & Noori, F. (2013). Applications of Neural Network Based on Genetic Algorithm for Long Term Energy Demand Forecasting. *Journal of Applied Theories of Economics*, 1(2), 29-52 (In Persian).

27. Shohadaei, M. A. (2007). *Fundamental Analysis in the Capital Market*. Tehran: Chalesh Publications (In Persian).

28. Thaghafi Kolvanegh, R. (2009). Evaluating the Effectiveness of Using Technical Analysis Patterns in Tehran Stock Exchange. *Master's thesis*. University of Esfahan. School of Administrative Sciences and Economics (In Persian).

29. ZivariPaydar, S., & Saberi Kamarposhti, M. (2016). Influence of Inflation and Steel Rate Changes on Vehicle stock Market Changes Using the GMDH Model Artificial Neural Networks, *The First International Conference on the New Paradigms of Business and Organizational Management*, Tehran, Shahid Beheshti University (In Persian).