

ارزیابی پیش‌بینی پذیری قیمت سهام با استفاده از شبکه‌های عصبی فازی در بورس تهران

سید جلال صادقی شریف

استاد یار گروه مدیریت مالی دانشگاه شهید بهشتی

j_sadeghisharif@sbu.ac.ir

سجاد فرازمند

دانشجوی دکتری مدیریت مالی دانشگاه شهید بهشتی (نویسنده مسئول)

sajad.farazmand@gmail.com

فعالان بورس برای تصمیم‌گیری در بازارهای مالی و کسب حداکثر بازدهی نیازمند ابزارهای پیشرفته و کاربردی هستند تا با دقت مناسب به پیش‌بینی پردازند. در این راه ضروری است ارزیابی پیش‌بینی‌ها متناسب با حوزه‌ی مالی انجام شود. این مقاله برای دست‌یابی به این هدف قیمت سهام پنجاه شرکت بورس تهران را با استفاده از شبکه‌های عصبی فازی پیشخور مدل‌سازی کرده است. همچنین با استفاده از سیستم کنترل‌گر انفیس، مدل شبکه عصبی در هر تکرار کنترل می‌شود. برای انجام محاسبات از قیمت‌های روزانه سهام شرکت‌های بورسی از آذر ۱۳۸۴ تا آذر ۱۳۹۴ استفاده شده است. دقت پیش‌بینی‌ها نیز ابتدا بر مبنای چهار شاخص‌های معتبر آماری ارزیابی گردید. سپس با استفاده از روش نرخ برخورد، صحت پیش‌بینی‌ها ارزیابی شده است. نتایج نشان می‌دهد دقت پیش‌بینی شبکه‌های عصبی فازی بسیار بالاست؛ همچنین در برخی موارد با وجود اینکه پیش‌بینی مربوط به یک سهم دارای دقت بالاتری دارد، از صحت پایین‌تری برخوردار است؛ لذا بر آورد صحت پیش‌بینی‌ها در ارزیابی پیش‌بینی‌ها سهمی تأثیرگذار دارد؛ از این رو پیشنهاد می‌شود در انجام و ارزیابی مدل‌های پیش‌بینی علاوه بر توجه به خطاهای آماری مرسوم از روش‌های کیفی ارزیابی صحت پیش‌بینی‌ها نظیر معیار نرخ برخورد استفاده شود.

طبقه بندی JEL: G24; G15; C45; C32

واژه‌های کلیدی: شبکه‌های عصبی مصنوعی، پیش‌بینی، بازده قیمت سهام، بورس تهران

۱. مقدمه

اغلب پدیده‌های پیرامون انسان رفتارهایی غیرخطی دارند. شناسایی و پیش‌بینی این رفتارها نیازمند استفاده از روش‌های نوین پیش‌بینی و ارزیابی است. امروزه تکنیک‌های محاسباتی نرم^۱ به طور گسترده در مسائل پیش‌بینی به خصوص در بورس استفاده می‌شوند؛ زیرا ابزارهایی دقیق برای پیش‌بینی در محیط‌های مغتشش^۲ و رهگیری رفتارهای غیرخطی هستند (آتسالیکس و والاوانیس^۳، ۲۰۰۹). برای نمونه می‌توان به سیستم‌های هوشمند شبکه‌های عصبی (ANN)، سیستم‌های فازی و الگوریتم‌های ژنتیک (GA) اشاره کرد که در حوزه مسائل مالی دارای کاربرد فراوان هستند (آرمانو و همکاران^۴، ۲۰۰۴). شبکه‌های عصبی مصنوعی برای اهداف گوناگونی از جمله تشخیص الگو، کلاس‌بندی و بهینه‌سازی به کار گرفته شده‌اند. قابلیت آن‌ها برای نگاشت اطلاعات ورودی به خروجی با خطای قابل قبول، این مدل‌ها را به ابزارهایی مناسب در مدل‌سازی فرآیندها تبدیل کرده است (هسو و همکاران^۵، ۱۹۹۵).

شبکه‌های عصبی مصنوعی می‌توانند رفتارها را تشخیص دهند و خود را با پویایی‌های محیطی تطبیق دهند (ژانگ، سان و میزوتونی^۶، ۱۹۹۷). مرور مطالعات تجربی نشان می‌دهد برای ارزیابی روش‌های پیش‌بینی در حوزه مالی، اغلب از خطاهای آماری استفاده می‌شود. استفاده صرف از این روش‌ها موجب شده «اندازه‌گیری صحت پیش‌بینی‌ها» مورد غفلت واقع شود. یعنی به این مسئله کمتر توجه شده است که روش پیش‌بینی چه تعداد از پیش‌بینی‌ها درست عمل می‌کند و در چه تعداد از پیش‌بینی‌ها ناموفق است. این مسئله در حالی رخ می‌دهد که در حوزه مدیریت و مسائل

-
1. Soft computing techniques.
 2. Noisy
 3. Atsalakis & valavanis
 4. Armano & et al.
 5. Hsu et al.
 6. Jang, sun & mizutani.

مالی انجام پیش‌بینی‌های اشتباه آثار بلندمدت بسیاری به همراه دارد؛ در نتیجه ضروری است برای ارزیابی روش‌های پیش‌بینی در این حوزه صرفاً به معیارهای مورد استفاده در رشته‌های فنی معیارهایی نظیر: (MSE, RMSE, MAPE, ...) بسنده نشود بلکه کارایی آن‌ها با معیارهایی متناسب با حوزه مسائل مدیریتی و مالی ارزیابی شود؛ لذا در ادامه این مقاله تلاش می‌شود معیاری برای ارزیابی صحت پیش‌بینی‌ها معرفی شده و مورد استفاده قرار می‌گیرد و به این مسئله پرداخته شود که آیا برآورد صحت پیش‌بینی‌ها تأثیری بر ارزیابی پیش‌بینی‌ها دارد؟

۲. ادبیات تحقیق

بسیاری از تحلیلگران مالی، فعالان بورس و سرمایه‌گذاران متقاعد شده‌اند که می‌توان بازده قیمتی سهام در بورس را پیش‌بینی کرد و بر اساس آن سودآوری لازم را کسب کرد. برای دستیابی به این هدف مدل‌های بسیاری برای پیش‌بینی قیمت‌ها در بازار سرمایه ارائه شده است. بررسی مطالعات در این زمینه نشان می‌دهد که مدل‌های پیش‌بینی قیمت در حالت کلی به دو دسته تحلیل‌های بنیادی و تکنیکال (فنی) تقسیم می‌شوند (بلیک^۱، ۱۹۸۲). تحلیل بنیادی مبتنی بر متغیرهای کلان اقتصادی نظیر: نرخ تورم، عرضه پول، صادرات، اندازه شرکت، نسبت قیمت به سود سهام (P/E) و وضعیت مالی شرکت می‌باشند (باسو، ۱۹۷۷؛ کمپل، ۱۹۸۷؛ دورا و سی، ۲۰۰۲). در تحلیل‌های تکنیکال فرض بر این است که تاریخ تکرارپذیر است و همبستگی بین حجم معاملات و قیمت، می‌تواند رفتار بازار مشخص کند (اپس و اپس، ۱۹۷۶؛ مارتینلی و هایمن، ۱۹۹۸؛ ترینر و فرگوسن، ۱۹۸۵)^۲ و بر این اساس به امر پیش‌بینی می‌پردازند.

ابتدا مبانی نظری مرتبط با انتخاب متغیرهای ورودی تحقیق یعنی متغیرهای اساسی تأثیرگذار بر قیمت بررسی می‌شود. در این راه، رابطه بین متغیرهای کلان اقتصادی و بازارهای رقیب بورس

1. Black

2. Basu; Campbell; Dourra & Siy

3. Edwards & Magee; Epps & Epps; Martinelli & Hyman; Plummer; Treynor & Ferguson

را با قیمت، با توجه به نظریات مطرح در مکاتب اقتصادی بررسی می‌شود. متغیرهای مورد بررسی بر دو نوعند که عبارتند از:

الف) متغیرهای کلان اقتصادی مانند قیمت جهانی نفت؛

ب) قیمت دارایی‌های رقیب بازار سهام مانند نرخ ارز، قیمت طلا و موارد دیگر.

کنزین‌ها و پولیون در این موضوع که مردم در هنگام افزایش حجم پول چه نوع دارایی مالی را جانشین آن می‌سازند، اتفاق نظر ندارند. کنزین‌ها بر این عقیده دارند که معمولاً دارایی‌های شامل درآمد ثابت (مانند اوراق قرضه و خزانه) جانشین مناسبی برای پول هستند. به عبارتی، در رویکرد کنزین‌ها بازدهی همه دارایی‌ها مانند سهام، یکسان و بدون ریسک در نظر گرفته می‌شود. در مقابل، پولیون استدلال می‌کنند که افزایش حجم پول به طور مستقیم و بدون واسطه بر قیمت دارایی‌ها اثر خواهد گذاشت. افزایش در حجم پول، تعادل بین مانده پول واقعی و مانده پول مطلوب را برهم می‌زند. مازاد عرضه نیز موجب افزایش تقاضا در دامنه وسیعی از کالاها و خدمات از جمله دارایی‌های مالی می‌شود.

در اقتصادهای متکی به نفت و ارز حاصل از آن، تحولات نفتی می‌تواند یکی از عوامل مهم تأثیرگذار بر بخش‌های مختلف اقتصاد مانند بازار سرمایه محسوب شود. بنابراین، لزوم بررسی تأثیر تغییرات بازار نفت بر شاخص بازار سهام تلقی می‌شود. سودآوری برخی شرکت‌ها مستقیماً تحت تأثیر تغییرات قیمت نفت است. افزایش قیمت نفت، موجب شکل‌گیری انتظارات خوش‌بینانه در مورد رونق برخی فعالیت‌های اقتصادی مانند صنایع پتروشیمی، پالایشگاه و... شده است، همچنین بخش تولید کالاهای غیرقابل تجارت مانند خدمات و مسکن می‌شود.

تغییرات نرخ ارز نیز می‌تواند از دو جنبه بر شاخص قیمت سهام تأثیر بگذارد:

الف) درآمد شرکت‌های واردکننده و صادرکننده کالا و خدمات، ارتباط مستقیم با نرخ ارز دارد.
ب) قیمت ارز به عنوان یک دارایی رقیب در پرتفوی فعالان مالی بر تصمیم‌های آن‌ها درباره خرید و فروش سهام مؤثر است.

به عقیده تحلیلگران فنی کلیه متغیرهای اثرگذار بر قیمت، تأثیر خود را در قیمت‌های تاریخی نشان می‌دهند از این رو می‌توان آنها را به عنوان بهترین ورودی‌ها در نظر گرفت (بلیک^۱، ۱۹۸۲). در ادامه مرور مطالعات تجربی مرور می‌شود.

مطالعات تجربی بسیاری در زمینه پیش‌بینی بازارهای مالی کشورهای توسعه نیافته انجام شده است. نتایج این مطالعات نشان می‌دهد مدل‌ها به خوبی توانسته‌اند در بازارهای مالی کشورهای توسعه نیافته، قیمت‌ها را پیش‌بینی کنند. در مطالعه تجربی فرسون و هاروی^۲ (۱۹۹۳) هجده سهم از بازارهای بورس بین‌المللی در کشورهای توسعه یافته و توسعه نیافته بررسی شد؛ نتایج نشان می‌دهد پیش‌بینی در بازارهای نوظهور امکان‌پذیر است. مطالعه تجربی هاروی (۱۹۹۵) بر روی هشتصد سهم از بیست بازار نوظهور نشان داد که قابلیت پیش‌بینی در بازارهای نوظهور کشورهای توسعه نیافته در مقایسه با بازارهای توسعه یافته کشورهای پیشرفته، بیشتر است و اطلاعات محلی نقش مهمتری در پیش‌بینی بازارهای در حال ظهور نسبت به بازارهای توسعه یافته بازی می‌کند.

آرمانو، مارچسی و مورو^۳ (۲۰۰۴) یک سیستم ترکیبی عصبی-ژنتیکی برای پیش‌بینی روند روزانه شاخص S&P500 ایجاد کردند و دو سیستم پیش‌بینی زیر را مقایسه نمودند: سیستم XCS عصبی و شبکه عصبی مصنوعی بازگشتی. لین و همکاران^۴ (۲۰۰۲) مدلی عصبی فازی برای پیش‌بینی روند روزانه قیمت‌ها ایجاد کردند و عملکرد چهار مدل متفاوت را مقایسه کردند: مدل رگرسیون ((REG)، مدل M-گراف ((GM)، مدل شبکه عصبی و مدل عصبی فازی. فرناندر، رودریگز و همکاران^۵ (۲۰۰۰) و پرز، کروز و همکاران^۶ (۲۰۰۳) از سیستم شبکه عصبی برای پیش‌بینی روند قیمت سهام در بورس مادرید استفاده کردند.

1. Black
2. Ferson and Harvey.
3. Armano, Marchesi, and Murru.
4. Lin et al.
5. Fernandez-Rodriguez et al.
6. Perez-Cruz et al.

هاروی و همکاران^۱ (۲۰۰۰) و هالیدی^۲ (۲۰۰۴) شبکه‌ای عصبی برای پیش‌بینی جهت تغییرات قیمت در بورس نیویورک ایجاد کردند. آتسالیکس و والوانیس^۳ (۲۰۰۶) مدلی عصبی فازی برای اندازه‌گیری و پیش‌بینی جهت تغییرات قیمت در بورس آتن (ASE) ارائه کردند. خاشی و بیجاری^۴ (۲۰۱۰) مدل آریمما، شبکه‌های عصبی و مدل ترکیبی ژانگ را مقایسه کردند که نتایج حاصل برتری عملکرد مدل ترکیبی را نشان داد.

گارسن و همکاران^۵ (۲۰۱۱) کاربرد مدل‌های شبکه عصبی مصنوعی را پیش‌بینی شاخص نزدک بررسی کردند. آن‌ها مدل‌های DAN2، MLP و GARCH را با شاخص‌های آماری میانگین مجذور خطا و میانگین قدر مطلق خطا ارزیابی کردند که نتایج حاصل بیانگر برتری مدل‌های ساده MLP، برای پیش‌بینی تغییرات در بورس هستند. کلیک و اگرن^۶ (۲۰۱۴) مدل‌های پیش‌بینی مبتنی بر فرکانس بالا را برای یافتن بهترین مدل پیش‌بینی نوسان برتری با مدل‌های GARCH و MIDAS و HAR-RV-CJ مقایسه کردند. نتایج این تحقیق حاکی از برتری مدل‌های فرکانس بالا بوده است. شبکه عصبی مصنوعی با اتصال کارای محاسباتی (CEFLANN) نیز یکی از دستگاه‌های نوین انجام مدل‌سازی بازارهای مالی است که نتایج به مراتب بهتری نسبت به روش‌های کلاسیک دارد (داش و داش^۷، ۲۰۱۶).

نشاط و محلوجی (۱۳۸۸) با ارائه نمونه عملی فرآیند اسپری دراینگ، متدلوژی مدل‌سازی فرآیندها با استفاده سلسله مراتبی از تحلیل رگرسیونی و الگوریتم شبکه عصبی مصنوعی، با هدف کنترل پیش‌بینانه کیفیت، تشریح و پیاده‌سازی کردند. آن‌ها در نهایت سناریوهای مختلفی برای تنظیم ورودی‌های فرآیند توسط مدل عصبی-آماري فرآیند طراحی کردند که با استفاده از آن توانستند کنترل پیش‌بینانه را جایگزین روش‌های مبتنی بر سعی و خطا در کنترل فرآیند کنند.

1. Harvey et al.
2. Halliday
3. Atsalakis and Valavanis.
4. Khashei & Bijari
5. Guresen et al.
6. Çelik & Ergin
7. Dash & Dash.

رضانیان و همکاران (۱۳۹۰) نتایج چندین روش از جمله میانگین متحرک ساده، موزون، روند خطی، روند تابع ترکیبی و... را در پیش‌بینی قیمت نفت با نتایج شبکه‌های عصبی-فازی مقایسه کردند. محمد علی زاده و همکاران (۱۳۹۴) به پیش‌بینی سقوط بازار سهام با استفاده از شبکه‌های عصبی نگاشت خود سازمان ده پرداختند. نتایج اجرای مدل و پیش‌بینی برون‌نمونه‌ای حاکی از این است که مدل عملکرد به نسبت قابل قبولی را در پیش‌بینی دوره‌های پیش از سقوط در بازار سهام به دست آورده است.

مرور مطالعات مزبور و سایر مطالعات نشان می‌دهد برای ارزیابی روش‌های پیش‌بینی، پذیرش مقادیر پیش‌بینی، انتخاب قابل پیش‌بینی‌ترین سهام و تصمیم‌گیری‌ها، اغلب از معیارهای اندازه‌گیری خطای آماری استفاده می‌شوند. این معیارها تنها توصیف‌گر میزان دقت پیش‌بینی هستند درحالی‌که یکی از مهم‌ترین مسائل پیش‌بینی، اندازه‌گیری میزان موفقیت یا شکست روش پیش‌بینی است. بنابراین معیارهای مذکور برای ارزیابی روش‌های پیش‌بینی کافی به نظر نمی‌رسد، لذا معرفی و استفاده از معیارهایی نوین و ابتکاری برای ارزیابی نتایج پیش‌بینی‌ها که متناسب با معیارهای ذهنی فعالان بازار باشد، در کسب شناخت بهتر و ارزیابی مؤثرتر ضروری به نظر می‌رسد. نظر به اهمیت این موضوع در این مقاله تلاش می‌شود پس از مدل‌سازی و ارائه دقت پیش‌بینی‌ها نتایج حاصل با استفاده از معیاری نوین (نرخ برخورد) ارزیابی شود.

۳. روش شناسی پژوهش

۳-۱. شبکه‌های عصبی مصنوعی (ANN)


امروزه به موازات مدل‌های متداول قبلی، روش‌های جدیدتری نیز برای پیش‌بینی ابداع شده است. گونه‌ای از این روش‌ها که به شبکه‌های عصبی مصنوعی موسومند، مدل ساده شده‌ای از سیستم عصبی مرکزی انسان هستند. یک شبکه عصبی از نرون‌ها تشکیل شده است. نرون یا گره کوچک‌ترین واحد پردازش اطلاعات است که اساس عملکرد شبکه‌های عصبی را تشکیل می‌دهد

(منهاج، ۱۳۷۷). هر نرون در شبکه به عنوان مرکز پردازش و توزیع اطلاعات عمل می‌کند و ورودی و خروجی مخصوص به خود را دارد (وو و لو^۱، ۱۹۹۵).

میزان تأثیر q بر a به وسیله مقدار عدد w تعیین می‌شود. ورودی دیگر مقدار ثابت 1 است که در جمله b ضرب شده و سپس با wp جمع می‌شود. این حاصل جمع ورودی خالص برای تابع تبدیل یا فعال‌سازی f (محرک) است. به این ترتیب خروجی نرون به صورت رابطه 1 تعریف می‌شود:

$$a = f(wp + b) \quad (1)$$

پارامترهای w و b قابل تنظیم می‌باشند و تابع محرک نیز توسط طراح انتخاب می‌شود. بر اساس انتخاب f و نوع الگوریتم یادگیری، پارامترهای w و b تنظیم می‌شوند. در حقیقت، یادگیری به این معنا است که w و b به صورتی تغییر کنند که رابطه ورودی و خروجی نرون با هدف خاصی مطابقت نماید. عموماً یک نرون بیش از یک ورودی دارد. در شکل 1 مدل یک نرون با R ورودی نشان داده شده است.



شکل ۱. مدل چند ورودی یک نرون

عددهای P_i عناصر بردار ورودی می‌باشند و با ماتریس وزن w و جمله اریب b (ورودی خالص را به صورت رابطه ۲ تشکیل می‌دهند):

$$n = \sum_{i=1}^R p_i \cdot w_{1,i} + b = w\bar{p} + b \quad (2)$$

در نهایت خروجی نرون به صورت رابطه (۳) خواهد بود:

$$a = f(w\bar{p} + b) \quad (3)$$

در حال حاضر انواع مختلفی از شبکه‌های عصبی وجود دارند که برخی از آن‌ها دارای کاربرد بیشتری هستند. بررسی مطالعات تجربی بر استفاده از شبکه‌هایی نظیر شبکه پیشخور تأکید دارند. به عنوان نمونه یو و همکاران^۱ (۲۰۰۸) و محمدی و فرج زاده (۱۳۹۰) شبکه عصبی پیشخور را مناسب ارزیابی می‌کنند. بر این اساس این روش معرفی و بررسی خواهد شد. شکل زیر شبکه عصبی پیشخور را نشان می‌دهد (کارایانیس و ونتساناپولوس^۲، ۱۹۹۳). برای پیش‌بینی، شبکه عصبی فضای ورودی را که شامل مقادیر جاری و گذشته سری زمانی و یا سایر متغیرهای توضیحی $(X_1, \dots, X_i, \dots, X_n)$ می‌باشد، به فضای خروجی یا مقادیر پیش‌بینی (\hat{Y}) می‌نگارد. در این مطالعه خروجی شبکه عصبی که برای پیش‌بینی سری زمانی بازده قیمتی سهام به کار می‌رود عبارت است از:

$$\widehat{E}_t = f(E_{t-1}, E_{t-2}, \dots, E_{t-p}) \quad (4)$$

به طوری که \widehat{E}_t بعد بردار p و مقدار پیش‌بینی قیمت سهام در زمان ورودی یا تعداد وقفه‌هایی است که در مدل وارد شده است. رابطه فوق را به صورت زیر نیز می‌توان نشان داد:

$$f(EW) = f(\beta_0 + \sum_{j=1}^q K(E_{\gamma_j}) \beta_j) \quad (5)$$

برای بررسی پیش‌بینی‌های شبکه عصبی طراحی شده از سیستم انفیس به صورت زیر استفاده می‌شود.

1. Yu et al.
2. Karayiannis and Venetsanopoulos

۲-۳. کنترلگر CON-ANFIS

کنترلگر CON-ANFIS براساس تکنیک یادگیری معکوس^۱ آموزش می‌بیند و با نام "یادگیری عمومی"^۲ نیز شناخته می‌شود. در مرحله آموزش، برای مدل‌سازی اعمال معکوس فرآیند از تکنیک برون خطی^۳ استفاده می‌شود. در مرحله اجرا، نتایج مدل عصبی فازی معکوس فرآیند را ارائه می‌کند. مدل پیش‌بینی قیمت به طور عمومی به صورت زیر توصیف می‌شود.

$$y(k+n) = F(y(k), U) \quad (۶)$$

به طوری که نماد n نشان‌دهنده مرحله فرآیند، F نشان‌دهنده تابع مرکب از f است و نماد U نشان‌دهنده اعمال کنترلی از k تا $k+n-1$ است. بر اساس معادله (۶) می‌توان گفت چون ورودی U از k تا $k+n-1$ تغییر می‌کند، قیمت سهام از $y(k)$ تا $y(k+n)$ دقیقاً در n مرحله تغییر می‌کند به علاوه فرض می‌شود رفتارهای معکوس مدل فرآیند بازار بورس نیز وجود دارند. از این رو به صورت تابع U که متأثر از $y(k)$ و $y(k+n)$ می‌باشد قابل تعریف است:

$$U = G(y(k), y(k+n)) \quad (۷)$$

این معادله نشان می‌دهد دنباله یکنمایی برای ورودی‌ها وجود دارد که به همراه نگاشت G مشخص می‌شود و می‌تواند طی گذراندن n مرحله به قیمت سهام گرایش یابد. بنابراین ابتدا باید نگاشت معکوس G را بدست آورد. در این راه، کنترلگر انفیس قادر است با ۲ ورودی و n خروجی و استفاده از داده‌های آموزشی که از مجموعه $\{y(k), y(k+n), U\}$ به دست می‌آید، می‌تواند نگاشت معکوس G را تقریب بزند.

۳-۳. ساختار کنترلگر CON-ANFIS

این سیستم انفیس از طریق روش سوگنو مقداردهی اولیه را انجام می‌دهد. علت استفاده از مدل سوگنو، وجود پارامتر Π است که برای بدست آمدن تقریبی بهتر، اضافه شده است. مدل

1. Inverse learning technique
2. General learning
3. Off-line technique.

سوگنو با دو ورودی $y(k)$ و $y(k+1)$ و یک خروجی تعریف می‌شود. برای هر ورودی، پنج تابع گوسین ترکیبی^۱ مشابه به صورت خیلی کوچک، کوچک، متوسط، بزرگ و خیلی بزرگ تعریف می‌شود. خروجی مدل نهایی در هر دوره‌ی زمانی برای آموزش دوره بعدی مورد استفاده قرار می‌گیرد. ترکیب انفیس طراحی شده با مدل شبکه عصبی میزان تفاوت خروجی مورد انتظار با داده‌های واقعی را کنترل می‌نماید. همچنین برای آزمون تقویت، کلیه محاسبات با استفاده از مدل‌های شبکه عصبی شعاعی و رگرسیون بردار پشتیبان نیز انجام شده است.

۴. داده‌ها

نظر به این که افزایش تعداد داده‌ها در شبکه‌های عصبی مصنوعی موجب کسب نتایج دقیق‌تر می‌شود، لذا داده‌های روزانه قیمت سهام پنجاه شرکت عضو بورس اوراق بهادار در بازه زمانی ده ساله، از آذر سال ۱۳۸۴ تا اسفند سال ۱۳۹۴، استفاده خواهد شد. این شرکت‌ها از پنج گروه خودرو و ساخت قطعات، مواد و محصولات دارویی، سیمان، آهک و گچ، فلزات اساسی و سرمایه‌گذاری استخراج شده و بر اساس مطالعه گارسن و همکاران^۲ (۲۰۱۱) قیمت چهار روز گذشته هر سهم به عنوان ورودی انتخاب شد. با توجه به وجود خاصیت «تخمین زننده عمومی»^۳ برای شبکه‌های عصبی محدودیتی در انتخاب تابع مورد برآورد (شرکت‌های انتخاب شده) وجود ندارد (چن و همکاران^۴، ۲۰۰۳).

برای کسب نتایج مناسب و تعدیل اثر رویدادهایی نظیر افزایش سرمایه و... از آمار سایت شرکت خدمات فناوری بورس تهران و نرم‌افزار شرکت ره‌آوردنویین برای جمع‌آوری داده‌ها استفاده شد. از بین داده‌های مذکور ۸۰ درصد آن‌ها برای آموزش شبکه و ۲۰ درصد برای آزمایش شبکه آموزش دیده به کار گرفته شد. بر اساس مطالعه شانکر و همکاران^۵ (۱۹۹۶) و

1. Gaussian Membership Functions.
2. Guresen et al.
3. Universal approximator
4. Chen et al.
5. Shanker et al.

پرینسیپ و همکاران^۱ (۱۹۹۹) نرمال‌سازی داده‌ها موجب بهبود عملکرد شبکه‌های عصبی می‌شود، بنابراین در این تحقیق کلیه داده‌ها اعم از داده‌های آموزش و آزمایش نرمال‌سازی شده‌اند. بدین منظور ابتدا داده‌ها با استفاده از رابطه (۸) نرمال‌سازی می‌شوند. استفاده از این رابطه نرمال‌سازی کلیه داده‌ها را به بازه -۱ تا +۱ می‌نگارد.

$$x_n = 2 \cdot \frac{x - \min(x)}{\max(x) - \min(x)} - 1 \quad (8)$$

پس از اجرای مراحل آموزش و آزمایش شبکه برای گزارش مقادیر واقعی (نه اعداد نرمالیزه) باید فرایند پس‌پردازش^۲ بر روی کلیه خروجی انجام شود که طی آن کلیه خروجی‌ها از مقادیر نرمال به واقعی تبدیل می‌شوند. برای انجام مراحل آموزش، آزمایش و ارزیابی شبکه‌های عصبی مصنوعی همچنین انجام فرایند پیش‌پردازش و پس‌پردازش از نرم‌افزار Matlab R2016 استفاده شد.

۵. ارزیابی

در این بخش ابتدا «صحت پیش‌بینی» شبکه‌های عصبی با استفاده از نرخ برخورد^۳ محاسبه و ارائه شده است. سپس نتایج حاصل با ده روش پیش‌بینی دیگر مقایسه می‌شود. برای خلاصه‌سازی و ارائه نتایج کلیه نتایج در قالب پنج گروه خودرو و ساخت قطعات، مواد و محصولات دارویی، سیمان، آهک و گچ، محصولات شیمیایی و فلزات اساسی ارائه می‌شود. برای بررسی دقت پیش‌بینی نیز از خطاهای آماری استفاده می‌شود. داده‌های مورد استفاده در بخش ارزیابی، داده‌های آزمایش^۴ هستند که در مراحل آموزش مدل حضور نداشته‌اند.

ابتدا به محاسبه نرخ برخورد می‌پردازیم. برای محاسبه نرخ برخورد از رابطه (۹) استفاده می‌شود:

$$\text{Hit Rate} = \frac{h}{n} \quad (9)$$

1. Principe et al.
2. Postprocessing
3. Hit rate
4. Test Data

که در آن h نشانگر تعداد پیش‌بینی‌های صحیح روند قیمت و n تعداد آزمایش‌ها است. بر اساس مطالعه آتسالیکیس (۲۰۰۹) می‌توان صحت پیش‌بینی را با استفاده از نرخ برخورد ارزیابی کرد. جدول ۱ نتایج حاصل را نشان می‌دهد:

جدول ۱. دقت پیش‌بینی بر حسب نرخ برخورد

سرمایه‌گذاری	فلزات اساسی	سیمان، آهک و گچ	مواد و محصولات دارویی	خودرو و ساخت قطعات	
۷/۵۵	۹/۵۹	۹/۵۸	۲/۵۹	۶/۵۶	شبکه عصبی پیشخور
۵/۵۲	۵۵	۷/۵۷	۴/۴۵	۷/۵۰	شبکه عصبی شعاعی
۸/۵۳	۲/۵۵	۸/۵۶	۹/۴۸	۵/۵۱	مدل عصبی فازی

مأخذ: نتایج تحقیق

در ادامه میزان صحت پیش‌بینی بازده قیمتی سهام با سایر روش‌ها مقایسه می‌شود. هدف اصلی این است که میزان صحت تکنیک‌های گوناگون برای پیش‌بینی بازده قیمتی سهام در بورس مشخص شود. نتایج کمی جدول ۲ ارائه شده‌اند.

جدول ۲. بررسی تطبیقی نتایج

نتایج تحقیق	مدل	نرخ برخورد (%)
پرز کروز و همکاران (۲۰۰۳)	MLP	۵۷
لندسی و همکاران (۲۰۰۰)	RBFN	۵۷
داسکن و همکاران (۲۰۰۵)	M-FIS	۵۳
داسکن و همکاران (۲۰۰۵)	TS-FIS	۵۶
هالیدی (۲۰۰۴)	NN	۵۵
آتسالیکیس (۲۰۰۶)	ATS-Anfis	۶۰
نتایج کمی این مطالعه	ANN-RBF-ANFIS	۵۹/۹

مأخذ: نتایج مطالعات تجربی

با توجه به جدول، نرخ برخورد روش‌های خطی و غیر خطی ذکر شده در بازه ۴۵/۴ تا ۵۹/۹ درصد هستند. بالاترین درصدهای بدست آمده مربوط به مدل‌های شبکه عصبی پیشخور است. در بخش بعدی مدل‌های پیش‌بینی بر اساس معیارهای مرسوم اندازه‌گیری خطای آماری بررسی می‌شوند. نتایج پیش‌بینی مربوط به شرکت‌های مورد بررسی بر اساس ریشه میانگین مجذور خط، میانگین مجذور خطا و میانگین قدرمطلق خطا ارائه در جداول ۳ تا ۵ ارائه شده است.^۱ جدول ۳. نتایج پیش‌بینی بر اساس خطاهای آماری مدل شبکه عصبی پیشخور

سرمایه‌گذاری	فلزات اساسی	سیمان، آهک و گچ	مواد و محصولات دارویی	خودرو و ساخت قطعات	
۹۱/۱۲۰۱	۸۱/۱۱۵۶۶	۲۶/۷۸۳۵۹۷۰	۸۵/۱۸۴۱۹	۴۵/۱۳۲۹	MSE
۵۸/۲۷	۵/۹۹	۷۸/۹۶۵	۱۲/۱۱۶	۰۱/۳۴	RMSE
۶۵/۱۴	۰۱/۵۱	۴۴/۹۱۰	۵/۵۰	۵۱/۱۶	MAE
۴۹/۲۳۸۷	۲۲/۶۳۹	۲۱/۴۱۴	۹۵/۱۴۷۴	۸۹/۶۶۱	MAPE

مأخذ: نتایج تحقیق

جدول ۴. نتایج پیش‌بینی بر اساس خطاهای آماری مدل شبکه عصبی شعاعی

سرمایه‌گذاری	فلزات اساسی	سیمان، آهک و گچ	مواد و محصولات دارویی	خودرو و ساخت قطعات	
۸/۱۰۶۲۲۱۹	۴۷/۶۸۵۲۲۹۴	۵۶/۲۵۲۵۲۹۹	۰۶/۴۸۵۶۱۹۹۲	۷۲/۹۴۶۸۵۵	MSE
۷۵/۹۳۵	۳۷/۲۲۶۳	۱۷/۱۳۹۲	۳۴/۶۲۵۰	۰۶/۸۵۸	RMSE
۳۹/۸۵۴	۸۹/۲۰۱۴	۹۱/۱۲۴۳	۹۲/۵۵۷۴	۸۲/۷۸۷	MAE
۲۹/۴	۹۲/۶	۲/۱۴	۳۷/۲	۴۰۹۹	MAPE

مأخذ: نتایج تحقیق

۱. رابطه مورد استفاده برای محاسبه ریشه میانگین مجذور خطا (RMSE)، میانگین مجذور خطا (MSE) و میانگین قدرمطلق خطا (MAE) به صورت زیر است:


$$RMSE = \sqrt{\frac{\sum_{t=1}^N e_t^2}{N}} \quad MSE = \frac{1}{N} \cdot \sum_{t=1}^N e_t^2 \quad MAE = \frac{1}{N} \cdot \sum_{t=1}^N |e_t| \quad MAPE = \frac{1}{N} \cdot \sum_{t=1}^N \frac{e_t}{y_t}$$

جدول ۵. نتایج پیش‌بینی بر اساس خطاهای آماری مدل عصبی- فازی

سرمايه‌گذاري	فلزات اساسي	سیمان، آهک و گچ	مواد و محصولات دارويي	خودرو و ساخت قطعات	
۹۱/۱۹۳۷۴	۱۹/۶۱۸۹۸	۷/۳۲۱۳۵۸۵	۷/۵۰۴۴۲۵۷۳۷۶	۴۹/۵۸۷۹۳	MSE
۹۲/۱۰۹	۶۶/۱۷۳	۷/۷۴۷	۲۶/۲۳۲۱۱	۹۷/۱۵۴	RMSE
۳۷/۷۹	۵۹/۹۱	۲۱/۳۳۸	۰۹/۱۵۲۶۵	۳۷/۱۲۲	MAE
۹۸/۰	۱	۰۳/۱	۰۶/۲	۹۵/۰	MAPE

مأخذ: نتایج تحقیق

مقایسه نتایج پیش‌بینی و واقعی صنعت سیمان، آهک و گچ برای نمونه در نمودار ۱ ارائه شده است.



نمودار ۱. مقایسه مقادیر واقعی و پیش‌بینی گروه سیمان، آهک و گچ

تأکید می‌شود کلیه اعداد ارائه شده در جداول بالا نرمال نیستند، بنابراین این ارقام منعکس‌کننده مقادیر واقعی خطا هستند که پس از اجرای فرایند پس‌پردازش بدست آمده‌اند. بر اساس جداول (۳) تا (۵) کمترین خطای پیش‌بینی میان مدل‌های پیش‌بینی، مربوط به شبکه عصبی مصنوعی پیش‌خور (به غیر از صنعت سیمان، آهک و گچ) است. لیونگ و همکاران^۱ (۲۰۰۰) و آتسالیکیس و والاوانیس (۲۰۰۹) نیز نتایج مشابهی را ارائه کرده‌اند. این موضوع تأکید مجددی است بر اینکه خواه پیش‌بینی مدل‌ها درست باشد یا نباشد، باید از طریق شاخص‌های خطای آماری نیز در مورد عملکرد سیستم قضاوت شود.

1. Leung et al.

۶. نتیجه‌گیری و پیشنهادات

بررسی مطالعات تجربی در بازارهای بورس جهان نشان می‌دهد که شبکه‌های عصبی مصنوعی یکی از برترین تکنیک‌هایی هستند که با هدف ارائه پیش‌بینی بهتر و کاهش تورش در تصمیم‌گیری‌ها به کار گرفته می‌شوند. از این رو ابتدا برای آشنایی با این روش، مدل‌های شبکه عصبی مصنوعی به صورت مفهومی و تکنیکی توصیف و ارائه گردید.

بیان شد که این مدل‌ها با تغییر در شرایط واقعی، توانایی یادگیری و اعمال تعدیل وضعیت خود را دارا هستند؛ از این رو می‌توانند با استفاده از داده‌های تاریخی، بازده قیمتی سهام را پیش‌بینی کنند سپس با استفاده از این روش و نرم‌افزار متلب پیش‌بینی‌های حاصل از شبکه عصبی مصنوعی ارائه گردید و نشان داده شد که شبکه‌های عصبی در ارائه پیش‌بینی بازده قیمتی سهام در بورس تهران دقت بسیار بالایی دارند، سپس نشان داده شد که توجه به دقت پیش‌بینی به عنوان تنها معیار مقایسه روش‌های پیش‌بینی کافی نیست، زیرا یکی از مهم‌ترین مسائل در پیش‌بینی، اندازه‌گیری میزان موفقیت یا شکست مدل‌ها در پیش‌بینی است. بر این اساس صحت پیش‌بینی بازده قیمتی سهام در بورس تهران به کمک معیار نرخ برخورد بررسی شد. نتایج نشان می‌دهد در برخی موارد با وجود اینکه پیش‌بینی مربوط به یک سهم دارای دقت بالاتری است از صحت پایین‌تری برخوردار است، لذا برآورد میزان صحت پیش‌بینی‌ها در ارزیابی آن‌ها سهمی تأثیرگذار دارد.

بنابراین پیشنهاد می‌شود در ارزیابی مدل‌های پیش‌بینی علاوه بر توجه به خطاهای آماری به معیارهای نوین ارزیابی از جمله معیارهای اندازه‌گیری صحت پیش‌بینی‌ها نیز توجه شود و در ارزیابی مدل‌ها، ارزیابی نتایج پیش‌بینی و انتخاب قابل پیش‌بینی‌ترین سهم مورد استفاده قرار گیرند. همچنین می‌توان نتایج حاصل از این تحقیق را با استفاده از روش‌های محاسباتی نرم دیگر مانند الگوریتم ژنتیک، الگوریتم مورچگان، الگوریتم زنبور عسل و... بررسی کرد.

منابع

- رمضانیان، محمد رحیم؛ رمضانپور، اسماعیل و سید حامد پوربخش (۱۳۹۰)، "رویکردهای جدید در پیش‌بینی با استفاده از شبکه‌های عصبی-فازی: قیمت نفت"، فصلنامه مدرس علوم انسانی - پژوهش‌های مدیریت در ایران، دوره پانزدهم، شماره ۳، صص ۱۴۹-۱۶۹.
- فرج‌زاده، زکریا و حمید محمدی (۱۳۹۰)، "کاربرد شبکه عصبی و ARIMA در پیش‌بینی قیمت گازوئیل"، فصلنامه پژوهش‌ها و سیاست‌های اقتصاد، سال نوزدهم، شماره ۵۹، صص ۲۰۱-۲۲۲.
- محمد علی زاده، آرش؛ راعی، رضا و شاپور محمدی (۱۳۹۴)؛ "پیش‌بینی سقوط بازار سهام با استفاده از شبکه‌های عصبی نگاشت خود سازمان ده"، مجله تحقیقات مالی، دوره ۱۷، شماره ۱، بهار و تابستان ۱۳۹۴، صفحه ۱۵۹-۱۷۸.
- منهاج، محمد باقر (۱۳۷۷)، "مبانی شبکه‌های عصبی (هوش محاسباتی)"، تهران: نشر دکتر حسایی.
- نشاط، نجمه و هاشم محلولجی (۱۳۸۸)؛ "کنترل پیش‌بینانه کیفیت با استفاده از شبکه‌های عصبی مصنوعی (ANFIS) و روش ترکیبی تحلیل رگرسیون و ANNs"، نشریه مدیریت صنعتی، دوره ۱، شماره ۳، پاییز و زمستان ۱۳۸۸، از صص ۱۵۳-۱۷۰.

Armano, M. Marchesi and A. Murru (2004), "A Hybrid Genetic-neural Architecture for Stock Indexes Forecasting", *Information Sciences*, 170(12), pp. 333.

Atsalakis, G.S. and K.P. Valavanis (2009b), "Forecasting Stock Market Short Term Trends Using a Neuro-Fuzzy Based Methodology", *Expert Systems with Applications*, 36(3), pp. 10696-10707.

Atsalakis, G. and K. Valavanis (2006), "Neuro-Fuzzy and Technical Analysis for Stock Prediction", *Working paper*. Technical University of Crete.

Basu, S. (1977), "The Investment Performance of Common Stocks In Relation To Their Price-Earnings Ratios: A Test of the Efficient Market Hypothesis", *Journal of Finance*, No. 32, pp. 663-682.

Black, F. (1982), "The Trouble with Econometrics Models", *Financial Analysis Journal*, 4(5), pp. 75-87.

Campbell, J. (1987), "Stock Returns and the Term Structure", *Journal of Financial Economics*, No. 18, pp. 373-399.

Çelik, S. and H. Ergin (2014), "Volatility Forecasting Using High Frequency Data: Evidence From Stock Markets", *Economic Modelling*, No. 36, pp. 176-190.

Chen, A.; Leung, M. T. and D. Hazem (2003), "Application of Neural Networks to An Emerging Financial Market: Forecasting and Trading The Taiwan Stock Index", *Computers and Operations Research*, No. 30, pp. 901923.

- Dash, R. and P. Dash** (2016), "A Hybrid Stock Trading Framework Integrating Technical Analysis with Machine Learning Techniques", *The Journal of Finance and Data Science*. Accepted & unpublished.
- Doerken, B.; Abraham, A.; Thomas, J. and M. Paprzycki** (2005), "Real Stock Trading Using Soft Computing Models", *In Proceedings of International Symposium on Information Technology: Coding and Computing ITCC*, Vol. 2, pp. 162–167.
- Dourra, H. and P. Siy** (2002), "Investment Using Technical Analysis and Fuzzy Logic", *Fuzzy Sets and Systems*, No. 127, pp. 221–240.
- Epps, T. and M. Epps** (1976), "The Stochastic Dependence of Security Price Changes and Transactions Volumes: Implications for the Mixture of Distribution Hypothesis", *Econometrica*, No. 44, pp. 305–321.
- Fernandez-Rodriguez, F.; Gonzalez-Martel, C. and S. Sosvilla-Rivebo** (2000), "On The Profitability Of Technical Trading Rules Based On Artificial Neural Networks: Evidence From The Madrid Stock Market", *Economics Letters*, No. 69, pp. 89–94.
- Ferson, W. and C. Harvey** (1993), "The Risk and Predictability of International Equity Returns", *Review of Financial Studies*, No. 6, pp. 527–566.
- Guresen, E. and Kayakutlu, G. and T., U. Daim** (2011), "Using Artificial Neural Network Models Iin Stock Market Index Prediction", *Expert Systems with Applications*, No. 38, pp. 10389–10397.
- Halliday, R.** (2004), "Equity Trend Prediction with Neural Networks", *Research Letters in the Information and Mathematical Sciences*, No. 6, pp. 135–149.
- Harvey, C.R.** (1995), "Predictable Risk and Returns in Emerging Markets", *Review of Financial Studies*, No. 8, pp. 773–816.
- Harvey, C.; Travens, K. and M. Costa** (2000), "Forecasting Emerging Market Returns Using Neural Networks", *Emerging Markets Quarterly*, 4(2) , pp. 43–55.
- Hsu, k.L.; Gupta, H.V. and S. Sorooshnian** (1995), "Artificial Neural Networks Modeling of Rainfall Runoff Process", *Water Resources Research*, 31(10) , pp. 2517-2530.
- Jang, J.; Sun, C. and E. Mizutani** (1997), "Neuro-Fuzzy and Soft Computing: a Computational Approach to Learning and Machine Intelligence", Prentice-Hall, NJ.
- Karayiannis, N.B. and A.N. Venetsanopoulos** (1993), "Artificial Neural Networks: Learning Algorithms", *Performance Evaluation and Applications*, Kluwer Academic Publishers, Boston, USA.
- Khashei, M. and M. Bijari** (2010), "An Artificial Neural Network (P, D,Q) Model for Time Series Forecasting", *Expert Systems with Applications*, 37(1) , pp. 479–489.
- Lendasse, E.; Bodt, D.; Wertz, V. and M. Verleysen** (2000), "Non-Linear Financial Time Series Forecasting Application to the Bel 20 Stock Market Index", *European Journal of Economical and Social Systems*, 14 (1) , pp. 81–91.
- Leung, M.T.; Daouk, H. and A. Chen** (2000), "Forecasting Stock Indices: a Comparison of Classification and Level Estimation Models", *International Journal of Forecasting*, No. 16, pp. 173–190.
- Lin, C.; Khan, H. and Huang, C.** (2002), "Can The Neuro Fuzzy Model Predict Stock Indexes Better Than Its Rivals?", *Discussion Papers of University of Tokyo CIRJE-F-165*.

- Martinelli, R. and B. Hyman** (1998), "Cup-With-Handle and the Computerized Approach", *Technical Analysis of Stocks and Commodities*, 16(10), pp. 63–76.
- Perez-Cruz, F.; Rodriguez, J-A. and J. Giner** (2003), "Estimating Garch Models Using Support Vector Machines", *Quantitative Finance*, No. 3, pp. 1–10.
- Principe, J.C.; Euliano, N. R. and W.C. Lefebvre** (1999), *Neural and Adaptive Systems: Fundamentals Through Simulations*, New York, USA: John Wiley & Sons.
- Shanker, M.; Hu, M.Y. and M. S. Hung** (1996), "Effect of Data Standardization on Neural Network Training", *Omega*, No. 24, pp. 385-397.
- Treynor, J. and R. Ferguson** (1985), "In Defense of Technical Analysis", *Journal of Finance*, XL, pp. 757–775.
- Wu, S. I. and R.P. Lu** (1995), "Combining Artificial Neural Networks and Statistics for Stock-Market Forecasting", PP. 257-264.
- Yu, L.; Wang, S. and K.K. Lai** (2008), "Forecasting Crude Oil Price with an Emd-Based Neural Network Ensemble Learning Paradigm", *Energy Economics*, Vol. 30, PP. 2623–2635.