فصلنامه مهندسی مالی و مدیریت اوراق بهادار
شماره پنجاه و سه / زمستان ۱۴۰۱
نوع مقاله : علمی پژوهشی
صفحات : ۱۳۳-۱۰۹

بهینه سازی بر روی شبکه ماشین یادگیری حداکثری (ELM) با استفاده از دو روش بهینه‌سازی ماشین یادگیری حداکثری پی‌درپی(OSELM) و الگوریتم پرواز پرندگان (ازدحام ذرات (PSO)) برای پیش‌بینی شاخص صنعت در بورس اوراق بهادار تهران

بنیامین حکیم‌زاده[۱]
احسان طیبی‌ثانی[۲]
مهدی سعیدی‌کوشا[۳]

تاریخ دریافت مقاله : ۱۴۰۰/۱۱/۲۷ تاریخ پذیرش مقاله : ۱۴۰۰/۱۲/۱۵

چکیده

همواره برای پیش‌بینی در بازارهای مالی دو رویکرد سنتی و هوشمند وجود داشته که در روش سنتی این پیش‌بینی بر اساس مدل‌های آماری و در روش هوشمند بر اساس مدل‌های هوش مصنوعی است. روش‌های سنتی عمدتاً از الگوهای خطی برای مدل کردن رفتار بازار استفاده می‌کنند در حالی که مزیت و برتری اصلی مدل‌های هوشمند توانایی یادگیری و مدل کردن رفتارهای غیرخطی موجود در بازار است. همیشه این موضوع مطرح بوده است که کدام روش‌ها می‌توانند رفتار بازار را بهتر مدل کنند. هدف از این پژوهش ارائه مدلی هوشمند برای پیش‌بینی شاخص صنعت در بورس اوراق بهادار تهران می‌باشد. این کار توسط شبکه عصبی ماشین یادگیری حداکثری[۱] و با استفاده از دو روش بهینه‌سازی ماشین یادگیری حداکثری پی‌درپی[۲] و الگوریتم پرواز پرندگان(ازدحام ذرات[۳]) صورت گرفته است. نتایج نشان می‌دهد که دقت پیش‌بینی این دو روش از لحاظ آماری تفاوت معناداری با یکدیگر نداشته اما ازلحاظ مدت‌زمان اجرای الگوریتم شبکه عصبی با روش بهینه‌سازی ماشین یادگیری حداکثری پی‌درپی بسیار بهتر و سریع‌تر عمل کرده است.

کلمات کلیدی

ماشین یادگیری حداکثری، الگوریتم پرواز پرندگان (ازدحام ذرات)، شاخص صنعت

۱-گروه مدیریت مالی، دانشکده علوم مالی، دانشگاه خوارزمی، تهران، ایران. be.hakimzadeh@gmail.com
۲-گروه مدیریت مالی، دانشکده علوم مالی، دانشگاه خوارزمی، تهران، ایران. (نویسنده مسئول) Ehsan_taieby_sani@khu.ac.ir
۳-گروه مدیریت مالی، دانشکده علوم مالی، دانشگاه خوارزمی، تهران، ایران. m.saeidi@khu.ac.ir

مقدمه

به دلیل اهمیت و جایگاه ویژه بازارهای مالی و تأثیری که بر بازارهای موازی می‌گذارد که نشان‌دهنده نقش پررنگ آن در اقتصاد هر کشور است، پیش‌بینی در این حوزه از اهمیت خاصی برخوردار است و به بخش جدایی‌ناپذیر و پراهمیتی در این حوزه تبدیل‌شده است(بیگی، ۱۳۹۸). هر چه میزان دقت این پیش‌بینی بیشتر باشد و خطای کمتری داشته باشد باعث اعتماد بیشتر سرمایه‌گذاران می‌شود زیرا از این طریق می‌توانند ریسک خود را به حداقل برسانند. به منظور بالا بردن دقت پیش‌بینی می‌توان عوامل مهم تأثیرگذار بر بازارهای مالی را شناسایی و به کمک آن‌ها خطاهای پیش‌بینی را کمتر کرد (بیک و کیم[۴]، ۲۰۱۸). در این پژوهش با کمک تعدادی از متغیرهای کلان اقتصادی این کار انجام می‌شود.

بازار بورس امروزه یکی از پرتراکنش‌ترین و جذاب‌ترین بازارها در تمام جهان است؛ که می‌تواند نمایانگر کیفیت یا سطح اقتصاد ملی هر کشور باشد، چراکه تمامی شاخص‌های کلان و خرد اقتصادی، سیاسی، اجتماعی، مالی و ... دست‌به‌دست هم داده‌اند و بازار بورس را متأثر از خود به‌پیش می‌برند. بازار سهام در اقتصاد نقش مهم و بسزایی دارد و یکی از مهم‌ترین عوامل نشان‌دهنده توسعه اقتصادی و رشد فنّاوری مدرن است، همچنین می‌تواند میزان رشد یا عقب‌ماندگی اقتصاد هر کشور را به نمایش بگذارد که دراین‌بین، شاخص قیمت سهام می‌تواند به‌عنوان نماد و تابلوی بازار بورس، وضعیت بازار بورس را به نمایش بگذارد. در همین راستا، بررسی تأثیر متغیرهای کلان اقتصادی بر شاخص سهام و پیش‌بینی روند آینده بازار سهام با استفاده از داده‌های تاریخی بازار سهام یکی از موضوعات مهم دانشگاهیان و سرمایه‌گذاران است (رخا داس و همکاران[۵]، ۲۰۱۹). به‌نحوی‌که تعامل بین قیمت سهام و متغیرهای کلان اقتصادی، مقدار زیادی از علایق تحقیقاتی را به‌عنوان نتیجه‌ای از افزایش چشمگیر در تجارت جهانی و جنبش سرمایه جذب می‌کند (وی و همکاران[۶]،۲۰۱۹).

از طرفی نیز، عدم اطمینان در روند شاخص‌های اقتصادی و نبود اطمینان و شفافیت لازم در بورس اوراق بهادار باعث شده تا تغییرات قیمت سهام باوجود اهمیت بسیار زیاد به‌راحتی قابل پیش‌بینی نباشد؛ بنابراین پیش‌بینی ارزش آینده بازار سهام برای سرمایه‌گذاران بسیار مهم است زیرا دانستن روند بازار سهام ریسک سرمایه‌گذاری را کاهش داده و اعتماد را بین سرمایه‌گذاران گسترش می‌دهد. دانستن حرکات آینده به دلیل ماهیت بسیار نوسانی آن‌یک مسئله چالش‌برانگیز است، ازاین‌رو، روش‌های مناسب محاسباتی برای پیش‌بینی حرکت قیمت سهام لازم است(بیک و کیم، ۲۰۱۸).

هدف این پژوهش ارائه یک مدل پیش‌بینی شاخص صنعت با استفاده از بهینه‌سازی شبکه عصبی

ماشین یادگیری حداکثری از طریق روش بهینه سازی ازدحام ذرات، به منظور بهبود و کاهش خطای پیش‌بینی شاخص با استفاده از هوش مصنوعی است.

مبانی نظری پژوهش

زمانی که حرف از بازار مالی می‌شود، بیشتر افراد ذهنشان به سمت بورس اوراق بهادار متمایل می‌شود. اولین و مهم‌ترین عامل که سرمایه‌گذاران جهت سرمایه‌گذاری در بورس اوراق بهادار مدنظر قرار می‌دهند، شاخص قیمت سهام است. از این رو آگاهی از عوامل مؤثر بر شاخص قیمت سهام با اهمیت است. عوامل متعددی وجود دارند که می‌توانند شاخص را تحت تأثیر قرار دهند و همچنین تغییر در قیمت هریک از دارایی‌ها می‌تواند بر سایر دارایی‌ها نیز تأثیر بگذارد. به‌عنوان‌مثال افزایش سطح نقدینگی و چاپ پول می‌تواند موجب تورم شده و نرخ ارز را تحت تأثیر قرار دهد، با افزایش نرخ ارز بازار سهام، طلا و مسکن نیز تحت تأثیر قرار می‌گیرند. عوامل مؤثر بر قیمت سهام گاهی داخلی و گاهی نیز ناشی از تغییر در متغیرهای بیرونی مؤثر بر اقتصاد است. بر این اساس، عوامل مؤثر بر قیمت سهام به عوامل داخلی و عوامل بیرونی طبقه‌بندی می‌شود (پاکدین امیری و همکاران، ۱۳۸۷). عوامل داخلی که قیمت سهام را تحت تأثیر قرار می‌دهد در ارتباط با عملیات و تصمیمات شرکت است این عوامل شامل عایدی هر سهم، افزایش سرمایه و دیگر عواملی است که درون شرکت اتفاق می‌افتد. عوامل بیرونی، عواملی است که تحت اختیار مدیریت شرکت نیست و به نحوی فعالیت شرکت را تحت تأثیر قرار می‌دهند.

یکی از دغدغه‌های مهم بسیاری از اقتصاددانان در دهه‌های اخیر بررسی تأثیر تکانه‌های نفتی بر اقتصاد داخلی کشورهای صادرکننده آن به‌ویژه کشورهای درحال‌توسعه بوده است. تأثیر قیمت نفت بر بازار سهام بسته به این‌که کشور صادرکننده نفت باشد یا واردکننده آن، متفاوت است؛ بنابراین کانال‌های اثرگذاری آن نیز برای هر کشوری متفاوت خواهد بود. در کشورهای صادرکننده نفت، افزایش قیمت جهانی نفت تراز تجاری را بهبود بخشیده، باعث افزایش مازاد حساب‌جاری و بهبود وضعیت خالص دارایی‌های (سرمایه‌های) خارجی می‌شود و این اتفاق سودآوری شرکت‌ها را بهبود می‌بخشد و همچنین تقاضای داخلی و قیمت سهام را افزایش می‌دهد. در کشورهای واردکننده نفت، فرآیند کلی در جهت معکوس کار می‌کند یعنی دچار کسری تجاری می‌شود و در طول زمان، ارزش پول کشور تضعیف شده و قیمت سهام کاهش می‌یابد(عباسی نژاد و همکاران،۱۳۹۲).

بعنوان آخرین عامل بیرونی می توان از حجم پول به‌عنوان یک متغیر کلان اقتصادی می‌تواند در بازار پول تأثیرات مهمی بر روی نرخ بهره و سطح عمومی قیمت‌ها داشته باشد اما با توجه به اینکه در ایران در عمل نرخ بهره وجود ندارد و نرخ سود نیز توسط بانک مرکزی تعیین می‌شود می‌توان تنها

تغییرات در سطح عمومی قیمت‌ها را در نظر گرفت. به‌عنوان‌مثال درصورتی‌که دولت دچار کسری بودجه شده باشد، مجبور به چاپ پول و تزریق نقدینگی در جامعه می‌شود که می‌تواند اثر منفی بر قیمت سهام داشته باشد. افزایش حجم نقدینگی در ایران ازنظر بسیاری از متخصصان علم اقتصاد حداقل ازلحاظ روانی آثار منفی بر بازار سهام دارد (اسلاملوییان و زارع، ۱۳۸۵).

شبکه عصبی مصنوعی

یک شبکه عصبی مصنوعی ایده‌ای برای پردازش اطلاعات است که از سیستم عصبی زیستی الهام گرفته و مانند مغز به پردازش اطلاعات می‌پردازد. عنصر کلیدی این ایده، ساختار جدید سیستم پردازش اطلاعات است. این سیستم از شمار زیادی عناصر پردازشی فوق‌العاده به‌هم‌پیوسته به نام نورون‌ها تشکیل شده که برای حل یک مسئله باهم هماهنگ عمل می‌کنند. شبکه‌های عصبی مصنوعی نیز مانند انسان‌ها با مثال یاد می‌گیرند و یک شبکه عصبی برای انجام وظیفه‌های مشخص مانند شناسایی الگوها و دسته‌بندی اطلاعات، در طول یک پروسه یادگیری تنظیم می‌شود. در سیستم‌های زیستی، یادگیری با تنظیماتی در اتصالات سیناپسی که بین اعصاب قرار دارد همراه است. از این روش در شبکه‌های عصبی نیز استفاده می‌شود. شبکه‌های عصبی مصنوعی با پردازش داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کند که به این عمل یادگیری می‌گویند. اصولاً توانایی یادگیری مهم‌ترین ویژگی یک سیستم هوشمند است. سیستمی که قابلیت یادگیری داشته باشد، منعطف‌تر است و ساده‌تر برنامه‌ریزی می‌شود، بنابراین بهتر می‌تواند در مورد مسائل و معادلات جدید پاسخگو باشد (جورابیان، ۱۳۸۶).

ساختار غیرخطی شبکه عصبی برای یافتن ارتباط بین اتفاقات و رخدادهای واقعی جهان استفاده می‌شود. شبکه‌ی عصبی جزء روش‌های چندبعدی به‌منظور پیش‌بینی می‌باشند که تنها چهارچوب غیرمالی رویدادها را در نظر نمی‌گیرد بلکه فرآیندهای خطی را نیز در نظر می‌گیرد. برای مثال شبکه‌های عصبی این توانایی رادارند تا برای مدل کردن سری زمانی خطی مورداستفاده قرار بگیرند که درواقع مطلب فوق را تأیید می‌کند (مقار و همیچه[۷]، ۲۰۲۰).

ساختار شبکه عصبی

شبکه‌ی عصبی یک سامانه پردازش داده‌ها است که از مغز انسان ایده گرفته و پردازش داده‌ها را به عهده پردازنده‌های کوچک و بسیار زیادی می‌سپارد که به‌صورت شبکه‌ای به‌هم‌پیوسته و موازی با یکدیگر برای حل یک مسئله رفتار می‌کنند. در این شبکه‌ها به کمک دانش برنامه‌نویسی، ساختار داده‌ای طراحی

می‌شود که می‌تواند همانند نورون عمل کند که به آن ساختار داده گره گفته می‌شود. در این ساختار با ایجاد شبکه‌ای بین این گره‌ها و اعمال یک الگوریتم آموزشی به آن، شبکه را آموزش می‌دهند. در این حافظه یا شبکه عصبی گره‌ها دارای دو حالت فعال و غیرفعال‌اند و هر یال دارای یک وزن است. یال‌های با وزن مثبت، موجب تحریک یا فعال کردن گره غیرفعال بعدی می‌شوند و یال‌های با وزن منفی، گره متصل بعدی را غیرفعال می‌کنند (رمضانیان و همکاران،۱۳۹۸).

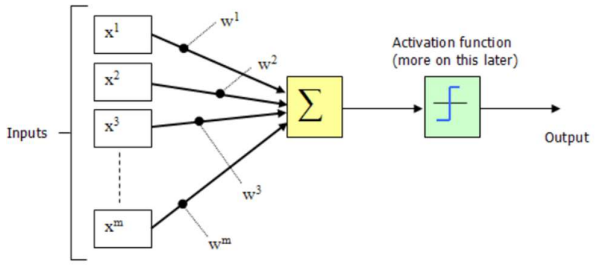

شکل ۱: ساختار شبکه عصبی

اطلاعات از طریق ورودی یا همان دندریت وارد نورون می‌شوند که با مقادیر $(x_1,\ldots\ldots,x_m)$ در تصویر قابل‌مشاهده هستند. در مدل شبکه عصبی مصنوعی به هر ورودی یک وزن $(w_1,\ldots\ldots,w_m)$ اختصاص می‌دهیم. این وزن‌ها درواقع اهمیت ورودی‌ها برای ما هستند، یعنی هر چه وزن بیشتر باشد، ورودی برای آموزش شبکه مهم‌تر است. سپس تمامی ورودی‌ها باهم جمع (Σ) شده و به‌صورت یک‌لایه به آکسون وارد می‌شوند. در مرحله بعد تابع فعالیت[۸] را بر روی داده‌ها اعمال می‌کنیم. پس‌ازآنجام محاسبات در این مرحله اطلاعات ما از طریق سیناپس‌های خروجی وارد نورون دیگر می‌شوند و این مرحله تا جایی ادامه پیدا می‌کند که به لایه خروجی برسیم (رمضانیان و همکاران،۱۳۹۸).

یادگیری در شبکه‌های عصبی

شبکه‌های عصبی این توانایی رادارند که سیگنال‌های ورودی را طبق طراحی که انجام می‌دهند پردازش کرده و به سیگنال‌های خروجی موردنظر تبدیل کنند. معمولاً پس از طراحی و پیاده‌سازی شبکه عصبی، تنظیم سیگنال‌های ورودی باید به‌گونه‌ای باشد که سیگنال‌های خروجی بتوانند شبکه خروجی موردنظر را به وجود بیاورند. مجموعه این اتفاقات آموزش شبکه عصبی می‌گویند. می‌توان گفت آموزش فرآیندی است که نتیجه آن یافتن بهترین وزن‌ها برای ورودی هر سلول شبکه عصبی است. درواقع آموزش به دنبال این موضوع است که وزن‌هایی را برای سلول‌های ورودی شبکه عصبی انتخاب نماید که خروجی به‌دست‌آمده کمترین خطا را نسبت به حالت مطلوب داشته باشد.

درمراحل‌ابتدایی آموزش، مقادیر را به‌صورت تصادفی انتخاب می‌کنیم. در طول مدت‌زمان انجام فرآیند آموزش‌توسط شبکه عصبی، پارامترهابه مقدارواقعی‌شان نزدیک‌تر می‌شوند. درمجموع می‌توان از دو روش با ناظر و بدون ناظر برای آموزش دادن به شبکه‌های عصبی استفاده کرد (اندرسون و همکاران[۹]، ۱۹۹۲).

ماشین یادگیری حداکثری[۱۰]

ایراد اساسی شبکه عصبی پرسپترون بالا بودن مدت‌زمان آموزش است زیرا در این شبکه پارامترهای زیادی باید در پروسه آموزش تنظیم شوند و همین باعث می‌شود که زمان آموزش بسیار بالا باشد. شبکه عصبی ELM یک رویکرد بسیار ساده‌ای برای حل این مسئله ارائه کرده است و به همین دلیل سرعت یادگیری بسیار بالایی دارد. در این شبکه لایه ورودی با یک سری وزن به لایه پنهان وصل شده است، البته خوبی ماجرا اینجا هست که در این شبکه به وزن‌ها یک مقدار تصادفی در همان ابتدا اختصاص می‌دهند و نیازی نیست در طول آموزش تنظیم شوند. نورون‌های لایه پنهان یک نورون معمولی هستند و نیازی به پیدا کردن مراکز و سیگمای هر نورون نیست و درنهایت تنها پارامتر قابل تنظیم این شبکه وزن‌های سیناپسی بین لایه پنهان و لایه خروجی است. یک شبکه روبه‌جلو هست و با استفاده از روش شبه معکوس وزن‌های سیناپسی را در یک‌لحظه محاسبه می‌کند و همین امر باعث شده سرعت یادگیری این شبکه بسیار بالا باشد (دینگ[۱۱]،۲۰۱۴).

مکانیسم تست

مکانیسم تست اطلاعات را از ساختار شبکه عصبی بازیابی می‌کند. ساختار شبکه عصبی، نقش حافظه-ای را دارد که توسط مکانیسم آموزش پر می‌شود و سپس توسط مکانیسم تست از اطلاعات ذخیره‌شده بهره‌برداری صورت می‌گیرد. مکانیسم تست اطلاعاتی را که مکانیسم آموزش با الگوریتم استخراج کرده، استفاده می‌نماید و جوابی متناسب با هر سؤال ارائه می‌دهد. کارایی یک شبکه عصبی با فراخوانی آن در فاز تست تعیین می‌شود، درواقع شبکه عصبی سؤالات کاربران را در فاز تست دریافت می‌کند. به این نمونه‌ها، نمونه تست الگوی فراخوانی می‌گویند. نمونه تست یا الگویی فراخوانی، فاقد خروجی هستند و شبکه عصبی باید خروجی این نمونه‌ها را تخمین بزند. مکانیسم تست یا مکانیسم فراخوانی شبکه عصبی، خروجی نمونه‌های تست را با استفاده از نگاشت به‌دست‌آمده در فاز آموزش تخمین می‌زند. هر چه پاسخ شبکه عصبی برای نمونه‌های تست به پاسخ واقعی نزدیک‌تر باشد نشان‌دهنده این است که نگاشت تشکیل‌شده به‌وسیله شبکه عصبی به نگاشت سیستم مسئله نزدیک‌تر است (مقار[۱۲]،۲۰۲۰).

بهینه‌سازی ماشین یادگیری حداکثری OSELM

یک روش بهینه‌سازی که تنها بر روی ساختار ماشین یادگیری حداکثری(ELM) قابلیت اجرا دارد و از تصویرسازی داده‌های ورودی بر روی فضای خروجی برای یافتن وزن‌های بهینه در لایه پنهان استفاده می‌کند که این کار را به کمک یک ماتریس کمکی انجام می‌دهد که در روش تحقیق به آن‌ها خواهیم پرداخت. ماشین یادگیری حداکثری(OSELM) قابلیت اجرا روی سیستم‌هایی که به‌صورت آنلاین عمل می‌کنند را دارا است و مشکل طولانی بودن زمان یادگیری شبکه‌های عصبی معمولی را ندارد (رخا داس و همکاران[۱۳]،۲۰۱۹).

الگوریتم‌های فرا ابتکاری

الگوریتم‌های فرا ابتکاری نوعی از الگوریتم‌های تصادفی هستند که برای یافتن پاسخ بهینه به کار می روند. الگوریتم‌های بهینه‌سازی به دودسته الگوریتم‌های دقیق و الگوریتم‌های تقریبی تقسیم‌بندی می‌شوند. الگوریتم‌های دقیق قادر به یافتن جواب بهینه به‌صورت دقیق هستند اما در مورد مسائل بهینه‌سازی سخت کارایی کافی را ندارند و زمان اجرای آن‌ها متناسب با ابعاد مسائل به‌صورت نمایی افزایش می‌یابد. الگوریتم‌های تقریبی قادر به یافتن جواب‌های خوب (نزدیک به بهینه) در زمان کوتاه برای حل مسائل بهینه‌سازی سخت هستند. الگوریتم‌های تقریبی نیز به سه دسته الگوریتم‌های ابتکاری[۱۴] و فرا ابتکاری[۱۵]و فوق ابتکاری [۱۶] تقسیم‌بندی می‌شوند (ژانگ[۱۷] و همکاران، ۲۰۰۷).

الگوریتم ازدحام ذرات

روش بهینه‌سازی ازدحام ذرات یک روش سراسری کمینه‌سازی جستجوی جمعی است که از روی رفتار اجتماعی دسته‌های پرندگان مدل شده است و با استفاده از آن می‌توان با مسائلی که جواب آن‌ها یک نقطه یا سطح در فضای n بعدی است، برخورد نمود. در چنین فضایی فرضیاتی مطرح می‌شود و یک سرعت ابتدایی به آن‌ها اختصاص داده می‌شود و کانال‌های ارتباطی بین ذرات در نظر گرفته می‌شود. سپس این ذرات در فضای پاسخ حرکت می‌کنند و نتایج حاصله بر مبنای یک ملاک شایستگی پس از هر بازه زمانی محاسبه می‌شود. باگذشت زمان ذرات به سمت ذراتی که دارای ملاک شایستگی بالاتری هستند حرکت می‌کنند. درواقع ذرات از همدیگر می‌آموزند و بر مبنای دانش به‌دست‌آمده به سمت بهترین همسایگان خود می‌روند (ژانگ و همکاران[۱۸] ، ۲۰۰۷).

در این الگوریتم هر پرنده با به اشتراک گذاشتن بهترین موقعیت خود و با در نظر گرفتن بهترین موقعیت دیگر ذرات به حرکت خود ادامه می‌دهد و به دلیل ارتباط تمامی ذرات با یکدیگر و تبادل

اطلاعات، سرعت همگرایی بالا است. مهم‌ترین ویژگی که به این اتفاق کمک می‌کند، حافظه‌دار بودن پرندگان است که باعث می‌شود بهترین موقعیت همه ذرات را ذخیره کنند و درحرکت‌های بعدی از آن استفاده کنند. البته گاهی ممکن است که پرندگان در بهینه‌های محلی گیر بیفتند و در فرآیندهای بعدی مورداستفاده قرار نگیرند پرندگان در هر مرحله برای حرکت از سه متغیر سرعت، بهترین موقعیت خود پرنده و بهترین موقعیت سایر پرندگان تأثیر می‌پذیرند(اشهر،۱۳۸۹).

مطالعات تجربی

ابراهیمی و شکری (۱۳۹۰) در مطالعه خود به بررسی تأثیر متغیرهای کلان اقتصادی بر قیمت سهام با تأکید بر نقش سیاست پولی با استفاده از مدل تصحیح خطای برداری ساختاری[۱۹] پرداخته‌اند. این پژوهش با استفاده از داده‌های ماهانه و بین سال‌های ۱۳۸۷-۱۳۷۸ صورت پذیرفته است. متغیرهای مستقل شامل قیمت نفت، تولید ناخالص داخلی، نرخ ارز، حجم پول، تورم و متغیر وابسته، شاخص قیمت سهام بورس اوراق بهادار تهران است. نتایج نشان می‌دهد در بلندمدت، تکانه قیمتی نفت، تولید ناخالص داخلی، نرخ ارز و حجم پول دارای اثرات مثبت بر شاخص قیمتی سهام و تکانه تورم دارای اثر منفی بر این شاخص است.

حسن‌زاده و کیانوند (۱۳۹۳) به بررسی اثرات شوک‌های نفتی بر تغییرات شاخص کل قیمت بورس اوراق بهادار در ایران پرداخته‌اند. بدین منظور از داده‌های ماهانه طی دوره زمانی فروردین ۱۳۷۰ تا دی‌ماه ۱۳۹۰ استفاده‌شده است. برای بررسی رابطه بین قیمت نفت و سهام، علاوه بر متغیرهای قیمت نفت و شاخص قیمتی سهام، نرخ ارز واقعی و حجم نقدینگی نیز به مدل اضافه‌شده است هم‌چنین از سه معیار مختلف برای مشخص کردن شوک‌های نفتی استفاده‌شده است: شوک‌های خطی، شوک‌های موزون شده و شوک‌های خالص. تحلیل آماری در قالب مدل‌های سری زمانی شامل گارچ[۲۰] و خود بازگشتی برداری[۲۱] انجام‌یافته است. طبق نتایج به‌دست‌آمده، شوک‌های نفتی اثر مثبت بر شاخص‌های سهام‌دارند یعنی با افزایش قیمت نفت، شاخص‌های سهام نیز افزایش می‌یابند. همچنین نتایج حاکی از آن است که اثر شوک‌های پولی بیشتر از شوک‌های نفتی است.

تهرانی و همکاران (۱۳۹۷) در پژوهشی به ارائه یک مدل ترکیبی از شبکه عصبی و تبدیل موجک پرداخته‌اند که از الگوریتم ژنتیک برای بهینه سازی تابع پایه تبدیل موجک با هدف حداکثر نمایی کارایی این تبدیل، استفاده شده است. داده های مورداستفاده برای این پژوهش داده های روزانه از تاریخ ۱۳۹۱/۰۲/۰۲ تا تاریخ ۱۳۹۶/۰۱/۳۰ است. نتایج این پژوهش نشان داد که با این روش می توان تابع

پایه ای متناسب با ویژگی های ذاتی سری زمانی برای پیش بینی یافت که خطای پیش بینی در این مدل نسبت به مدل شبکه عصبی و مدل ترکیبی شبکه عصبی و تبدیل موجک کاهش یابد.

میرعلوی و پورزمانی(۱۳۹۸) در مدل پیشنهادی پژوهش خود یک سیستم دو سطحی از شبکه‌های عصبی پرسپترون چندلایه پیشنهاد داده اند و از چندین شاخص برای پیش‌بینی استفاده نموده‌اند. در پژوهش مذکور داده‌های شاخص قیمت بورس اوراق بهادار تهران از ۱۳۹۱ تا ۱۳۹۵ در نظر گرفته شده است. همچنین برای آموزش بهتر شبکه‌ی عصبی و در نتیجه بهبود نتایج بدست آمده، از الگوریتم بهینه‌سازی ملخ برای انتخاب بهترین نمونه‌ها استفاده شده است. نتایج بدست آمده نشان از عملکرد بهتر مدل پیشنهادی برمبنای خطای پیش‌بینی نسبت به دیگر مدل‌ها بوده است.

کومار و همکاران[۲۲](۲۰۱۶) در پژوهشی به پیش‌بینی قیمت طلا پرداختند. آن‌ها در این پژوهش با استفاده از سه روش شبکه عصبی پیشخور بدون بازخورد، شبکه عصبی پیشخور پس انتشار خطا[۲۳] و شبکه عصبی ماشین یادگیری حداکثری و با استفاده از داده‌های تاریخی قیمت طلا، قیمت نقره، قیمت نفت خام و نرخ ارز خارجی به عنوان ورودی‌های شبکه به پیش‌بینی پرداخته‌اند. نتایج بیانگر این موضوع می‌باشد که ماشین یادگیری حداکثری در مقایسه با سایر شبکه‌ها افزایش کارایی و دقت بیشتری دارد.

ژانگ و همکاران[۲۴] (۲۰۱۹)، در مطالعه‌ی خود با عنوان پیش‌بینی شاخص بازار بر اساس شبکه‌ی معماری جدیدی از شبکه‌ی مولد متقابل[۲۵] پرداختند. آن‌ها در پژوهش خود حافظه کوتاه‌مدت طولانی[۲۶] را به‌عنوان تعیین‌کننده‌ی پیش‌بینی قیمت بسته شدن سهام در نظر گرفتند. همچنین آن‌ها شبکه‌ی مولد متقابل را با چندلایه پرسپترون[۲۷] به‌عنوان تشخیص‌دهنده پیشنهاد دادند. نتایج این پژوهش نشان داد که می‌تواند در مقایسه با سایر مدل‌ها در یادگیری ماشین و یادگیری عمیق عملکرد بهتری داشته باشد.

سیدرا و همکاران[۲۸] (۲۰۲۰) در پژوهش خود اقدام به ارائه مدلی دو رگه برای برمبنای یادگیری ماشین و یادگیری عمیق برای پیش بینی شاخص نیفتی[۲۹] ۵۰ بورس هند پرداخته‌اند. داده های مربوط به شاخص مذکور را از دسامبر ۲۰۱۴ تا جولای ۲۰۲۰ مورد بررسی قرار داده‌اند. برای افزایش قدرت پیش‌بینی مدل رگرسیون پیشنهادی خود از شبکه حافظه کوتاه مدت-بلندمدت[۳۰] با روش اعتبارسنجی گام پیش‌رو[۳۱] و جستجوی شبکه‌ای[۳۲] استفاده نمودند که در نهایت نشان دادند مدل‌های بر مبنای حافظه کوتاه مدت-بلندمدت بر مبنای داده‌های هفته آخر بیشترین قدرت پیش‌بینی کنندگی را دارا است.

بر این اساس در این پژوهش سعی بر پیش‌بینی مقادیر آینده شاخص صنعت با حداقل خطا بر اساس قیمت نفت، نرخ ارز، ارزش معاملات و داده‌های شاخص صنعت، در بازار بورس تهران است که تاکنون با

رویکرد ماشین یادگیری حداکثری و استفاده از روش بهینه‌سازی ازدحام ذرات مطالعه‌ای در این خصوص صورت نگرفته است.

روش تحقیق

پژوهش حاضر از نظر هدف کاربردی و از حیث ماهیت علی_مقایسه‌ای است. در تحقیق حاضر جامعه آماری شامل کلیه شاخص‌های بورس اوراق بهادار تهران و شاخص‌های کلان اقتصادی است و نمونه آماری نیز داده‌های روزانه شاخص صنعت بورس اوراق بهادار بین سال‌های ۱۳۹۰ تا ۱۴۰۰چراکه باتوجه به حذف اثر شرکتهای واسطه گری مالی و سرمایه‌گذاری نماگری بهتری از شاخص کل می‌شد و همچنین شاخص داده‌های روزانه مربوط به نرخ ارز، شاخص قیمت نفت اوپک و شاخص ارزش معاملات بین سال‌های ۱۳۹۰ تا ۱۴۰۰ است. به‌عبارت‌دیگر محقق می‌کوشد تا اثر تغییرات نرخ ارز، قیمت نفت اوپک، ارزش معاملات و داده‌های شاخص صنعت را بر بازده شاخص صنعت بورس اوراق بهادار اندازه‌گیری نماید.

داده‌های مربوط به متغیرهای ذکر شده در دوره‌ی زمانی ۱۰ ساله، بین سال‌های ۱۳۹۰ الی ۱۴۰۰ است که به صورت روزانه گردآوری‌شده است. بعد از جمع‌آوری اطلاعات از منابع مورد نظر، تمامی داده‌ها در نرم‌افزار اکسل[۳۳] وارد شده است. استفاده از نرم‌افزار اکسل به منظور تسهیل در وارد کردن اطلاعات به ورودی‌ها در پایتون[۳۴] که به‌عنوان زبان برنامه‌نویسی مورد استفاده قرار خواهد گرفت، است. داده‌های آماری مورداستفاده در این پژوهش از اطلاعات منتشر شده توسط بانک مرکزی جمهوری اسلامی ایران و همچنین گزارشات سازمان بورس اوراق بهادار، سایت شبکه اطلاع رسانی طلا، سکه و ارز[۳۵] و شرکت بورس اوراق بهادارتهران[۳۶] گردآوری گردیده است.

مدل به کار گرفته‌شده در این پژوهش یک مدل ریاضی است که در آن از تکنیک شبکه‌های عصبی به‌عنوان عنصر تحلیلگر مدل استفاده‌شده است. اطلاعات ورودی مدل شامل، نرخ ارز، قیمت نفت، نقدینگی بازار و داده‌های گذشته‌ی شاخص صنعت مربوط به دوره زمانی ۱۳۹۰-۱۴۰۰ به‌صورت روزانه است و خروجی مدل شاخص صنعت بازار بورس است. در ابتدا و قبل از استفاده از مدل باید مدل را با اطلاعات مناسب آموزش داد. در این پژوهش مدل با استفاده از آموزش با ناظر، آموزش داده می‌شود بدین معنی که اطلاعات آموزش ورودی و خروجی هم‌زمان به مدل داده می‌شود تا مدل بتواند ارتباط بین ورودی‌ها و خروجی‌ها را کشف نماید. باید توجه کرد که هر مجموعه داده به سه بخش تقسیم می‌شود:

۱. ۲۰٪ برای مقداردهی اولیه

۲. ۷۰٪ برای آموزش شبکه عصبی

۳. ۱۰٪ باقی‌مانده نیز برای تست قابلیت تعمیم شبکه به کار می‌رود.

در بخش صنعت، شرکت‌های تولیدی و صنعتی نظیر کاشی و سرامیک، دارو، پالایشگاه و ... قرار دارند. درواقع شاخص صنعت نشان‌دهنده میانگین تغییرات قیمت سهام شرکت‌های فعال دربخش صنعت است.

ماشین یادگیری حداکثری نوعی شبکه عصبی است که تنها یک‌لایه مخفی دارد و تفاوت آن با شبکه عصبی معمولی در این است که مقادیر وزن‌های لایه‌ی اول در طول یادگیری تغییر نمی‌کنند و تنها پارامترهای قابل یادگیری آن وزن‌های لایه‌ی خروجی آن هستند. تابع خروجی ماشین یادگیری حداکثری برای یک شبکه عصبی پیشرو تک لایه با n گره‌ی پنهان به شکل زیر نمایش داده می‌شود:

$$f_n(x) = \sum_{i=1}^{n} \beta_i h_i(x) = \sum_{i=1}^{n} \beta_i G(I\,.\,a_i.\,b_i) \quad a_i \in R^d \quad .\, b_i \in R \qquad (۱)$$

که $\beta = \{\beta_1 . \dots . \beta_l\}$ نشان‌دهنده بردار وزن خروجی بین لایه‌های پنهان است و $h(x) =$ $\{h_1(x) . \dots . h_1(x)\}$ نگاشت یژگی‌های غیرخطی ماشین یادگیری حداکثری است.

توابع خروجی گره‌ها می‌تواند منحصربه‌فرد نباشد و در سلول‌های عصبی پنهان متفاوتی مورداستفاده قرار گیرد. همچنین $a_i \in R^d . b_i \in R$ که $h_i(x) = G(x_i\,.\,a_i\,.\,b_i)$ به توابع خروجی گره پنهان (با پارامترهای گره‌های مخفی $(a.b)$) اشاره دارد و یک تابع غیرخطی پیوسته است که قضایای قابلیت برآورد ضریب کلی ماشین یادگیری حداکثری را برقرار می‌سازد (دینگ و همکاران[۳۷]، ۲۰۱۴).

در این پژوهش تابع فعال‌سازی سیگموید به دلیل استفاده بیشتر در سایر پژوهش‌ها و شهرت بیشتر در میان توابع فعال‌سازی مورداستفاده قرارگرفته است. تابع سیگموئید[۳۸] که تابع لجستیک[۳۹] نیز نامیده می‌شود، دارای شکلی S مانند است که می‌تواند هر مقدار را به یک مقدار میان بازه صفر و یک نگاشت دهد. اگر منحنی به سمت مثبت بی‌نهایت برود، پیش‌بینی به عدد یک نگاشت داده می‌شود و اگر منحنی به سمت منفی بی‌نهایت برود، پیش‌بینی به عدد صفر نگاشت داده می‌شود. بنابراین سه مرحله الگوریتم ماشین یادگیری حداکثری می‌تواند به‌صورت زیر خلاصه شود:

حداکثری یادگیری ماشین الگوریتم
ورودی: یک مجموعه آموزشی $(x_i . t_i) \in R^n \times R^m (i = 1.2. \dots . N)$و تابع فعال Gو Lتا گره پنهان
خروجی: وزن‌های خروجی β
گام ۱: تعیین پارامترهای گره‌های پنهان $(a_i . b_i).\ i = 1. \dots . \tilde{N}$ به‌طور تصادفی
گام ۲: محاسبه ماتریس خروجی لایه پنهان H
گام ۳: محاسبه وزن خروجی βکه $\beta^* = H^{\dagger}T$

از سوی دیگر دو الگوریتم بهینه‌سازی شامل الگوریتم ماشین یادگیری حداکثری(OSELM) و ازدحام

ذرات(PSO) بکار گرفته شده اند.

الگوریتم ماشین یادگیری حداکثری(OSELM) به تکنیکی گفته می‌شود که در آن برای به‌روزرسانی وزن‌ها فقط به تعداد n عملیات خطی نیاز داریم که n تعداد داده‌های ورودی است. به‌این‌ترتیب ماشین یادگیری حداکثری(OSELM) قابلیت اجرا روی سیستم‌هایی که به‌صورت آنلاین عمل می‌کنند را دارا است و مشکل طولانی بودن زمان یادگیری شبکه‌های عصبی معمولی را ندارد. درواقع به دلیل ساختار خاص ELM (تک لایه بودن و عدم‌تغییر در وزن‌های لایه اول) است که پیاده‌سازی الگوریتم بهینه‌سازی OSELM بر روی آن امکان‌پذیر است. در واقع در این پژوهش ما از OSELM برای بهینه‌سازی وزن‌های لایه دوم یا همان لایه مخفی در ساختار ELM استفاده می‌کنیم. الگوریتم OSELM از دو ماتریس برای یادگیری وزن‌های شبکه استفاده می‌کند. ماتریس بتا (β) ماتریس وزن‌های شبکه و دی (D)، ماتریس کمکی الگوریتم OSELM است. مقداردهی اولیه آن‌ها به‌صورت زیر انجام می‌پذیرد:

$$\beta^0 = D_0 H_0^T T_0 \quad (۲)$$

$$D_0 = (H_0^T H_0)^{-1} \quad (۳)$$

$$T_0 = \left[t_1 . t_2 . \ldots . t_{N_0}\right]^T \quad (۴)$$

به‌روزرسانی ماتریس‌های بتا و دی به‌صورت زیر است:

$$\mathrm{D_{K+1}} = \mathrm{D_K} - \mathrm{D_K H_{K+1}^T}\left(\mathrm{I} + \mathrm{H_{K+1} D_K H_{K+1}^T}\right)^{-1}\mathrm{H_{K+1} D_K} \quad (۵)$$

$$\beta^{\mathrm{K+1}} = \beta^{\mathrm{K}} - \mathrm{D_{K+1} H_{K+1}^T}\left(\mathrm{T_{K+1}} - \mathrm{H_{K+1}}\beta^{\mathrm{K}}\right)^{1} \quad (۶)$$

در الگوریتم ازدحام ذرات هر ذره به‌عنوان یک پرنده در نظر گرفته می‌شود که تمامی پرندگان به دنبال یافتن بهترین نقطه می‌باشند و این اتفاق از طریق به اشتراک‌گذاری اطلاعات صورت می‌گیرد. به اشتراک‌گذاری اطلاعات بدین‌صورت است که تمامی پرندگان تابع برازندگی خود را محاسبه کرده و هر پرنده که بهترین برازندگی را داشته باشد بااطلاع دادن به سایر پرندگان باعث می‌شود تا سایر پرندگان به سمت او حرکت کنند و این اتفاق تا زمانی ادامه می‌یابد که همه پرندگان در بهترین نقطه جمع شوند . هرپرنده باتوجه به موقعیتی که در آن قرار دارد و بهترین موقعیت محلی قبلی خودش و همچنین بهترین موقعیت دیگر پرندگان، بهترین جهت را برای حرکت انتخاب می‌کند. درواقع فرضیه به اشتراک‌گذاری اطلاعات بین پرندگان، پایه و اساس این الگوریتم به‌حساب می‌آید (ژانگ و همکاران، ۲۰۰۷).

در هر مرحله موقعیت هر پرنده تحت تأثیر سه متغیر است که شامل بهترین موقعیتی است که خود پرنده در آن حضورداشته که با pbest و بهترین موقعیتی که سایر پرندگان اطلاع داده‌اند که با gbest

نمایش داده می‌شود. متغیر سوم نیز سرعت هر پرنده است (ژانگ و همکاران، ۲۰۰۷).

سرعت ذره:

$$v_{ij} = wv_{ij}(t) + c_1 r_1\left(p_{ij}^{pbest}(t) - x_{ij}(t)\right) + c_2 r_2(p_{ij}^{gbest}(t) - x_{ij}(t) \quad (۶)$$

مکان ذره:

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1) \quad (۷)$$

مراحل انجام الگوریتم ازدحام ذرات به صورت زیر است.

۱- مقداردهی اولیه

۲- انتخاب رهبر و به‌روزرسانی سرعت و موقعیت

۳- به‌روزرسانی اطلاعات گروهی پرندگان (هوش جمعی)

۴- تکرار فعالیت‌های انجام‌شده

معیارهای اندازه‌گیری خطا

با استفاده از معیارهای اندازه‌گیری خطا می‌توان میزان خطای روش‌های پیش‌بینی را برآورد کرد و بر اساس آن دقت پیش‌بینی روش‌های مختلف را باهم مقایسه نمود. در ادامه چگونگی محاسبه برخی از روش ها اندازه‌گیری خطای پیش‌بینی و روش محاسبه آن‌ها ارائه خواهد شد.

خطای جذر میانگین مربعات[۴۰] (RMSE) روشی است برای اندازه‌گیری میزان خطا است که تفاوت میان مقادیر تخمین زده‌شده و مقدار واقعی را به ما نشان می‌دهد. این شاخص همواره مقداری نامنفی دارد و هرچقدر که به صفر نزدیک‌تر باشد، نشان از بالاتر بودن دقت تخمین دارد.

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1} e_i^2} \quad (۸)$$

میانگین قدر مطلق خطا[۴۱] (MAE) روش دیگری است برای اندازه‌گیری میزان خطا است و این شاخص همواره مقداری نامنفی دارد و هرچقدر که به صفر نزدیک‌تر باشد، نشان از بالاتر بودن دقت تخمین دارد.

$$MAE = \frac{1}{n}\sum_{i=1} |e_i^2| \quad (۹)$$

میانگین مربع خطای نسبی[۴۲](MSRE) روش دیگری است برای اندازه‌گیری میزان خطا است و نحوه محاسبه آن به شرح ذیل است.

$$MSRE = \frac{1}{n}\sum_{i=1} \left|\frac{e_i}{a_i}\right|^2 \quad (۱۰)$$

میانگین قدر مطلق درصد خطا[۴۳](MAPE) روش دیگری است برای اندازه‌گیری میزان خطا است و

نحوه محاسبه آن به شرح ذیل است.

$$MAPE = \frac{100}{n}\sum_{i=1}\left|\frac{e_i}{a_i}\right| \quad (۱۱)$$

آزمون آماری تی استیودنت[۴۴]

با توجه به اینکه ما در این پژوهش از دو روش برای پیش‌بینی شاخص صنعت استفاده کرده‌ایم، با کمک آزمون تی استیودنت به دنبال پاسخ به این سؤال هستیم که آیا تفاوت این دو روش معنادار است یا خیر. درواقع ما با استفاده از روش‌های اندازه‌گیری خطا، تنها می‌توانیم متوجه شویم که دقت کدام روش بیشتر است اما نمی‌توان تشخیص داد که تفاوت بین آن‌ها معنادار است یا خیر که این کار با استفاده از آزمون تی استیودنت امکان‌پذیر می‌شود.

$$T = \frac{X_n - \mu}{S_n/\sqrt{n}} \quad (۱۲)$$

$$X_n = (X1 + X2 + \cdots + Xn)/n \quad (۱۳)$$

$$S_n^2 = \frac{1}{n-1}\sum_{i=1}^{n}(X_i - X_n)^2 \quad (۱۴)$$

یافته‌ها

هدف اصلی در این پژوهش دستیابی به یک مدل برای پیش‌بینی دقیق‌تر شاخص صنعت بورس اوراق بهادار تهران است. در ابتدا هر یک از مدل‌های مطرح‌شده اجرا شده و سپس با استفاده از روش‌های اندازه‌گیری خطا نتایج به‌دست‌آمده ارزیابی می گردد. به‌منظور پیش‌بینی شاخص صنعت در بازار بورس اوراق بهادار تهران از داده‌های نرخ ارز، قیمت جهانی نفت، حجم نقدینگی و داده‌های گذشته شاخص صنعت که به‌عنوان داده‌های ورودی می‌باشند و به‌صورت روزانه در بازه زمانی ۱۳۹۰ تا ۱۴۰۰ جمع‌آوری‌شده‌اند، استفاده می شود و شاخص صنعت به‌عنوان خروجی در نظر گرفته می شود. به‌منظور بررسی حجم نقدینگی بازار، ارزش معاملات روزانه بین سال‌های ۱۳۹۰ تا ۱۴۰۰ مورد استفاده قرار می گیرد. پس از جمع‌آوری داده‌های مربوطه، یک شبکه عصبی مناسب توسط زبان برنامه‌نویسی پایتون برای آن طراحی می‌شود و سپس شبکه عصبی توسط داده‌های جمع‌آوری‌شده آموزش داده می‌شود و در انتها مورد آزمون قرار می‌گیرد.

شبکه عصبی به کار گرفته‌شده در این پژوهش شبکه عصبی ماشین یادگیری حداکثری است که n سلول عصبی در لایه مخفی آن قرار داده شده و با استفاده از روش بهینه‌سازی ازدحام ذرات به بهینه‌سازی وزن‌های لایه دوم شبکه عصبی پرداخته می شود. مقداردهی اولیه شبکه نیز به‌صورت تصادفی انجام

می‌پذیرد و پس از آن وزن‌های لایه اول دیگر تغییر نمی‌کند. در پایان با استفاده از روش‌های اندازه‌گیری خطا میزان دقت پیش‌بینی را بر روی داده‌های تست که ۱۰ درصد داده‌ها را شامل می‌شود، سنجیده شده و به بررسی نتایج حاصل از روش پیشنهادی پرداخته می شود. الگوریتم فرا ابتکاری بهینه‌سازی ازدحام ذرات را به‌منظور بهینه‌سازی شبکه عصبی مصنوعی ماشین یادگیری حداکثری با تعداد نورون‌های متفاوت(۳۰، ۵۰، ۱۰۰، ۳۰۰، ۱۰۰۰) آزمایش می گردد که نتایج حاصل از آن به شرح زیر می شود. پارامترهای استفاده‌شده برای اجرای الگوریتم بهینه‌سازی ازدحام ذرات به شرح زیر است:

۱- تعداد پرندگان استفاده‌شده در این پژوهش ۱۰۰ عدد است.

۲- ضریب اینرسی برابر ۸/ در نظر گرفته‌شده است (w=/۸)

۳- ضریب حرکت به سمت بهترین محلی ۱/ در نظر گرفته‌شده است (α=/۱)

۴- ضریب حرکت به سمت بهترین گروه نیز ۱/ در نظر گرفته‌شده است (β=/۱)

تمامی ضرایب در روش الگوریتم ازدحام ذرات نیز به‌صورت تصادفی و بر اساس آزمایش و خطا به‌دست‌آمده است و بهترین ضرایب به‌دست‌آمده در پژوهش مورد استفاده قرار گرفته‌اند.برای مقداردهی اولیه هر پرنده می‌توان از دو روش تصادفی و هوشمند استفاده کرد. در روش تصادفی یا تصادفی مقداردهی وزن‌های لایه‌ی پنهان به‌صورت تصادفی انجام می‌شود. در روش هوشمند تعدادی از پرندگان به‌صورت هوشمند و سایر پرندگان به‌صورت تصادفی مقداردهی می‌شوند. در روش هوشمند از تصویرسازی برای رسیدن به جواب قابل قبول استفاده می‌شود. منظور از تصویرسازی، یافتن بردار وزن مناسب با توجه به تصویربردار ورودی روی فضای بردار خروجی است.

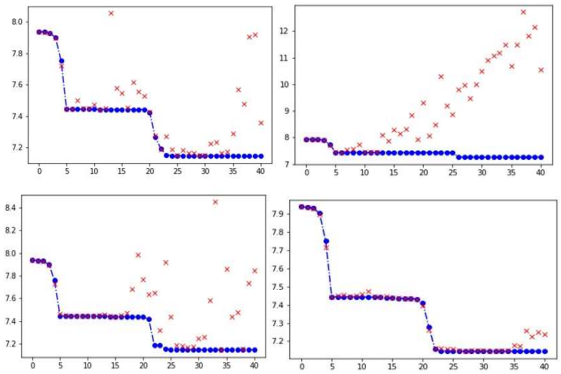

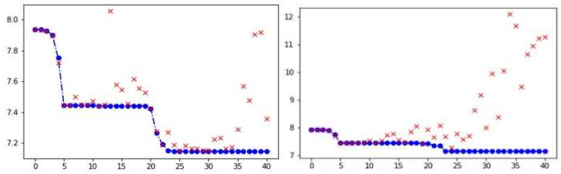

شکل ۲: نمودار خطاهای پرنده‌ی شماره ۱ الی ۶ در هر مرحله از جستجو

در نمودارهای بالا(محور افقی: تعداد دفعات اجرای الگوریتم، محور عمودی: میزان خطای پیش‌بینی در اجرای الگوریتم توسط هر پرنده، نقاط آبی: pbest، نقاط قرمز: مقدار خطا) روند جستجوی نقاط بهینه شش پرنده که به‌صورت تصادفی از میان ۱۰۰ پرنده انتخاب شده‌اند نشان داده شده است. در این نمودارها محور افقی نشان‌دهنده تعداد دفعات اجرای الگوریتم و محور عمودی نشان‌دهنده میزان خطای پیش‌بینی در اجرای الگوریتم توسط هر پرنده می‌باشند. نقاط آبی نشان‌دهنده خطای pbest و نقاط قرمز نشان‌دهنده خطای لحظه‌ای برای هر پرنده است. مشاهده می‌کنیم که معمولاً برای مدتی خطای pbest بدون تغییر بوده است که نشان‌دهنده این است که آن پرنده نتوانسته است که pbest بهتری را بیابد.

با توجه به نمودارهای بالا، با افزایش در تعداد دفعات اجرای الگوریتم، معمولاً مشاهده می‌شود نقاط بهینه محلی (pbest) که پرندگان می‌یابند بهتر می‌شود اما با توجه به تلاش هر پرنده برای یافتن نقاط بهتر و جستجوی کامل‌تر محیط نقاط بیشتری را جستجو می‌کند که درنتیجه آن میزان خطا که با استفاده ازمجذور میانگین خطاهای[۴۵] به‌دست‌آمده است درجدول ۱ نمایش داده شده است بیشتر می‌شود.

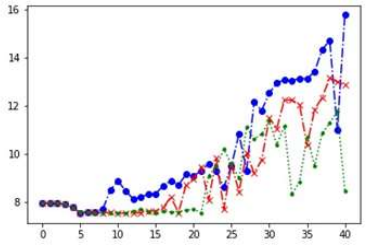

شکل ۳: نمودار خطاهای سه پرنده در هر مرحله از جستجو

در این نمودار نیز محور افقی نشان‌دهنده تعداد دفعات اجرای الگوریتم و محور عمودی نشان‌دهنده میزان خطای پیش‌بینی در اجرای الگوریتم است. این نمودار خطاهای سه پرنده را که به‌صورت تصادفی انتخاب‌شده‌اند را نشان می‌دهد و نتایج را به این صورت می‌توان تفسیر کرد که پرنده‌ها در بهینه محلی گیر نیفتاده و کل فضا را جستجو کرده‌اند.

جدول۱: پیش‌بینی شاخص صنعت توسط OSELM

تعداد نورون ها									
۱۰۰۰		۳۰۰		۱۰۰		۵۰		۳۰	
مقدار واقعی	OSELM	مقدار واقعی	OSELM	مقدار واقعی	OSELM	مقدار واقعی	OSELM	مقدار واقعی	OSELM
۱۸۴۱۸۲	۱۸۴۱۴۲.۷۰۸۴	۱۸۴۱۸۲	۱۸۴۲۲۷.۵۴۲۵	۱۸۴۱۸۲	۱۸۴۱۳۱.۰۹۹۵	۱۸۴۱۸۲	۱۸۴۱۲۸.۴۲۰۵	۱۸۴۱۸۲	۱۸۴۲۷۴.۸۷۱۱
۱۸۴۳۱۱	۱۸۴۲۹۸.۷۷۱۷	۱۸۴۳۱۱	۱۸۴۳۲۵.۱۷۳۷	۱۸۴۳۱۱	۱۸۴۲۹۵.۱۵۸۸	۱۸۴۳۱۱	۱۸۴۲۹۴.۳۲۵	۱۸۴۳۱۱	۱۸۴۳۳۹.۹۰۳۳
۱۸۲۷۲۷	۱۸۲۷۵۶.۵۹۲۹	۱۸۲۷۲۷	۱۸۲۶۹۲.۶۹۹۱	۱۸۲۷۲۷	۱۸۲۶۸۸.۶۶۳۷	۱۸۲۷۲۷	۱۸۲۷۶۷.۳۵۴	۱۸۲۷۲۷	۱۸۲۶۵۷.۰۵۳
۱۸۳۱۸۲	۱۸۳۱۹۸.۷۹۱۵	۱۸۳۱۸۲	۱۸۳۱۶۲.۵۳۷۱	۱۸۳۱۸۲	۱۸۳۲۰۳.۷۵۲۶	۱۸۳۱۸۲	۱۸۳۲۰۴.۸۹۷۵	۱۸۳۱۸۲	۱۸۳۱۴۲.۳۱۱
۱۸۴۶۳۸	۱۸۴۶۴۳.۵۰۴۱	۱۸۴۶۳۸	۱۸۴۶۴۴.۳۷۹۸	۱۸۴۶۳۸	۱۸۴۶۳۰.۸۶۹۷	۱۸۴۶۳۸	۱۸۴۶۴۵.۵۰۵۶	۱۸۴۶۳۸	۱۸۴۶۵۱.۰۰۹۷
۱۸۸۴۰۴	۱۸۸۳۸۰.۳۱۵۲	۱۸۸۴۰۴	۱۸۸۴۳۱.۴۵۲۹	۱۸۸۴۰۴	۱۸۸۴۳۴.۶۸۲۶	۱۸۸۴۰۴	۱۸۸۴۳۶.۲۹۷۵	۱۸۸۴۰۴	۱۸۸۳۴۸.۰۱۷۷
۱۹۳۸۱۴	۱۹۳۸۲۵.۵۴۴۷	۱۹۳۸۱۴	۱۹۳۸۰۰.۶۱۸۶	۱۹۳۸۱۴	۱۹۳۷۹۹.۰۴۴۳	۱۹۳۸۱۴	۱۹۳۷۹۸.۲۵۷۲	۱۹۳۸۱۴	۱۹۳۸۴۱.۲۸۷۵
۱۹۵۴۳۹	۱۹۵۴۶۷.۲۹۰۱	۱۹۵۴۳۹	۱۹۵۴۰۶.۲۰۹۲	۱۹۵۴۳۹	۱۹۵۴۰۲.۳۵۱۵	۱۹۵۴۳۹	۱۹۵۴۰۰.۴۲۲۶	۱۹۵۴۳۹	۱۹۵۳۷۲.۱۳۲۵
۱۹۸۶۱۶	۱۹۸۶۲۱.۸۰۶۷	۱۹۸۶۱۶	۱۹۸۶۲۲.۷۳۰۵	۱۹۸۶۱۶	۱۹۸۶۰۸.۴۷۷۷	۱۹۸۶۱۶	۱۹۸۶۲۳.۹۱۸۲	۱۹۸۶۱۶	۱۹۸۶۰۲.۲۷۵۱
۲۰۲۳۱۳	۲۰۲۳۵۱.۲۶۵۴	۲۰۲۳۱۳	۲۰۲۳۵۷.۳۵۳۱	۲۰۲۳۱۳	۲۰۲۲۶۳.۴۲۸۹	۲۰۲۳۱۳	۲۰۲۲۶۰.۸۱۹۹	۲۰۲۳۱۳	۲۰۲۴۰۳.۴۴۵۵
۲۰۱۱۲۹	۲۰۱۱۳۶.۵۰۲۴	۲۰۱۱۲۹	۲۰۱۱۳۷.۶۹۶	۲۰۱۱۲۹	۲۰۱۱۳۸.۷۱۹۱	۲۰۱۱۲۹	۲۰۱۱۱۸.۷۶۹۴	۲۰۱۱۲۹	۲۰۱۱۴۶.۷۳۳
۱۹۳۵۵۲	۱۹۳۵۷۵.۴۰۹۲	۱۹۳۵۵۲	۱۹۳۵۷۹.۱۳۳۴	۱۹۳۵۵۲	۱۹۳۵۸۲.۳۲۵۶	۱۹۳۵۵۲	۱۹۳۵۸۳.۹۲۱۷	۱۹۳۵۵۲	۱۹۳۶۰۷.۳۳۰۹
۱۸۶۷۴۵	۱۸۶۷۸۳.۷۶۲۲	۱۸۶۷۴۵	۱۸۶۷۸۹.۹۲۸۹	۱۸۶۷۴۵	۱۸۶۶۹۴.۷۸۵۳	۱۸۶۷۴۵	۱۸۶۷۹۷.۸۵۷۶	۱۸۶۷۴۵	۱۸۶۸۳۶.۶۱۹۸
۱۸۹۷۳۵	۱۸۹۷۱۲.۹۶۷۳	۱۸۹۷۳۵	۱۸۹۷۰۹.۴۶۲۱	۱۸۹۷۳۵	۱۸۹۷۶۳.۵۴۲۳	۱۸۹۷۳۵	۱۸۹۷۶۵.۰۴۴۶	۱۸۹۷۳۵	۱۸۹۶۸۲.۹۲۲۷

جدول۲: پیش‌بینی شاخص صنعت توسط Random PSO

تعداد نـورون هـا									
۱۰۰۰		۳۰۰		۱۰۰		۵۰		۳۰	
مقـدار واقعـی	Random PSO	مقـدار واقعـی	Random PSO	مقـدار واقعـی	Random PSO	مقـدار واقعـی	Random PSO	مقـدار واقعـی	Random PSO
۱۸۴۱۸۲	۱۸۵۷۴۲.۰۵۵۲	۱۸۴۱۸۲	۱۸۳۸۰۹.۶۲۲۸	۱۸۴۱۸۲	۱۸۴۰۲۸.۴۰۵۶	۱۸۴۱۸۲	۱۸۴۰۲۴.۸۳۳۶	۱۸۴۱۸۲	۱۸۴۳۳۲.۰۲۲۵
۱۸۴۳۱۱	۱۸۴۷۹۶.۵۱۹۹	۱۸۴۳۱۱	۱۸۴۱۹۵.۱۰۸۹	۱۸۴۳۱۱	۱۸۴۲۶۳.۱۹۸۴	۱۸۴۳۱۱	۱۸۴۳۵۹.۹۱۳۳	۱۸۴۳۱۱	۱۸۴۲۶۴.۳۱
۱۸۲۷۲۷	۱۸۱۵۵۲.۰۲۵۷	۱۸۲۷۲۷	۱۸۳۰۰۷.۴۶۰۴	۱۸۲۷۲۷	۱۸۲۸۴۲.۶۸۱۵	۱۸۲۷۲۷	۱۸۲۸۴۵.۳۷۱۸	۱۸۲۷۲۷	۱۸۲۶۱۴.۰۰۸۸
۱۸۳۱۸۲	۱۸۲۵۱۵.۳۰۱۳	۱۸۳۱۸۲	۱۸۳۳۴۱.۱۳۷۶	۱۸۳۱۸۲	۱۸۳۱۱۶.۳۶۰۵	۱۸۳۱۸۲	۱۸۳۱۱۴.۸۳۴	۱۸۳۱۸۲	۱۸۳۲۴۶.۱۱۳
۱۸۴۶۳۸	۱۸۴۸۵۶.۵۳۸۵	۱۸۴۶۳۸	۱۸۴۶۹۰.۱۶۴	۱۸۴۶۳۸	۱۸۴۶۵۹.۵۱۶۱	۱۸۴۶۳۸	۱۸۴۶۶۰.۰۱۶۵	۱۸۴۶۳۸	۱۸۴۶۵۹.۰۱۵۷
۱۸۸۴۰۴	۱۸۷۴۶۳.۶۰۴۲	۱۸۸۴۰۴	۱۸۸۶۲۸.۴۶۷۷	۱۸۸۴۰۴	۱۸۸۳۱۱.۴۱۳۸	۱۸۸۴۰۴	۱۸۸۴۹۸.۷۳۹۴	۱۸۸۴۰۴	۱۸۸۴۹۴.۴۳۳
۱۹۳۸۱۴	۱۹۴۲۷۲.۳۷۷۸	۱۹۳۸۱۴	۱۹۳۷۰۴.۵۸۷۶	۱۹۳۸۱۴	۱۹۳۸۵۹.۱۲۹۴	۱۹۳۸۱۴	۱۹۳۸۶۰.۱۷۸۹	۱۹۳۸۱۴	۱۹۳۷۶۹.۹۲۰۲
۱۹۵۴۳۹	۱۹۶۵۶۲.۲۴۵۶	۱۹۵۴۳۹	۱۹۵۱۷۰.۸۸۷	۱۹۵۴۳۹	۱۹۵۳۲۸.۴۱۱۴	۱۹۵۴۳۹	۱۹۵۵۵۲.۱۶۰۴	۱۹۵۴۳۹	۱۹۵۵۴۷.۰۱۶۸
۱۹۸۶۱۶	۱۹۸۸۴۶.۵۵۱۹	۱۹۸۶۱۶	۱۹۸۵۶۰.۹۶۸۴	۱۹۸۶۱۶	۱۹۸۵۹۳.۳۰۱۱	۱۹۸۶۱۶	۱۹۸۵۹۲.۷۷۳۳	۱۹۸۶۱۶	۱۹۸۶۳۸.۱۷۱
۲۰۲۳۱۳	۲۰۰۷۹۳.۶۹۰۲	۲۰۲۳۱۳	۲۰۱۹۵۰.۳۴۸۵	۲۰۲۳۱۳	۲۰۲۱۶۳.۴۱۷۱	۲۰۲۳۱۳	۲۰۲۴۶۶.۰۶۱۵	۲۰۲۳۱۳	۲۰۲۴۵۹.۱۰۴۲
۲۰۱۱۲۹	۲۰۰۸۳۱.۱۱۹	۲۰۱۱۲۹	۲۰۱۰۵۷.۸۹۷۳	۲۰۱۱۲۹	۲۰۱۰۹۹.۶۷۲۳	۲۰۱۱۲۹	۲۰۱۱۵۹.۰۰۹۸	۲۰۱۱۲۹	۲۰۱۱۰۰.۳۵۴۳
۱۹۳۵۵۲	۱۹۲۶۲۲.۵۴۶۵	۱۹۳۵۵۲	۱۹۳۷۷۳.۸۵۵۸	۱۹۳۵۵۲	۱۹۳۶۴۳.۵۰۸۹	۱۹۳۵۵۲	۱۹۳۶۴۵.۶۳۷	۱۹۳۵۵۲	۱۹۳۴۶۲.۶۱۹۲
۱۸۶۷۴۵	۱۸۵۲۰۵.۹۶۳۴	۱۸۶۷۴۵	۱۸۶۳۷۷.۶۳۹۸	۱۸۶۷۴۵	۱۸۶۸۹۶.۵۲۵۱	۱۸۶۷۴۵	۱۸۶۵۸۹.۹۵۱۱	۱۸۶۷۴۵	۱۸۶۵۹۶.۹۹۸۸
۱۸۹۷۳۵	۱۹۰۶۰۹.۷۹۷۹	۱۸۹۷۳۵	۱۸۹۵۲۶.۱۹۰۲	۱۸۹۷۳۵	۱۸۹۸۲۱.۱۲۷۸	۱۸۹۷۳۵	۱۸۹۸۲۳.۱۳۰۸	۱۸۹۷۳۵	۱۸۹۶۵۰.۸۷۵۲
۱۸۷۷۵۷	۱۸۹۰۴۸.۸۹۵	۱۸۷۷۵۷	۱۸۷۴۴۸.۶۳۱۲	۱۸۷۷۵۷	۱۸۷۶۲۹.۸۰۷۱	۱۸۷۷۵۷	۱۸۷۶۲۶.۸۴۹۲	۱۸۷۷۵۷	۱۸۷۶۳۲.۷۶۵۱
۱۸۳۳۴۹	۱۸۱۶۸۷.۷۶۱۴	۱۸۳۳۴۹	۱۸۳۷۴۵.۵۲۹۲	۱۸۳۳۴۹	۱۸۳۵۱۲.۵۵۶۴	۱۸۳۳۴۹	۱۸۳۱۸۱.۶۴	۱۸۳۳۴۹	۱۸۳۵۰۸.۷۵۲۸

جدول۳: پیش‌بینی شاخص صنعت توسط Mixed PSO

تعداد نورون ها									
۱۰۰۰		۳۰۰		۱۰۰		۵۰		۳۰	
مقدار واقعی	Mixed PSO	مقدار واقعی	Mixed PSO	مقدار واقعی	Mixed PSO	مقدار واقعی	Mixed PSO	مقدار واقعی	Mixed PSO
۱۸۴۱۸۲	۱۸۳۹۵۱.۶۰۸۳	۱۸۴۱۸۲	۱۸۴۲۵۸.۷۹۷۲	۱۸۴۱۸۲	۱۸۴۲۴۳.۶۱۶۴	۱۸۴۱۸۲	۱۸۴۲۴۶.۲۹۵۳	۱۸۴۱۸۲	۱۸۴۲۶۵.۹۴۱۲
۱۸۴۳۱۱	۱۸۴۳۸۲.۷۰۲۴	۱۸۴۳۱۱	۱۸۴۳۳۴.۹۰۰۸	۱۸۴۳۱۱	۱۸۴۳۳۰.۱۷۶۲	۱۸۴۳۱۱	۱۸۴۲۹۰.۹۹	۱۸۴۳۱۱	۱۸۴۲۸۴.۸۷۵۹
۱۸۲۷۲۷	۱۸۲۵۵۳.۴۷۷۸	۱۸۲۷۲۷	۱۸۲۷۸۴.۸۴۰۷	۱۸۲۷۲۷	۱۸۲۶۸۰.۵۹۲۹	۱۸۲۷۲۷	۱۸۲۶۷۸.۵۷۵۲	۱۸۲۷۲۷	۱۸۲۶۶۳.۷۷۸۷
۱۸۳۱۸۲	۱۸۳۲۸۰.۴۵۹۲	۱۸۳۱۸۲	۱۸۳۲۱۴.۸۱۹۷	۱۸۳۱۸۲	۱۸۳۱۵۵.۶۶۷۹	۱۸۳۱۸۲	۱۸۳۱۵۴.۵۲۳	۱۸۳۱۸۲	۱۸۳۲۱۷.۸۷۲۷
۱۸۴۶۳۸	۱۸۴۶۰۵.۷۲۵۹	۱۸۴۶۳۸	۱۸۴۶۴۸.۷۵۸	۱۸۴۶۳۸	۱۸۴۶۴۶.۶۳۱۵	۱۸۴۶۳۸	۱۸۴۶۲۸.۹۹۳۳	۱۸۴۶۳۸	۱۸۴۶۲۶.۲۴۱۲
۱۸۸۴۰۴	۱۸۸۵۴۲.۸۷۹۳	۱۸۸۴۰۴	۱۸۸۳۵۷.۷۰۶۹	۱۸۸۴۰۴	۱۸۸۳۶۶.۸۵۷۹	۱۸۸۴۰۴	۱۸۸۳۶۵.۲۴۳	۱۸۸۴۰۴	۱۸۸۳۵۳.۴۰۰۶
۱۹۳۸۱۴	۱۹۳۷۴۶.۳۰۶	۱۹۳۸۱۴	۱۹۳۸۳۶.۵۶۴۷	۱۹۳۸۱۴	۱۹۳۸۳۲.۱۰۴۲	۱۹۳۸۱۴	۱۹۳۷۹۵.۱۰۸۶	۱۹۳۸۱۴	۱۹۳۷۸۹.۳۳۶۳
۱۹۵۴۳۹	۱۹۵۲۷۳.۱۱۷۱	۱۹۵۴۳۹	۱۹۵۴۹۴.۲۹۴۳	۱۹۵۴۳۹	۱۹۵۴۸۳.۳۶۴	۱۹۵۴۳۹	۱۹۵۴۸۵.۲۹۲۹	۱۹۵۴۳۹	۱۹۵۴۹۹.۴۳۷۹
۱۹۸۶۱۶	۱۹۸۵۸۱.۹۵۱۷	۱۹۸۶۱۶	۱۹۸۶۲۷.۳۴۹۴	۱۹۸۶۱۶	۱۹۸۶۰۶.۸۹۴۱	۱۹۸۶۱۶	۱۹۸۶۰۶.۴۹۸۱	۱۹۸۶۱۶	۱۹۸۶۰۳.۵۹۴۸
۲۰۲۳۱۳	۲۰۲۰۸۸.۶۲۵۷	۲۰۲۳۱۳	۲۰۲۲۳۸.۲۰۸۶	۲۰۲۳۱۳	۲۰۲۳۷۳.۰۰۷۱	۲۰۲۳۱۳	۲۰۲۳۷۵.۶۱۶۱	۲۰۲۳۱۳	۲۰۲۳۹۴.۷۴۸۸
۲۰۱۱۲۹	۲۰۱۱۷۲.۹۹۱۶	۲۰۱۱۲۹	۲۰۱۱۱۴.۳۳۶۱	۲۰۱۱۲۹	۲۰۱۱۴۰.۷۶۵۲	۲۰۱۱۲۹	۲۰۱۱۱۶.۷۲۳۳	۲۰۱۱۲۹	۲۰۱۱۴۵.۰۲۷۹
۱۹۳۵۵۲	۱۹۳۶۸۹.۲۶۳۳	۱۹۳۵۵۲	۱۹۳۵۹۷.۷۵۴۴	۱۹۳۵۵۲	۱۹۳۵۱۵.۲۹	۱۹۳۵۵۲	۱۹۳۵۹۰.۳۰۶	۱۹۳۵۵۲	۱۹۳۶۰۲.۰۱۰۷
۱۸۶۷۴۵	۱۸۶۵۱۷.۷۱۲۴	۱۸۶۷۴۵	۱۸۶۶۶۹.۲۳۷۵	۱۸۶۷۴۵	۱۸۶۶۸۴.۲۱۳۸	۱۸۶۷۴۵	۱۸۶۸۰۸.۴۲۹۱	۱۸۶۷۴۵	۱۸۶۸۲۷.۸۱۰۲
۱۸۹۷۳۵	۱۸۹۶۰۵.۸۰۸۳	۱۸۹۷۳۵	۱۸۹۷۷۸.۰۶۳۹	۱۸۹۷۳۵	۱۸۹۷۶۹.۵۵۱۳	۱۸۹۷۳۵	۱۸۹۷۷۱.۰۵۳۵	۱۸۹۷۳۵	۱۸۹۶۸۷.۹۳۰۲
۱۸۷۷۵۷	۱۸۷۹۴۷.۷۸۹۳	۱۸۷۷۵۷	۱۸۷۸۲۰.۵۹۶۴	۱۸۷۷۵۷	۱۸۷۸۰۸.۰۲۵	۱۸۷۷۵۷	۱۸۷۷۰۳.۷۵۶۵	۱۸۷۷۵۷	۱۸۷۸۲۶.۵۱۲۴
۱۸۳۳۴۹	۱۸۳۱۰۳.۶۶۵۴	۱۸۳۳۴۹	۱۸۳۲۶۷.۲۲۱۸	۱۸۳۳۴۹	۱۸۳۲۸۳.۳۸۷۳	۱۸۳۳۴۹	۱۸۳۲۸۰.۵۳۴۵	۱۸۳۳۴۹	۱۸۳۴۳۸.۳۸۵۵

در جداول بالا نتایج حاصل از پیش‌بینی شاخص صنعت با استفاده از دو روش PSO و OSELM در کنار مقدار واقعی شاخص نشان داده شده است. نتایج حاکی از دقت بالای هر دوروش می‌باشد و با توجه به جداول می‌توان نتیجه گرفت که هر چه تعداد نورون‌ها بیشتر شده است دقت پیش‌بینی بالاتر رفته است و در مجموع می‌توان گفت که دقت شبکه عصبی OSELM نسبت به PSO بیشتر می‌باشد که درادامه با بررسی میزان خطاهای روش‌های مختلف بررسی خواهیم کرد که آیا تفاوت میان دقت پیش-بینی در دو روش معنادار است یا خیر.

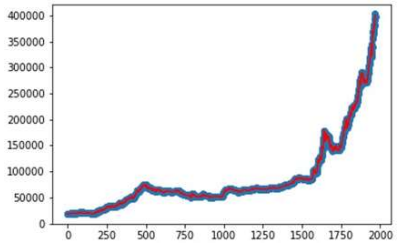

شکل ۴: نمودار پیش‌بینی شاخص صنعت به‌وسیله OSELM

در این نمودار خطوط آبی‌رنگ نشان‌دهنده شاخص صنعت و خطوط قرمزرنگ نشان‌دهنده پیش‌بینی شاخص توسط شبکه عصبی OSELM است.

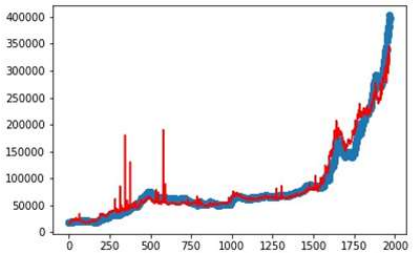

شکل ۵: نمودار پیش‌بینی شاخص صنعت به‌وسیله PSO

در این نمودار خطوط آبی‌رنگ نشان‌دهنده شاخص صنعت و خطوط قرمزرنگ نشان‌دهنده پیش‌بینی شاخص توسط الگوریتم PSO است.

جدول ۴: جدول اندازه گیری خطای پیش‌بینی

تعداد نورون های لایه پنهان	MAPE			تعداد نورون های لایه پنهان	RMSE			تعداد نورون های لایه پنهان
	Random PSO	Mixed PSO	OSELM		Random PSO	Mixed PSO	OSELM	
۳۰ cells	۰.۰۵۳۳	۰.۰۱۵۹	۰.۰۱۸۴	۳۰ cells	۸۵.۵۵	۴۹.۲۶	۵۵.۱۳	۳۰ cells
۵۰ cells	۰.۰۶۷۳	۰.۰۱۰۵	۰.۰۰۷۹	۵۰ cells	۹۴.۸	۳۷.۶۵	۲۹.۳۹	۵۰ cells
۱۰۰ cells	۰.۰۵۵۸	۰.۰۰۸۳	۰.۰۰۶۸	۱۰۰ cells	۸۷.۳۵	۳۴.۲۴	۲۷.۴۱	۱۰۰ cells
۳۰۰ cells	۰.۲۷۶۳	۰.۰۱۴۸	۰.۰۰۶۱	۳۰۰ cells	۲۱۴.۸	۴۲.۸۴	۲۴.۵۷	۳۰۰ cells
۱۰۰۰ cells	۰.۴۷۶۱	۰.۰۵۶۹	۰.۰۰۵۴	۱۰۰۰ cells	۹۸۵.۲	۱۲۰.۶۶	۲۱.۳۷	۱۰۰۰ cells
تعداد نورون های لایه پنهان	MAE			تعداد نورون های لایه پنهان	MSRE			تعداد نورون های لایه پنهان
	Random PSO	Mixed PSO	OSELM		Random PSO	Mixed PSO	OSELM	
۳۰ cells	۲۴۳۶.۵	۱۰۵۳.۲	۵۸۵.۰۱	۳۰ cells	۰.۰۰۰۱۶۸۰۰	۰.۰۰۰۰۹۵۸۰	۰.۰۰۰۰۷۵۴۰	۳۰ cells
۵۰ cells	۳۱۷۵	۸۶۹.۳	۵۷۰.۹۲	۵۰ cells	۰.۰۰۰۱۷۴۰۰	۰.۰۰۰۰۸۸۶۰	۰.۰۰۰۰۷۴۴۰	۵۰ cells
۱۰۰ cells	۲۶۶۸.۲	۷۵۹.۶	۵۶۴.۱۷	۱۰۰ cells	۰.۰۰۰۱۷۰۰۰	۰.۰۰۰۰۸۵۲۰	۰.۰۰۰۰۷۲۶۰	۱۰۰ cells
۳۰۰ cells	۸۴۰۲.۳	۹۳۱.۹	۵۴۹.۳۵	۳۰۰ cells	۰.۰۰۰۲۹۸۰۰	۰.۰۰۰۰۹۲۶۰	۰.۰۰۰۰۷۰۶	۳۰۰ cells
۱۰۰۰ cells	۹۶۷۱.۶	۱۸۴۹.۵	۵۳۸.۴۹	۱۰۰۰ cells	۰.۰۰۰۳۹۲۰۰	۰.۰۰۰۰۹۹۷۰	۰.۰۰۰۰۰۶۹۸	۱۰۰۰ cells

در جدول بالا میزان خطای حاصل از اجرای الگوریتم PSO به دو صورت Mix و تصادفی (random) و همچنین نتایج حاصل از شبکه عصبی OSELM ارائه‌شده است که با استفاده از چهار روش اندازه‌گیری خطا، میزان دقت پیش‌بینی هر روش به‌دست‌آمده است. همچنین تعداد نورون‌های متفاوتی را در لایه پنهان استفاده کردیم تا بتوانیم بهترین تعداد نورون‌ها را یافته و دقت پیش‌بینی را بالاتر ببریم.

جداول به صورت تفکیک شده بر اساس چهار روش اندازه‌گیری خطا با تعداد نورون‌های متفاوت در لایه پنهان برای هر دو روش PSO و OSELM نمایش داده شده‌اند.

نتایج نشان می‌دهند که در هر چهار روش اندازه‌گیری خطا و با تعداد نورون‌های متفاوت در لایه پنهان، روش OSELM خطای کمتری را نسبت به روشPSO دارد. برای اثبات معناداری این اختلاف از آزمون آماری استفاده می‌کنیم که در ادامه نتایج حاصل از آزمون آماری تی-استیودنت نیز ارائه شده است. همچنین می‌توان گفت که با افزایش تعداد نورون‌ها در لایه پنهان خطا کاهش می‌یابد اما از یک نقطه به بعد خطا مجددا افزایش می‌یابد که در اصطلاح به آن بیش برازش[۴۶]می‌گویند.

جدول۵: آزمون آماری تی-استیودنت میان مقادیر پیش‌بینی

آزمون آماری t_test	مقایسه معناداری میان نتایج پیش بینی مقدار شاخص توسط دو الگوریتم OSELM و PSO	
	Random PSO	Mixed PSO
P_Value	۰.۲۰۴۰۰۸۸۷۶	۰.۲۶۴۳۵۳۷۶۲

نتایج را این‌گونه می‌توان تفسیر کرد که پیش‌بینی شاخص با استفاده از دو روش OSELM و PSO تفاوت معناداری ندارد (البته با اختلاف اندکی نتایج حاصل از OSELM بهتر است).

جدول ۶: جدول اندازه گیری مدت زمان اجرای پیش‌بینی

تعداد نورون های لایه پنهان	TIME		
	OSELM	Mixed PSO	Random PSO
۳۰ cells	۴.۹۲	۳۴۹	۵۵۱
۵۰ cells	۳.۳۷	۵۱۸	۶۱۰
۱۰۰ cells	۷.۱۷	۹۳۴	۹۲۰
۳۰۰ cells	۷.۹۶	۱۲۷۹	۱۲۴۸
۱۰۰۰ cells	۹.۳	۲۰۴۸	۲۰۱۶

در جدول۶ نیز نتایج حاصل از مدت زمان اجرای هر دو الگوریتم PSO و OSELM با تعداد نورون‌های مختلف در لایه مخفی نشان داده شده است. نتایج به وضوح نشان می‌دهند که مدت زمان اجرای الگوریتم توسط شبکه عصبی OSELM بسیار کمتر از روش PSO می‌باشد که البته با افزایش تعداد نورون‌ها، مدت زمان اجرای الگوریتم در هر دو روش زیادتر شده است که اتفاقی معمول است. در ادامه نیز نتایج حاصل از آزمون آماری که به منظور معناداری یا عدم معناداری این اختلاف زمانی انجام شده است نمایش داده می‌شود.

جدول۷: آزمون آماری تی-استیودنت میان زمان‌های پیش‌بینی

آزمون آماری t_test	مقایسه معناداری میان نتایج پیش بینی مقدار شاخص توسط دو الگوریتم OSELM و PSO	
	Random PSO	Mixed PSO
P_Value	۰.۰۱۶۳۰۰۱۰۷	۰.۰۲۷۸۷۴۲۷۸

نتایج جدول نشان از مزیت و برتری قابل توجه OSELM نسبت به PSO در مدت زمان اجرای الگوریتم دارد.

نتیجه‌گیری

در پژوهش‌های پیشین که به پیش‌بینی شاخص بورس و یا قیمت سهام پرداخته بودند دارای دو رویکرد سنتی و هوشمند بودند و در اکثر آن‌ها به این نتیجه رسیده بودند که مزیت اصلی روش‌های هوشمند مثل شبکه‌های عصبی یا الگوریتم‌های فرا ابتکاری نسبت به روش‌های سنتی، داشتن سرعت بیشتر و خطای کمتر است. همچنین روش‌های هوشمند دارای انعطاف‌پذیری و دقت بالا در حل مسائل سری‌های زمانی غیرخطی با الگوهای پیچیده می‌باشند، به همین دلیل ما در این پژوهش از روش‌های هوشمند برای پیش‌بینی شاخص صنعت استفاده نموده‌ایم.

ما با استفاده از یک شبکه عصبی ELM که دارای یک‌لایه مخفی است و همچنین وزن‌های داده‌شده به لایه اول که به‌صورت تصادفی انتخاب می‌شوند و تا پایان تغییر پیدا نمی‌کنند، تلاش می‌کنیم تا بتوانیم پیش‌بینی دقیق‌تری از شاخص را ارائه دهیم. برای بهینه‌سازی وزن‌های لایه مخفی شبکه عصبی ELM از دو روش بهینه‌سازی PSO و OSELM استفاده کردیم که هرکدام دارای ویژگی‌های خاص خود می‌باشند. برای مثال معمولاً PSO به دلیل جستجوی بخش بزرگی از فضا دارای دقت بالایی است و به همان دلیل نیز مدت‌زمان زیادی را صرف این کار می‌کند اما OSELM علاوه بر دقت مناسب در پیش-بینی دارای سرعت‌بالایی نیز است.

بهینه‌سازی بر روی وزن‌های لایه دوم ساختارELM توسط الگوریتمPSO به دو صورتMIX و تصادفی (Random) (که تفاوتشان در محل شروع حرکت پرندگان است که در مدل رندوم تمامی پرندگان به صورت تصادفی در محیط پخش می‌شوند و محل شروع حرکتشان کاملا تصادفی است اما در مدل MIX محل شروع حرکت تعداد محدودی از پرندگان به صورت دستی و با توجه به ۲۰ درصد داده‌ها که به عنوان داده‌های مقداردهی اولیه مورد استفاده قرار گرفته‌اند تعیین می‌شود) و همچنین شبکه عصبی OSELM صورت گرفته است که با استفاده از چهار معیار اندازه‌گیری خطا (MAE,MAPE, MSRE,RMSE)، دقت پیش‌بینی آن‌ها سنجیده شده است. نتایج حاصل از معیارهای اندازه‌گیری خطا نشان می‌دهد که دقت پیش‌بینی در شبکه عصبیOSELM نسبت به هر دو حالت MIX و Random در الگوریتم PSO بالاتر بوده و با تغییر تعداد نورون‌ها در لایه مخفی نیز تغییری در نتیجه حاصل نشده است.

البته مقایسه معناداری تفاوت مدل‌ها به وسیله آزمون t-test نشان می‌دهد که تفاوت در پیش‌بینی توسط دو الگوریتم PSO و OSELM معنادار نبوده، در واقع می‌توان گفت که دقت پیش‌بینی در هر دو مدل یکسان است و یا اینکه تفاوت آن‌ها تفاوت معناداری نمی‌باشد.

همچنین با توجه به نتایج بدست آمده، خروجی اجرای الگوریتم‌ها نشان می‌دهد که مدت زمان اجرای الگوریتم و سرعت انجام پیش‌بینی در شبکه عصبی OSELM بسیار کم‌تر از الگوریتم PSO می‌باشد. همچنین مقایسه معناداری تفاوت مدت زمان اجرای مدل‌ها به وسیله آزمون t-test نیز برنتایج بدست آمده صحه می‌گذارد و نشان می‌دهد که در تمامی حالات، شبکه عصبی OSELM از لحاظ زمانی بسیار بهتر از PSO عمل کرده است.

با توجه به نتایج به‌دست‌آمده فرض وجود عدم تفاوت معنادار میان قدرت پیش‌بینی شبکه عصبی OSELM و شبکه عصبی ELM با تابع بهینه‌سازی PSO را نمی‌توان رد نمود لذا از لطحاظ قدرت پیش‌بینی کنندگی تفاوت معناداری ندارند. اما فرض عدم تفاوت سرعت عملکرد شبکه عصبی ELM با تابع بهینه‌سازی PSO نسبت به شبکه عصبی OSELM رد می گردد که این بدان معناست که سرعت عملکرد شبکه عصبی OSELM بیشتر می‌باشد.

منابع

۱) ابراهیمی، محسن؛ شکری، نوشین (۱۳۹۰). بررسی تاثیر متغیرهای کلان اقتصادی بر قیمت سهام با تاکید بر نقش سیاست پولی .فصلنامه علمی مدلسازی اقتصادی. ۵(۱۳). ۲۳-۴۵.

۲) اسلاملوییان, کریم, زارع, هاشم. (۱۳۸۵). بررسی تاثیر متغیرهای کلان و داراییهای جایگزین بر قیمت سهام در ایران یک الگوی خودهمبسته با وقفه های توزیعی .*پژوهشهای اقتصادی ایران*. ۸(۲۹).۱۷-۴۶.

۳) دموری, داریوش, فرید, داریوش, اشهر, مرتضی. (۱۳۹۰). پیش‌بینی شاخص کل بورس اوراق بهادار تهران با استفاده از الگوریتم پرواز پرندگان و مقایسه آن با الگوهای سنتی .*مجله دانش حسابداری*: ۲(۵).۷-۳۰.

۴) بیگی، شاهرخ (۱۳۹۸). بررسی تعاملات نرخ ارز و بازار سهام، رویکرد سیستم معادلات هم‌زمان، پایان‌نامه کارشناسی‌ارشد، دانشگاه خوارزمی تهران.

۵) پاکدین امیری, علیرضا, پاکدین امیری, مجتبی, پاکدین امیری, مرتضی. (۱۳۸۸). ارائه مدل پیش بینی شاخص کل قیمت سهام با رویکرد شبکه های عصبی (مطالعه موردی: بورس اوراق بهادار تهران) .*دوفصلنامه جستارهای اقتصادی*.۶(۱۱).۸۳-۱۰۸

۶) جورابیان، محمود (۱۳۸۶)،شبکه‌های عصبی مصنوعی، انتشارات دانشگاه شهیدچمران.

۷) حسن زاده, علی, کیانوند, مهران. (۱۳۹۳). اثر شوک‌های متقارن و نامتقارن نفتی بر شاخص کل قیمتی در بازار بورس اوراق بهادار تهران .اقتصاد پولی مالی. ۲۱(۸).۳۰-۶۱.

۸) رمضانیان کشتلی، مریم و مومنی کشتلی، رضا،۱۳۹۸،کاربرد الگوریتم های یادگیری ماشین در پیش بینی تصمیمات سیستم های قضایی،پنجمین کنفرانس ملی علوم انسانی و مطالعات مدیریت،تهران،

۹) سارنج, علیرضا, قدس, مجید, تهرانی, رضا. (۱۳۹۷). پیش‌بینی شاخص کل بورس اوراق بهادار تهران با استفاده از رویکرد ترکیبی الگوریتم های فراابتکاری، هوش مصنوعی و معادله پارامتریک موجک .*مهندسی مالی و مدیریت اوراق بهادار*، (۳۵) ۹، ۳۶۵-۳۹۱،

۱۰) عباسی‌نژاد حسین، ابراهیمی سجاد. اثر نوسان‌های قیمتی نفت بر بازده بورس اوراق بهادار تهران. فصلنامه پژوهش ها وسیاست های اقتصادی. ۱۳۹۲; ۲۱ (۶۸) :۱۰۸-۸۳

۱۱) مرادزاده فرد, مهدی. (۱۳۹۵). توانایی مدیریتی، کارآیی سرمایه گذاری و ریسک سقوط آتی قیمت سهام .*مطالعات تجربی حسابداری مالی*. ۱۳(۵۰)، ۳۳-۶۴.

۱۲) میرعلوی, سید حسین, پورزمانی, زهرا. (۱۳۹۸). ارائه مدلی جهت پیش‌بینی قیمت سهام با استفاده از روش‌های فرا ابتکاری و شبکه‌های عصبی .مهندسی مالی و مدیریت اوراق بهادار، ۱۰(۴۰)، ۵۷-۸۳.

13) Anderson, D., & McNeill, G. (1992). Artificial neural networks technology. Kaman Sciences Corporation, 258(6), 1-83.

14) Baek, Y., & Kim, H. Y. (2018). ModAugNet: A new forecasting framework for stock market index value with an overfitting prevention LSTM module and a prediction LSTM module. *Expert Systems with Applications, 113*, 457-480.
15) Das, S. R., Mishra, D., & Rout, M. (2019). Stock market prediction using Firefly algorithm with evolutionary framework optimized feature reduction for OSELM method. Expert Systems with Applications: X, 4, 100016.
16) D. Kumar, S.S. Meghwani, M. Thakur.,Proximal support vector machine based hybrid prediction models for trend forecasting in financial markets., J Comput Sci, 17 (2016), pp. 1-13
17) Jones, C. M., & Kaul, G. (1996). Oil and the stock markets. *The journal of Finance, 51*(2), 463-491.
18) Moghar, A., & Hamiche, M. (2020). Stock Market Prediction Using LSTM Recurrent Neural Network. Procedia computer science, 170, 1168-1173.
19) Sidra, M., , Jaydip, S., & Abhishek, D.(2020). Stock Price Prediction Using Machine Learning and LSTM-Based Deep Learning Models. International Journal of Business Forecasting and Marketing Intelligence
20) Simon S. Haykin.(1994)., Neural Networks, 2nd Edition., Prentice Hall PTRUpper Saddle River, NJUnited States
21) Wei, Y., Qin, S., Li, X., Zhu, S., & Wei, G. (2019). Oil price fluctuation, stock market and macroeconomic fundamentals: Evidence from China before and after the financial crisis. *Finance Research Letters, 30*, 23-29.
22) Zhang, X., Chen, Y., & Yang, J. Y. (2007). Stock Index Forecasting Using PSO Based Selective Neural Network Ensemble. Paper presented at the IC-AI.
23) Zhang, K., Zhong, G., Dong, J., Wang, S., & Wang, Y. (2019). Stock market prediction based on generative adversarial network. Procedia computer science, 147, 400-406

یادداشت‌ها :

1 Extreme Learning Machine
2 Online sequential extreme learning machine (OSELM)
3 particle swarm optimization
4 Baek, & Kim
5 Rekha Das et al
6 Wei et al
7 Moghar & Hamiche
8 Activation Function
9 Anderson et al
10 Extreme Learning Machine
11 Ding
12 Moghar

13 Rekha Das et al
14 heuristic
15 meta-heuristic
16 hyper heuristic
17 Zhang et al
18 Zhang et al
19 Structural vector autoregression
20 Generalized AutoRegressive Conditional Heteroskedasticity (GARCH)
21 Vector Autoregressive
22 Kumar et al
23 backpropagation (backprop, BP)
24 Zhang & et al
25 generative adversarial network
26 Long short-term memory
27 multilayer perceptron
28 Sidra et al
29 The NIFTY 50 is a benchmark Indian stock market index that represents the weighted average of 50 of the largest Indian companies listed on the National Stock Exchange.
30 Long-short term memory(LSTM)
31 Walk-forward Validation
32 Grid Searching
33 Excel
34 python
35 tgju.org
36 Tse.ir
37 Ding et al
38 sigmoid
39 Logestic function
40 Root Mean Square Error (RMSE)
41 Mean Absolute Error (MAE)
42 Mean Square Root Error(MSRE)
43 Mean Absolute Percentage Error(MAPE)
44 t_Student
45 root-mean-square error (RMSE)
46 Over fit