

تحلیل آشوب، تجزیه موجک و شبکه عصبی در پیش بینی شاخص بورس تهران

حسین عباسی نژاد^۱

اسماعیل نادری^۲

تاریخ دریافت: ۱۳۹۱/۰۴/۲۴

تاریخ پذیرش: ۱۳۹۱/۰۸/۲۲

چکیده

این مطالعه برای پیش بینی بازدهی شاخص قیمت و بازده نقدی بورس اوراق بهادار تهران، آشوب را تحلیل و پیش بینی پذیری را بررسی کرده و نیز عملکرد انواع مدل های شبکه عصبی را با کمک داده های تجزیه شده با روش موجک ارزیابی کرده است. به همین منظور، از داده های سری زمانی روزانه و سری بازدهی شاخص قیمت و بازده نقدی بورس طی دوره زمانی ۵ فروردین ۱۳۸۸ تا ۱۸ اردیبهشت ۱۳۹۱ استفاده شده است. براساس نتایج این مطالعه، سری بازدهی بورس در دوره بررسی شده، پیش بینی پذیر بوده و آثار غیرخطی معین و آشوبی داشته است. همچنین برطبق معکوس آماره حداکثر نمای لیاپانوف، تعداد روزهای پیش بینی پذیر در این مطالعه، ۳۱ روز به دست آمد. یافته دیگر این پژوهش نیز به برتری عملکرد مدل های شبکه عصبی چندلایه پیش خور (MFNN) و شبکه عصبی فازی (ANFIS) مبتنی بر داده های تجزیه شده به کمک تجزیه موجک در مقابل به کارگیری سطح داده ها دلالت دارد. در این بین نیز برتری با مدل شبکه عصبی چندلایه پیش خور بوده است.

واژگان کلیدی: پیش بینی، بورس، تحلیل آشوب، تجزیه موجک، مدل های شبکه عصبی.

JEL: G14, G17, C22, C45, C60.

۱. مقدمه

امروزه اهمیت پیش بینی و منافع حاصل از آن، برای تصمیم گیری و سیاست گذاری از ابعاد مختلف، بر کسی پوشیده نیست. در سال های اخیر، مدل های ساختاری که در تبیین وضع موجود به طور نسبی موفق بوده اند، سابقه چندان موفقیتی در زمینه پیش بینی نداشته اند. در این میان، در قیاس با این مدل ها، رویکرد اقتصاددانان به مدل های تک متغیره سری زمانی در زمینه پیش بینی گسترش یافته است. این در حالی است که مبنای نظری قابلیت پیش بینی پذیری قیمت انواع دارایی ها، به طور سنتی در گرو نپذیرفتن «فرضیه بازار کارا»^۳

۱. استاد دانشکده اقتصاد دانشگاه تهران، Email: Habasi@ut.ac.ir

۲. دانشجوی کارشناسی ارشد اقتصاد دانشگاه تهران، Email: Naderi.ec@ut.ac.ir

درباره بازارها و نحوه قیمت‌گذاری آنهاست (اوزر و ارتوکاتلی، ۲۰۱۰).^۱ برای بررسی فرضیه بازار کارا، در بورس اوراق بهادار تهران، از روش‌های متعددی استفاده شده است که بعضی از آنها، مانند مطالعه سلیمی‌فر و شیرزور (۱۳۸۹)، این فرضیه را تأیید کرده‌اند و بعضی دیگر مانند، راسخی و خانعلی‌پور (۱۳۸۸)، تهرانی و همکاران (۱۳۸۷)، مشیری و مروت (۱۳۸۴) و مطالعه مشیری و فروتن، (۱۳۸۳)، آن را رد کرده‌اند. نبودن تقارن در نتایج مطالعات صورت گرفته را می‌توان ناشی از متفاوت بودن روش‌هایی دانست که آنها استفاده کرده‌اند (بارنت و سرلیتس، ۲۰۰۰).^۲ بر این اساس، آزمون‌های قدرتمند آشوبی که مبتنی بر نظریه آشوب‌اند، پاسخی مناسب به این بی‌تقارنی می‌باشد. ازسویی، براساس نظریه آشوب و ازسوی دیگر، بر پایه ایرادهای وارد شده بر فرضیه بازارهای کارا، فرضیه بازارهای فرکتال^۳ مطرح گردید که در بازارهای آشوب‌گونه صادق است (روویو و همکاران، ۲۰۰۲).^۴

بنابراین، براساس نظریه آشوب، نگرشی جدید، یعنی فرضیه بازارهای فرکتال مطرح شد. این فرضیه برای توضیح پدیده‌های بازارهای مالی درمقابل فرضیه بازارهای کاراست. اطمینان‌یافتن از برقراری فرضیه بازارهای فرکتال در گرو اجرای آزمون حداکثر نمای لیاپانوف و بررسی معکوس حداکثر نمای لیاپانوف به‌دست آمده است. گفتنی است آزمون حداکثر نمای لیاپانوف برای اطمینان از پیش‌بینی‌پذیر بودن سری بررسی شده براساس مدل‌های غیرخطی و بررسی معکوس حداکثر نمای لیاپانوف به‌دست آمده برای تعیین زمان پیش‌بینی‌پذیر است.

همچنین نکته مهم آن است که در صورت تأیید آشوبی بودن رفتار یک‌سری در دوره بررسی شده، دیگر نمی‌توان براساس مدل‌های خطی آنها را مدل‌سازی و پیش‌بینی کرد. به بیان دیگر، مدل‌های خطی نتایج خوبی ندارند.

۲. مروری بر مبانی نظری و پیشینه تحقیق

آشوب در لغت به معنای هرج و مرج، درهم‌ریختگی، شلوغی، آشفتگی و بی‌نظمی آمده است. در مباحث فلسفی نیز این واژه به وضعیتی اطلاق می‌شود که در آن، تصادف حکم فرمات. همچنین در مباحث نظری، آن را به معنای نظم موجود در بی‌نظمی توصیف کرده‌اند و عمدتاً از شناخت رموز و قوانین موجود در

1. Gökhan Özer & Cengiz Ertokatli

2. Barrent and Serletis

۳. این فرضیه بیانگر بازاری متشکل از سرمایه‌گذاران فراوان و با افق سرمایه‌گذاری مختلف است. مجموعه اطلاعات مهم برای هریک از افق‌ها نیز متفاوت است؛ از این رو تا زمانی که بازار ساختار فرکتال‌گونه خود را حفظ کند، بدون در نظر گرفتن مقیاس زمانی آن‌ها، باثبات باقی خواهند ماند؛ باین‌حال هنگامی که افق‌های زمانی سرمایه‌گذاران بازار یکسان و یکنواخت شود، بازار ناپایدار خواهد شد؛ زیرا افراد براساس مجموعه اطلاعات یکسانی معامله خواهند کرد.

4. Rubio & et al

طبیعت نشت گرفته است. تعابیر بسیاری به‌منظور تفهیم هرچه بیشتر آشوب به کار رفته است، برای نمونه اگر به شکل دود سیگار توجه کنیم، ابتدا دود حلقه‌های منظمی را تشکیل داده و سپس این جریان رو به بالا، به آشفته‌گی و بی‌نظمی میل می‌کند.

نکته درخور توجه آنکه رفتار آشوب‌گونه، رفتاری تصادف‌گونه نیست، بلکه رفتاری قطعی است؛ اما از دیدگاه ناظری که از ساختار و عملکرد مولد سیگنال آشوب‌گونه بی‌اطلاع است یا اطلاع عمیقی از آن ندارد، نمی‌توان این سیگنال را از سیگنالی واقعاً تصادفی بازشناخت و با استفاده از آزمون‌های آماری کاملاً تفکیک کرد.

بنابراین با توجه به قطعیت‌نداشتن ناشی از معین و محدود بودن دقت اندازه‌گیری مقادیر لحظه‌ای سیگنال‌ها، حتی با دانستن منابع تولید سیگنال‌های آشوبی، مقادیر آتی آنها با دقتی محاسبه و پیش‌بینی می‌شود که دائماً به‌صورت نمایی در حال کاهش است. با این تفاسیر، سیستم‌های آشوبی را می‌توان سیستم‌های دینامیکی غیرخطی دانست که اول، حساسیت بسیاری به وضعیت نخست داشته؛ دوم، جذب‌کننده‌های عجیب و پیچیده‌ای دارند و سوم، شکستگی‌های ناگهانی ساختاری در مسیر زمانی آنها به‌خوبی رؤیت می‌شود (پروخورف، ۲۰۰۸)؛^۲ با این حال برای درک عمیق‌تر شالوده این گونه سیستم‌ها ذکر دو نکته اساسی است:

۱. اگرچه این سیستم‌ها ظاهری تصادفی دارند، رفتارشان معین و قطعی است. به این معنا که به‌رغم قوانین و معادلات قطعی و معین که منابع ایجاد آشوب و نیز کل رفتار این گونه سیستم‌ها بر پایه آنها استوار است، به‌علت به‌کارگیری اندازه‌گیری برای مدل‌سازی چنین رفتاری، مطمئناً قطعیت و تقریب‌نداشتن، هرچند کوچک، ایجاد خواهد شد.^۳

۲. اگرچه این قطعیت‌نداشتن بسیار ناچیز است، برای مثال 10^{-6} واحد، قرار گرفتن این مقادیر ناچیز به‌عنوان «مقادیر نخست»^۴ سیستم آشوبی، با توجه به اینکه این سیستم‌ها حساسیت بسیاری به وضعیت نخست دارند، موجبات قبض و بسط این اختلالات هرچند کوچک در طی زمان را فراهم می‌کند. درنتیجه، اختلاف مقادیر اندازه‌گیری‌شده با مقادیر محاسبه‌شده، به‌تدریج افزایش خواهد یافت. این تفاوت در زمان‌های بلندمدت، به مقادیر بزرگ‌تری منتهی می‌شود؛ بنابراین نتایج مدل‌سازی‌ها و پیش‌بینی‌های

۱. مسیرهای زمانی همه سری‌های پویای پایدار اعم از معمولی یا آشوبی، حدی دارند که به آن تعادل یا جذب‌کننده می‌گویند.

2. Prokhorov

۳. این قطعیت‌نداشتن ناشی از خطای اندازه‌گیری در انسان‌ها، حتی با به‌کارگیری رایانه‌های بسیار پیشرفته نیز برطرف نخواهد شد.

4. Initial Value

رایانه‌ای، حتی نزدیک به مقدار واقعی نیست. بر این اساس رفتار سیستم، ظاهری تصادف گونه داشته و در بلندمدت پیش‌بینی‌ناپذیر خواهد شد (ویلیامز، ۲۰۰۵).^۱

ازسویی، پویایی اجزاء اختلال در هر فرآیند آشوبی، تشخیص آن را از فرآیندی تصادفی بسیار دشوار می‌سازد؛ اما این موضوع با آزمون‌های نمای لیاپانوف و معکوس حداکثر نمای لیاپانوف به دست آمده شناسایی می‌شود. ازسوی دیگر، روش موجک یک سری‌زمانی نامانا را به دو بخش روند و اجزاء تقسیم کرده است. این مسئله موقعیت مدل‌سازی جداگانه هر یک از بخش‌های یک سری‌زمانی، یعنی روند و اجزاء را در قالب مدلی واحد فراهم می‌آورد (لینش و جون، ۲۰۱۰).^۲ بنابراین، در پیش‌بینی سری‌هایی که ساختار پیچیده و آشوبی و فرکتال دارند، مانند شاخص‌های بازارهای مالی، تبدیل موجک بسیار مؤثر و کارا خواهد بود؛ چراکه تبدیل موجک، نویزهای با فرکانس بالا را با حفظ روند این نویزها، از داده‌ها حذف می‌کند. این موضوع طبیعتاً با کاهش مقادیر انحرافات در برآورد مدل‌ها، سبب بهبود مدل‌سازی‌ها و در نتیجه، بهبود پیش‌بینی‌ها خواهد شد (همایونی و امیری، ۲۰۱۱).^۳

در طول سال‌های اخیر، به کاربرد مدل‌های شبکه عصبی و مدل‌های ترکیبی توجه بسیاری شده است، گفتنی است این توجه به دلیل نتایج دقیق و صحیح این مدل‌ها در قیاس با سایر مدل‌هاست. با توجه به این موضوع، گورسن و همکاران (۲۰۱۱)^۴ در مقاله‌ای با عنوان «کاربرد مدل شبکه عصبی مصنوعی در پیش‌بینی شاخص بازار سهام» بر پایه ایده‌ای مبنی بر پویا و مؤثرتر کردن مدل شبکه عصبی مصنوعی در پیش‌بینی شاخص سهام، کوشیده‌اند عملکرد مدل‌های خطی و غیرخطی سنتی را بهبود بخشند. یینگ‌وی و همکاران (۲۰۱۱)^۵ نیز با به کارگیری مدل شبکه عصبی فازی بازارهای سهام تایوان را بررسی کرده‌اند. نتایج این پژوهش بیانگر برتری مدل‌های شبکه عصبی فازی بر مدل‌های شبکه عصبی مصنوعی و مدل‌های آماری از جمله مدل‌های سری‌زمانی بوده است. اصفهانی‌پور و آقامیری (۲۰۱۰)^۶ شاخص قیمت بازار سهام تهران را با استفاده از مدل‌های شبکه عصبی فازی پیش‌بینی کرده‌اند. نتایج این مطالعه نشان داد که پیش‌بینی انجام شده تقریباً ۹۷/۸ درصد با واقعیت سازگاری داشته است.

الوادی و طاهراسماعیل (۲۰۱۱)^۷ با استفاده از تجزیه موجک و مدل ARIMA پیش‌بینی داده‌های سری‌زمانی را تجزیه و تحلیل کرده‌اند. ایشان به ورود تبدیل‌های موجک در علوم همچون فیزیک، مهندسی، ریاضی و آمار (اقتصادسنجی) اشاره می‌کنند و در پژوهش خود، مزایا و برتری تبدیل موجک در

1. Williams
2. Lineesh & John
3. Homayouni & Amiri
4. Gursen & Kayakutlu & Daim
5. Ying Wei & Liang Chen & Hwa Ho
6. Esfahanipour & Aghamiri
7. Al Wadia & Tahir Ismail

بررسی و پیش‌بینی داده‌های سری‌زمانی را بیان داشته‌اند. ایشان در جهت اثبات هدف خود، از داده‌های روزانه سهام عمان استفاده کرده‌اند. چین‌چو و لین‌چن (۲۰۱۱)^۱ رابطه میان بازار سهام و بازارهای حقیقی اقتصاد را با به‌کارگیری تجزیه موجک بررسی کرده‌اند. شوارتز (۲۰۱۰)^۲ با به‌کارگیری آزمون‌های آشوب، جوانب مختلف پیچیدگی‌های بازارهای مالی و اثر آنها بر سرمایه‌گذاری را بررسی کرده است. لنتو (۲۰۰۹)^۳ نیز با استفاده از روش‌های آزمون آشوب هرست، رابطه میان وابستگی‌های بلندمدت و سود در بازارهای مالی کانادا را بررسی کرده است. به‌طور کلی، پترز (۱۹۹۶)^۴، ملیگان و لامباردو (۲۰۰۴)^۵، کارنلیس و یالامووا (۲۰۰۴)^۶، اونالی و گودارد (۲۰۰۹)^۷ و هانگ (۲۰۱۰)^۸ به این نکته اشاره کرده‌اند که اخیراً برای مدل‌سازی بازارهای بورس، توجه سیاست‌گذاران اقتصادی به مدل‌های غیرخطی‌ای جلب شده است که از فیزیک و ریاضیات وارد اقتصادسنجی شده‌اند. از جمله این مدل‌ها می‌توان به آزمون‌های آشوب، روش تجزیه فرکانس موجک و... اشاره کرد.

از جمله مطالعات مهم داخلی در این زمینه‌ها عبارت است از: مطالعه نادری و کمیجانی (۱۳۹۱)، حیدری‌زارع و کردلویی (۱۳۸۹)، فهیمی‌فرد و همکاران (۱۳۸۹)، مشیری و همکاران (۱۳۸۹)، منجمی و همکاران (۱۳۸۸)، فلاح‌شمس و دنلوآصغری (۱۳۸۸)، مشیری و مروت (۱۳۸۵)، آذر و افسر (۱۳۸۵)، مشیری و مروت (۱۳۸۴) و مطالعه سلامی (۱۳۸۱).

۳. چارچوب نظری مدل‌های تحقیق

۳.۱. آزمون‌های تشخیص فرآیندهای آشوبی

در پیشینه نظری آشوب، آزمون‌های متعددی برای تشخیص فرآیند آشوبی از فرآیندهای تصادفی مطرح شده است. بعضی از این آزمون‌ها تصادفی‌بودن فرآیند را می‌سنجند، درحالی‌که بعضی دیگر یکی از خصوصیات فرآیندهای آشوبی را می‌آزمایند. گروه نخست این آزمون‌ها را آزمون‌های غیرمستقیم و گروه دوم آنها را آزمون‌های مستقیم گویند. در آزمون‌های غیرمستقیم، مانند آزمون BDS، معمولاً تصادفی‌بودن پسماندهای یک رگرسیون خطی یا غیرخطی را می‌آزمایند. در نتیجه، رد فرضیه تصادفی‌بودن جملات

1. Chin Chou & Lin Chen
2. Schwarz
3. Lento
4. Peters
5. Mulligan & Lombardo
6. Cornelis & Yalamova
7. Onali & Goddard
8. Huang

پسماند، لزوماً به معنای آشوبی بودن یک فرآیند نیست؛ چراکه این مسئله به علت نوع تصریح مدل خطی و غیرخطی استفاده شده در آزمون است (مشیری، ۱۳۸۱).

مفهوم نمای لیاپانوف پیش از ظهور نظریه آشوب، برای مشخص کردن پایداری سیستم‌های خطی و غیرخطی به کار می‌رفت. محاسبه توان لیاپانوف از طریق اندازه‌گیری مقدار کشیدگی یا خمیدگی رخ داده در هر سیستم انجام می‌شود. روش‌های متعددی برای محاسبه نمای لیاپانوف وجود دارد که از میان آنها، می‌توان به روش‌های مستقیم و روش ماتریس ژاکوبی^۱ سیستمی اشاره کرد (معینی و همکاران، ۱۳۸۵). در حقیقت نمای لیاپانوف، متوسط نرخ هم‌گرایی یا واگرایی نمایی مسیرهای مجاور در فضای حالت‌اند و برای اندازه‌گیری حساسیت به تغییر وضعیت نخست هر فرآیند به کار گرفته می‌شوند. مقدار مثبت نمای لیاپانوف از ویژگی‌های سیستم آشوب‌گونه بوده و در مقابل، مقدار منفی آن، بیانگر وضعیت سیستم دینامیک میراست (وولف، ۱۹۸۵). در نهایت اینکه معکوس حداکثر نمای لیاپانوفی که محاسبه شد، می‌تواند بیانگر حد فاصل معین و تصادفی قراردادن سری مرتبط را تعیین کند؛ بنابراین براساس آن می‌توان میزان پیش‌بینی‌پذیری یا به بیان دیگر، تعداد روزهای پیش‌بینی‌پذیر در این مطالعه را مشخص کرد (وولف، ۱۹۸۵). در این مقاله نیز از همین روش استفاده شده است.

۲.۳. مدل‌های شبکه عصبی مصنوعی

مدل‌های شبکه عصبی، فرآیند توزیع موازی با ماهیت طبیعی بوده و ویژگی مهم آن، توانایی مدل‌سازی روابط غیرخطی و پیچیده بدون نیاز به فرضیات قبلی از ماهیت ارتباط بین داده‌هاست. انواع شبکه‌های عصبی مصنوعی مختلف، به نوعی مغز را الگو قرار می‌دهند. همچنین می‌کوشند از طریق تقلید از ذهن انسان، یعنی فرآیند یادگیری، با استفاده از روش‌های محاسباتی برای خودکارسازی فرآیند اکتساب دانش از نمونه‌ها یا داده‌ها، مسائل پیچیده و بزرگ را حل کنند. شبکه‌های عصبی مصنوعی کاربردهای متفاوتی از قبیل طبقه‌بندی داده‌ها، تقریب توابع، پیش‌بینی متغیرها، خوشه‌بندی و بهینه‌سازی دارند.

از جمله مزایای مهم استفاده از شبکه‌های عصبی مصنوعی این است که اول، تشابه بسیاری با سیستم عصبی انسان دارند، یعنی هوشمندند و برخلاف روش‌های مبتنی بر مدل‌های سنتی، شبکه‌های عصبی روش‌های خودتطبیقی هستند که از داده‌ها استخراج می‌شوند، یعنی قابلیت تعلیم دارند.^۲ همچنین در آن پیش‌فرض‌های بسیار کمی مرتبط با مدل‌های استفاده‌شده برای مسائل وجود دارد یا به عبارتی مدل آزاد^۳ است. دوم، شبکه‌های عصبی علاوه بر اینکه در پردازش اطلاعات، به علت پردازش موازی، سرعت

1. Jacobian Matrix

2. Data- driven self- adaptive methods

3. Model free

فوق‌العاده‌ای دارند، قابلیت تعمیم‌دهی چشمگیری نیز دارند. سوم، شبکه‌های عصبی تقریب‌زننده‌های کلی تابعی^۱ هستند؛ چراکه شبکه‌های عصبی در مقایسه با روش‌های آماری سنتی، آشکال تابعی جامع‌تر و انعطاف‌پذیری بیشتری دارند.

۱.۲.۳. شبکه عصبی مصنوعی چندلایه پیش‌خور

ساده‌ترین شکل شبکه عصبی فقط دو لایه دارد: لایه ورودی^۲ و لایه خروجی^۳. شبکه عصبی همچون سیستمی ورودی‌خروجی عمل می‌کند و ارزش نرون‌های ورودی را با استفاده از تابع تبدیل یا فعال‌ساز، برای محاسبه ارزش نرون‌های خروجی استفاده می‌کند. در شبکه‌های چندلایه، علاوه بر لایه‌های ورودی و خروجی، از لایه‌های پنهان نیز استفاده می‌شود؛ چراکه این لایه‌های پنهان، توانایی‌های پیش‌بینی این مدل‌ها را افزایش می‌دهد. ابتدا رامل هارت (۱۹۸۶)^۴ و پس‌از آن، بسیاری از نویسندگان از جمله نیلسون (۱۹۸۷)^۵، ساینکو (۱۹۸۹)^۶، فاناهاشی (۱۹۸۹)^۷، هارنیک (۱۹۹۰)^۸ و وایت (۱۹۹۲)^۹ اثبات کرده‌اند که شبکه‌های عصبی پیش‌خور با لایه‌های پنهان، تابع فعال‌ساز لوجستیک در لایه پنهان، تابع فعال‌ساز خطی در نرون خروجی و تعداد نرون‌های کافی در لایه پنهان قادرند هر تابعی را با دقت دلخواه تقریب بزنند.

۲.۲.۳. شبکه عصبی فازی

مفهوم منطق فازی^{۱۰} نخستین‌بار در پی تنظیم نظریه مجموعه‌های فازی به وسیله پروفیسور لطفی‌زاده (۱۹۶۵) در صحنه محاسبات نو ظاهر شد. منطق فازی از جمله منطق‌های چندارزشی است و بر نظریه مجموعه‌های فازی تکیه می‌کند. مجموعه‌های فازی خود از تعمیم و گسترش مجموعه‌های قطعی^{۱۱} به صورتی طبیعی حاصل می‌آید. روش مدل‌سازی استفاده‌شده در Anfis مشابه با سایر روش‌های تشخیص سیستم است. در مرحله نخست، سیستمی پارامتری فرض در نظر گرفته شده و سپس داده‌های ورودی و خروجی در شکلی قابل استفاده در Anfis جمع‌آوری می‌شود. پس‌از آن، می‌توان از این مدل برای آموزش مدل FIS استفاده کرد. عموماً این نوع مدل‌سازی در صورتی عملکرد خوبی دارد که داده‌های اعمال شده به Anfis در جهت آموزش شاخص‌های تابع عضویت، دربرگیرنده همه ویژگی‌های مدل FIS مدنظر باشد.

1. Universal functional approximates
2. Input Layer
3. Output Layer
4. Rumelhart
5. Nielson
6. Cybenko
7. Fanahashi
8. Hornik
9. White
10. Fuzzy logic
11. Crisp sets

به‌طور کلی، منطق فازی سه مرحله مشخص کلی دارد که عبارت است از: ۱. مرحله فازی سازی؛^۱ داده‌های عددی را در حوزه دنیای واقعی به اعداد فازی در حوزه فازی تبدیل می‌کند؛ ۲. مرحله تجمیع؛^۲ در این مرحله، محاسبه مقادیر فازی، همه بین صفر و یک، در حوزه فازی صورت می‌گیرد؛ ۳. مرحله عکس فازی سازی؛^۳ تبدیل معکوس اعداد فازی به دست آمده در حوزه فازی، به داده‌های عددی در حوزه دنیای واقعی.

۳.۳. تجزیه موجک

روش موجک، یک سری‌زمانی نامانا را به دو بخش روند و اجزاء تقسیم کرده که این موضوع موقعیت مدل‌سازی جداگانه هریک از بخش‌های هر سری‌زمانی، یعنی روند و اجزاء را در مدلی واحد فراهم می‌آورد (لینش و جون، ۲۰۱۰). تحلیل موجک ابزار بسیار قدرتمندی است که می‌توان از آن برای بررسی اطلاعات کیفی سری‌های زمانی شدیداً نامانا استفاده کرد (عباسی‌نژاد و محمدی، ۱۳۸۶). در این جهت، در ادامه نخست به تجزیه داده‌ها به کمک روش موجک پرداخته و سپس دوباره مدل‌سازی مدل‌های غیرخطی مذکور براساس داده‌های تجزیه شده ارائه می‌شود.

تجزیه موجک با استفاده از توابع پایه‌ای،^۴ سری‌زمانی را به فضای فرکانس برده و سپس سری مذکور را در زمان و مقیاس‌های مختلف نشان می‌دهد. برخلاف تبدیل فوری که یگانه تابع پایه‌ای آن را تابع سینوسی تشکیل می‌دهد، تجزیه موجک توابع پایه‌ای پیوسته و ناپیوسته متفاوتی دارد؛ اما همه این توابع انرژی محدودی دارند.^۵ این خاصیت موجک‌ها سبب شده است که این تجزیه بتواند سری‌های نامانا و زودگذر را را بررسی کند. به‌طور کلی، تجزیه‌های موجک را براساس طول داده‌ها، می‌توان به دو دسته «تبدیل موجک پیوسته (CWT)»^۶ و «تبدیل موجک گسسته (DWT)»^۷ تقسیم کرد (کریم و همکاران، ۲۰۱۱). سری بازدهی بورس از نوع سری‌های گسسته است. همچنین توابع مهم تبدیل موجک گسسته عبارت است از: توابع هار،^۸ دابیشز،^۹ سیملتس،^{۱۰} کوایفلتس،^{۱۱} میر.^{۱۲} همین‌طور سری مطالعه شده در این پژوهش، شباهت بسیاری به تابع تبدیل دابیشز (db3) دارد. همچنین در میان انواع توابع تبدیل گسسته، تابع تبدیل موجک

1. Fuzzification
2. Aggregation
3. Defuzzification
4. Basis Function
5. Finite Energy
6. Continuous Wavelet Transform
7. Discrete Wavelet Transform
8. Haar
9. Daubechies
10. Symmelets
11. Coiflets
12. Meyer

دایشز پرکاربردترین آنهاست. با توجه به این چند موضوع، در این پژوهش نیز از این تابع تبدیل استفاده شده است (وادی و اسماعیل، ۲۰۱۱).

۴.۳. ارزیابی پیش‌بینی مدل‌های مختلف

پس از تخمین مدل برای ارزیابی اجرای مدل‌های رقیب، باید قدرت پیش‌بینی مدل‌ها در خارج از نمونه را بررسی کرد. برای این منظور، معمولاً داده‌ها را به دو مجموعه جدا تقسیم می‌کنند: بخش اول، به مجموعه آموزش^۱ یا تخمین و بخش دوم، به مجموعه آزمون^۲ موسوم است. ابتدا ضرایب مدل با استفاده از داده‌های مجموعه اول تخمین زده می‌شود و سپس با استفاده از داده‌های مجموعه دوم قدرت پیش‌بینی مدل یا به عبارت دیگر، توان تعمیم مدل به خارج از مجموعه داده‌های استفاده شده در تخمین ارزیابی می‌شود. در این قسمت، هدف حداقل کردن خطای پیش‌بینی در مجموعه آزمون است و به همین منظور، معمولاً از معیارهای MSE^3 و $RMSE^4$ استفاده می‌شود. به طور کلی، در میان سایر معیارهای برازش دقت پیش‌بینی، معیارهای مذکور پرکاربردترند. در بسیاری از مطالعات، از معیار $RMSE$ به عنوان بهترین معیار برازش دقت پیش‌بینی مدل‌ها استفاده کرده‌اند؛ چراکه این معیار در واقع میانگینی از معیار MSE بوده و تمامی ویژگی معیار MSE ، از جمله در نظر گرفتن داده‌های دورافتاده در مقایسه دقت مدل‌ها را دربردارد. همچنین این معیار به این علت که جذر MSE است، اختلاف خطاها را کمتر نشان می‌دهد (سوانسون و همکاران، ۲۰۱۱).

اساساً پس از مدل‌سازی و برآورد و پیش‌بینی یک‌سری از داده‌ها، این سؤال مطرح می‌شود که «تا چه اندازه پیش‌بینی انجام شده مناسب و درخور اتکاست؟» غالباً می‌توان چندین مدل را یافت که برازش خوبی روی داده‌های نمونه داشته و پیش‌بینی از طریق تک‌تک آنها امکان‌پذیر باشد؛ اما نباید به سادگی تصور کرد مدلی که برازش بهتری روی داده‌های نمونه دارد، لزوماً پیش‌بینی بهتری را به همراه خواهد داشت. بسیاری از پژوهشگران برای انتخاب بهترین مدل، از معیار حداقل میانگین مجذور خطاهای پیش‌بینی ($MSPE$)^۵ استفاده می‌کنند. استفاده از این روش منوط به این فروض است که خطاهای پیش‌بینی، توزیع نرمال با میانگین صفر داشته باشد و نیز این خطاها فاقد همبستگی و نیز همبستگی بین‌زمانی باشند. به این فروض دو ایراد وارد است: اول، اگرچه عمدتاً فرض می‌کنیم که خطاهای پیش‌بینی، توزیع نرمال دارند، الزاماً این خطاها توزیع نرمال با میانگین صفر ندارند؛ دوم، احتمال وجود خودهمبستگی شدید میان خطاهای پیش‌بینی

1. Training Set
2. Testing Set
3. Mean Square Error
4. Root Mean Square Error
5. Mean Square Prediction Error

حاصل از دو مدل رقیب، بسیار زیاد است، به‌ویژه هنگامی که پیش‌بینی‌ها به‌صورت چنددوره‌ای انجام شده باشد. برای رفع این موانع، می‌توان به راهکارهای گرنجر و نیولد (۱۹۶۷)،^۱ دیولد و ماریانو (۱۹۹۵)^۲ و... اشاره کرد که هر یک ایرادهایی دارد. در این میان، این مطالعه برای مقایسه حداقل میانگین مجذور خطاهای پیش‌بینی در مدل‌های مختلف از آماره آزمون معرفی شده به‌وسیله کلارک و وست (۲۰۰۶)^۳ استفاده کرده است. آماره این آزمون به‌صورت $Z_i = e_{1i}^2 - [e_{2i}^2 - (f_{1i} - f_{2i})^2]$ است که در آن، f_{1i} مقادیر پیش‌بینی شده مبتنی بر مدل نخست و f_{2i} نیز مقادیر حاصل از پیش‌بینی براساس مدل دوم است. همچنین e_{1i} خطای پیش‌بینی حاصل از به‌کارگیری مدل نخست بوده و e_{2i} خطای پیش‌بینی حاصل از به‌کارگیری مدل دوم است.

۴. تفسیر نتایج

این پژوهش از بازدهی شاخص قیمت و بازده نقدی بورس اوراق بهادار تهران به‌صورت روزانه، در دوره زمانی ۵ فروردین ۱۳۸۸ تا ۱۸ اردیبهشت ۱۳۹۱ استفاده کرده است. گفتنی است علائم اختصاری متغیرهای به‌کاربرده شده در این مطالعه عبارت است از: $Tedpix$ ^۴، بیانگر شاخص قیمت و بازده نقدی؛ $dlted$ ، تفاضل لگاریتم شاخص قیمت و بازده نقدی که در ادامه، آن را به اختصار، شاخص بازدهی بورس می‌خوانیم.

۴.۱. بررسی پیش‌بینی‌پذیری سری بازدهی بورس

۴.۱.۱. آزمون نسبت واریانس (VR)

این آزمون بر مبنای آزمون «لو و مکینلی»^۵ است و برای بررسی این موضوع استفاده می‌شود که آیا رفتار اجزاء سری بازدهی بورس «مارتینگل»^۶ است؟

جدول ۱. نتایج آزمون نسبت واریانس در سری بازدهی بورس

Value	d.f	Probability	معیار
			آزمون
۶/۳۸	۷۵۶	۰/۰۰۰	Variance ratio test

منبع: یافته‌های تحقیق

1. Granger and Newbold Test
2. Diebold and Mariano Test
3. Clark and West Test
4. Tehran Exchange Dividend Price Index
5. Lo and MacKinlay
6. Martingale

نتایج آزمون مذکور بیانگر آن است که هیچ‌گونه شواهدی دال بر اینکه سری مذکور و نیز سری وقفه‌های آن، از نوع فرآیندهای مارتینگلی باشند، وجود نداشته و در نتیجه، فرآیند تولید داده در آنها تصادفی نیست. به همین دلیل، می‌توان به پیش‌بینی‌پذیر بودن این سری پی برد. نکته درخور توجه اینکه از نتایج این آزمون نمی‌توان به خطی یا غیرخطی بودن فرآیند تولید داده در سری بازدهی بورس پی برد و فقط می‌توان مارتینگلی نبودن و برخورداری از قابلیت پیش‌بینی‌پذیری آن را نتیجه گرفت.

۲.۱.۴. آزمون BDS

این آزمون را بروک و دکرت و شینکمن (BDS) در سال ۱۹۸۷ معرفی کردند. آزمون BDS بر مبنای انتگرال همبستگی عمل می‌کند که تصادفی بودن فرآیند ایجادکننده یک سری زمانی را در مقابل وجود همبستگی کلی در آن ارزیابی می‌کند. این آزمون به‌خوبی برای ارزیابی وجود فرآیند غیرخطی کلی، از جمله فرآیند آشوب‌گونه، در سری زمانی مشاهده‌شده قرار می‌گیرد. نتایج این آزمون در جدول زیر آمده است.

جدول ۲. نتایج آزمون BDS در سری بازدهی بورس

Dimension	BDS-Statistic	SD	Z-Statistic	Prob
۲	۰/۰۳۶۷۸۴	۰/۰۰۳۱۲۰	۱۱/۷۸۸	۰/۰۰۰۰
۳	۰/۰۵۹۵۷۰	۰/۰۰۴۹۵۴	۱۲/۰۲۵	۰/۰۰۰۰
۴	۰/۰۷۰۷۰۷	۰/۰۰۵۸۹۳	۱۱/۹۹۹	۰/۰۰۰۰
۵	۰/۰۷۲۰۱۴	۰/۰۰۶۱۳۶	۱۱/۷۳۷	۰/۰۰۰۰

منبع: یافته‌های تحقیق

با توجه به نتایج مندرج در جدول ۲، فرضیه صفر این آزمون رد می‌شود. گفتنی است این فرضیه به‌معنای تصادفی نبودن سری پسماندهای مدل مذکور است؛ بنابراین می‌توان به وجود فرآیندی غیرخطی در سری بازدهی بورس پی برد که ممکن است فرآیندی آشوب‌گونه نیز داشته باشد. لازم به یادآوری است که هرگاه در نتایج آزمون BDS، تصادفی بودن یک سری در بعدهای بیش از دو رد شود، احتمال غیرخطی بودن آن سری زیاد خواهد بود؛ زیرا فرضیه مقابل در این آزمون نامشخص است. از این‌رو این آزمون نیز شواهدی دیگر بر غیرخطی بودن سری بازدهی بورس است.

۳.۱.۴. آزمون حداکثر نمای لیاپانوف

اساساً آزمون بزرگ‌ترین نمای لیاپانوف، سرعت واگرایی یا هم‌گرایی دو نقطه آغازین را در یک مسیر زمانی^۱ بر اثر گذشت زمان اندازه‌گیری می‌کند. در واقع، توان‌های لیاپانوف این واگرایی یا هم‌گرایی را

1. Trajectory (orbit)

به وسیله تابعی نمایشی می‌سنجد و براساس این تابع، سرعت متوسط دورشدن یا نزدیک شدن دو نقطه ابتدایی نزدیک به یکدیگر را اندازه‌گیری می‌کند که در تعیین پایداری محلی^۱ سیستم‌های خطی و غیرخطی به کار می‌رود. ازسویی، مثبت بودن نمای لیاپانوف، بیانگر واگرایی نمایی مسیرهای زمانی، حساسیت بسیار به وضعیت نخست و در نتیجه، وجود آشوب در سری است. ازسوی دیگر، منفی بودن آن نشان‌دهنده هم‌گرایی نمایی مسیرهای زمانی بوده است. همچنین صفر بودن توان لیاپانوف بیانگر آن است که سری هیچ‌گونه مسیر هم‌گرایی یا واگرایی ندارد. به عبارتی فرآیندی ثابت است؛ ازاین رو معمولاً وجود دست‌کم یک نمای لیاپانوف کافی است تا آشوب‌گونه بودن سیستم را بتوان نتیجه گرفت.

اصولاً برای محاسبه بزرگ‌ترین نمای لیاپانوف دو روش وجود دارد: ۱. روش مستقیم؛^۲ ۲. روش ژاکوبین.^۳ از روش مستقیم هنگامی که استفاده می‌شود که معادلات حرکت سیستم به‌طور صریح مشخص باشد. گفتنی است این معادلات از حل معادلات تفاضلی یا دیفرانسیل مرتبط حاصل می‌شود. اما چون معمولاً حرکت سیستم‌های اقتصادی مشخص نیست، از روش ژاکوبین برای محاسبه نمای لیاپانوف در این‌گونه سیستم‌ها استفاده می‌شود. روش ژاکوبین را نیچکا و دیگران (۱۹۹۲) مطرح کردند. آنها با استفاده از نظریه «تیکن» معادلات مربوطه به سیستم‌های آشوبی را تشکیل داده و با استفاده از شبکه عصبی مصنوعی این مدل‌ها را برآورد و به کمک آن، بزرگ‌ترین نمای لیاپانوف را تخمین زده‌اند. گفتنی است که در این مطالعه از هر دو روش فوق به کمک نرم‌افزار MATLAB برای تشخیص آشوبی بودن سری بازدهی بورس استفاده شده است که نتایج آن به‌طور مجزا در جداول ۳ آمده است.

جدول ۳. حداکثر نمای لیاپانوف به روش مستقیم

حداکثر وقفه	۱	۲	۳	۴	۵
نمای لیاپانوف	۰	$۴/۳۷ \approx ۱۰^{-۱۹}$	$۰/۰۰۳۵۸$	$۰/۰۰۴۸۰$	$۰/۰۲۴۲۱$
حداکثر نمای لیاپانوف	$۰/۰۲۴۲۱$				

منبع: یافته‌های تحقیق

جدول ۴. حداکثر نمای لیاپانوف به روش ژاکوبین؛ مبتنی بر شبکه عصبی

حداکثر وقفه	۱	۲	۳	۴	۵
نمای لیاپانوف	$۴/۹۱ \approx ۱۰^{-۱۹}$	$۱/۱۷ \approx ۱۰^{-۲۱}$	$۰/۰۰۱۳۹$	$۰/۰۰۹۱۱$	$۰/۰۳۲۵۹$
حداکثر نمای لیاپانوف	$۰/۰۳۲۵۹$				

منبع: یافته‌های تحقیق

1. Local Stability
2. Direct Method
3. Jacobian Method


نتایج جداول ۳ و ۴ مؤید آشوب‌گونه بودن سری بازدهی بورس بوده، چراکه مقادیر آزمون‌های لیاپانوف در هر دو روش مستقیم و نیز روش ژاکوبین مثبت است. همچنین، با توجه به اینکه به علت حساسیت بسیار به وضعیت نخست، یعنی هر نقطه اولیه انتخابی، این مقادیر مسیرهای نزدیک به هم نیز به سرعت واگرا می‌شود و هیچ نقطه ثابت یا چرخه متناوبی وجود نخواهد داشت؛ بنابراین فرآیند بررسی شده آشوبی است.

ازسویی نیز حداکثر نمای لیاپانوف به دست آمده در روش نخست، یعنی روش مستقیم، برابر 0.2421 است. بر این اساس، حد پیش‌بینی‌پذیری در این مطالعه، یعنی تعداد روزهای پیش‌بینی‌پذیر، معکوس این عدد و تقریباً ۴۲ روز است. همچنین این عدد در روش دوم حد پیش‌بینی‌پذیری، یعنی تعداد روزهای پیش‌بینی‌پذیر، تقریباً ۳۱ روز است؛ بنابراین برای اطمینان بیشتر به نتایج تحقیق، در این مطالعه حد پیش‌بینی‌پذیری را ۳۱ روز انتخاب می‌کنیم.

۲.۴. تجزیه داده‌ها به کمک روش موجک

نتایج آزمون‌های دیکی-فولر و فیلپس-پرون درباره سری لگاریتم شاخص قیمت و بازده نقدی بورس اوراق بهادار تهران بر نامانابودن متغیر مذکور در سطح دلالت دارد. همچنین نتایج آزمون‌های فوق درباره سری تفاضل لگاریتم (بازدهی) قیمت و بازده نقدی بورس، مؤید مانابودن آن بوده است؛ ازاین رو می‌توان از آزمون‌های مذکور $I(1)$ بودن سری لگاریتم شاخص قیمت و بازده نقدی بورس اوراق بهادار تهران را نتیجه گرفت. در ادامه، به کمک روش موجک آنها تجزیه شده و نهایتاً به کمک مدل‌های مختلف شبکه عصبی پیش‌بینی می‌شوند.

برای انتخاب سطح تجزیه داده‌ها، آنها ابتدا به پنج سطح تجزیه شده و سپس به کمک جعبه گرافیکی موجک در نرم‌افزار MATLAB، سطح بهینه مشخص شد. براساس آن، سطح بهینه تجزیه داده‌ها برابر سطح یک شده است. شکل زیر نمودار تجزیه داده‌ها را تا یک سطح و با تابع دابیشز ۳ نشان می‌دهد. گفتنی است داده‌های شاخص بورس با نمودار دابیشز ۳ همخوانی داشتند؛ ازاین رو از تابع سه استفاده شد.



شکل ۱. نمودار تجزیه داده‌ها با استفاده از تابع داییشز و تا یک سطح

منبع: یافته‌های تحقیق

لازم به یادآوری است داده‌ها را تا یک سطح واشکافی کرده و بر مبنای آن تقریب و جزئیات به دست آمده را محاسبه کردیم. با توجه به این موضوع، شکل فوق نمودار تقریب $\{a(1)\}$ و جزئیات $\{d(1)\}$ سری شاخص بورس را نشان می‌دهد که برای تجزیه داده‌ها با استفاده از تابع تبدیل موجک گسسته داییشز ۳، به کار گرفته خواهد شد. گفتنی است به کمک آنها می‌توانیم مدل‌سازی‌های مدنظر را انجام دهیم.

۳.۴. مدل‌سازی سری بازدهی بورس با مدل‌های شبکه عصبی

۱.۳.۴. مدل شبکه عصبی چندلایه پیش‌خور

با توجه به اهمیت معماری شبکه، در این قسمت پیش از مقایسه انواع مدل‌های شبکه عصبی پیش‌خور، نکات مربوط به معماری شبکه را بیان می‌کنیم. نخست اینکه برای پیدا کردن میزان نرون بهینه سعی کرده‌ایم تا به کمک کدنویسی در نرم‌افزار مطلب، شبکه‌های مختلفی را با نرون‌های متفاوت ارزیابی کنیم؛ از این رو تعداد ۲ تا ۲۰ نرون در شبکه‌های دو و سه لایه ارزیابی شد. هریک از این نرون‌ها سی بار آموزش^۱ کرده و

1. Train

برای مقایسه کارایی مرحله آموزش مدل‌های شبکه عصبی^۱ آنها، خطای داده‌های آزمون^۲ را که ۳۰ درصد از کل داده‌ها را تشکیل می‌دهند، به صورت تصادفی، در مدل‌های مختلف ملاک قرار داده‌ایم. در نهایت، تعداد نرون بهینه برابر هشت نرون بوده و تعداد لایه بهینه برابر دو لایه بوده است. نکته دیگر انتخاب الگوریتم آموزش بوده که از میان الگوریتم‌های مختلف، بهترین عملکرد را الگوریتم^۳ Traincgp داشته است.

نکته دیگری که می‌توان پس از اتمام طراحی شبکه بدان اشاره کرد، استفاده از پنج وقفه از متغیر وابسته و نیز یک متغیر مجازی^۴ است که به عنوان متغیرهای ورودی مدل در نظر گرفته شده‌اند. گفتمنی است معیار انتخاب متغیر مجازی شوک‌های نامتعارفی است که بر سری بررسی شده وارد آمده است. بدین صورت که شوک‌های بزرگ‌تر از سه انحراف معیار وارد شده بر سری به عنوان شوک نامتعارف در نظر گرفته شده است. بر پایه این ساختار، متغیر مذکور پیش‌بینی شده و نتایج آن در جدول ۶ آمده است.

جدول ۶. نتایج تخمین انواع مدل‌های MFNN

RMSE	MSE	مدل	ت.ب.ت.
نتایج براساس داده‌های تجزیه نشده			
۰/۰۰۵۱۳	۰/۰۰۰۲۶۳	MFNN (5lag of dltd & DUM)	۱
نتایج براساس داده‌های تجزیه شده			
۰/۰۰۲۵۰	۰/۰۰۰۰۶۲	MFNN (5lag of dltd & DUM)	۲

منبع: یافته‌های تحقیق

نهایتاً در اینجا، ذکر دو نکته ضروری است: نخست، همان‌طور که گفته شد، برای مقایسه کارایی مرحله آموزش مدل‌های شبکه عصبی چندلایه پیش‌خور، از خطای داده‌های آزمون استفاده شد که علت آن همگن بودن نتایج حاصل از مدل‌های تحقیق است؛ زیرا در مدل‌های شبکه عصبی فازی، برای بررسی کارایی مرحله آموزش مدل‌های مختلف فقط از داده‌های آزمون^۵ استفاده شده و حجم داده‌های اعتبارسنجی درباره آنها برابر صفر است. بنابراین حجم داده‌های اعتبارسنجی برای مدل شبکه عصبی چندلایه پیش‌خور نیز معادل صفر در نظر گرفته شد. دوم، همان‌طور که در جدول ۶ ملاحظه می‌شود، نتایج مدل فوق که بر پایه داده‌های تجزیه شده است، از نظر برخورداری از خطای پیش‌بینی کمتر، عملکرد بهتری دارند.

1. Performance
2. Test
3. Conjugate Gradient Polak-Ribière
4. Dummy Variable
5. Test

۲.۳.۴. مدل شبکه عصبی فازی

یادگیری عصبی- انطباقی (ANFIS)^۱ عملکردی مشابه با شبکه‌های عصبی دارد. با توجه به سه مرحله فازی سازی سیستم، ابتدا داده‌های ورودی را فازی‌سازی (نرمالیزه) کرده،^۲ سپس داده‌های فازی‌شده را به داخل جعبه‌ابزار گرافیکی ANFIS فراخوانی کرده و FIS موجود در جعبه‌ابزار ANFIS را معرفی می‌کنیم. همچنین بر مبنای جعبه‌ابزار FIS که در جعبه‌ابزار گرافیکی ANFIS به صورت انتخاب گزینه‌هایی با هشت نوع تابع مختلف^۳ درآمده است، بهترین تابع را انتخاب خواهیم کرد؛ چراکه FIS در حقیقت فضای ورودی داده‌ها را به صورت فازی شبکه‌بندی می‌کند. بنابراین نوع تابع FIS برای فازی‌سازی فضای ورودی بسیار مهم است.

برای انتخاب نوع تابع FIS، در جعبه‌ابزار گرافیکی ANFIS بدین صورت عمل می‌کنیم که به علت حجم زیاد داده‌ها، هر تابع را برای پنجاه داده انتخاب شده به صورت تصادفی، اجرا کرده و مقادیر واقعی و مقادیر خروجی شبکه را به دست آوردیم. سپس خطاهای مربوطه به هر تابع را محاسبه کرده و در نهایت، سیستم استنتاج فازی (FIS) بهینه را انتخاب کردیم. نتایج حاکی از آن بوده که دو تابع FIS گوسی^۴ کمترین خطای ممکن و به تبع بیشترین دقت را داشته‌اند. گفتنی است با اختلاف ناچیزی، عملکرد gaussmf بهتر بوده است. پس از انتخاب تابع FIS بهینه، نوبت به اجرای مرحله تخمین اولیه خواهد رسید که معادل با مرحله یادگیری^۵ برای داده‌های آموزش است. بر این اساس، شبکه بهینه در بخش یادگیری، ضرایب توابع را تخمین زده و در این بخش، با توجه به آنها مقدار خروجی‌های سیستم، یعنی مقادیر شبیه‌سازی شده یا پیش‌بینی خارج از نمونه را به دست می‌دهد.

بنابراین بر اساس سیستم استنتاج فازی gaussmf میزان خطای پیش‌بینی شبکه عصبی فازی در پیش‌بینی خارج از نمونه شاخص بازدهی بورس را در دو مدل ANFIS مجزا برآورد می‌کنیم که در هر دوی آنها، پنج وقفه از متغیر وابسته به همراه متغیر مجازی وجود داشته است. گفتنی است متغیر مجازی دربرگیرنده شکست‌های ساختاری موجود در سری بازدهی بورس در دوره بررسی شده است. نتایج این برآورد در جدول ۷ آمده است.

۱. ANFIS واژه‌ای اختصاری است که از حروف اول *Adaptive Neuro-Fuzzy Inference System* گرفته شده است.

۲. یعنی داده‌ها به اعدادی بین صفر و یک تبدیل شده تا جعبه‌ابزار گرافیکی ANFIS قادر به خواندن آنها باشد.

۳. که عبارت است از: ۱. Ψ_{sigmf} ؛ ۲. Ψ_{dsigmf} ؛ ۳. Ψ_{pimf} ؛ ۴. Ψ_{gaussmf} ؛ ۵. Ψ_{gaussmf} ؛ ۶. Ψ_{gbellmf} ؛ ۷. Ψ_{trapmf} ؛ ۸. Ψ_{trimf} .

4. Gaussmf and gauss2mf

5. Train now

در این بخش نیز تأکید می‌کنیم درباره بررسی کارایی مرحله آموزش مدل‌های شبکه عصبی فازی، مقادیر داده‌های اعتبارسنجی معادل صفر بوده و انتخاب بهترین مدل صرفاً براساس نتایج حاصل از داده‌های آزمون^۱ به‌دست آمده است.

جدول ۷. مقدار خطاهای پیش‌بینی با استفاده از مدل ANFIS

ردیف	مدل	تابع استنتاج فازی	MSE	RMSE
نتایج براساس داده‌های تجزیه‌نشده				
۱	ANFIS (5lag of dltd & DUM)	gaussmf	۰/۰۰۰۰۲۹۸	۰/۰۰۰۵۴۶
نتایج براساس داده‌های تجزیه‌شده				
۲	ANFIS (5lag of dltd & DUM)	gaussmf	۰/۰۰۰۰۰۶۸	۰/۰۰۲۶۱

منبع: یافته‌های تحقیق

جدول فوق نیز نشان می‌دهد نتایج مدل شبکه عصبی فازی مبتنی بر داده‌های تجزیه‌شده از نظر خطای پیش‌بینی کمتر، عملکرد بهتری از مدل‌های با داده‌های تجزیه‌نشده دارد.

۴.۴. ارزیابی عملکرد پیش‌بینی مدل‌های تحقیق

همان‌گونه که پیش‌تر گفته شد، این مطالعه به کمک آماره Z_i که کلارک و وست (۲۰۰۶) ارائه کردند، قدرت پیش‌بینی مدل‌های تحقیق را با هم مقایسه می‌کند. به‌همین منظور، پس از محاسبه مقدار آماره Z_i ، آن را روی مقداری ثابت رگرس کرده و سپس معناداری این مقدار ثابت را می‌آزماید. چنانچه فرضیه صفر این آزمون مبنی بر نبودن تفاوت معنادار بین مقدار ثابت و عدد صفر پذیرفته شود، قدرت پیش‌بینی دو مدل، یعنی مدل‌های یک و دو، با هم برابر بوده و در غیر این صورت، بسته به مثبت یا منفی بودن، این مقدار ثابت برآورد شده و برتری هریک از مدل‌ها در پیش‌بینی، بر مدل دیگر تعیین می‌شود.

جدول ۸. مقایسه مدل‌های مختلف براساس آزمون کلارک و وست

ردیف	مدل‌ها		ضریب C	آماره t	Prob
	Model 1	Model 2			
۱	MFNN با داده‌های تجزیه‌نشده	MFNN با داده‌های تجزیه‌شده	۰/۴۳	۳/۰۶۱۴	۰/۰۰۶۴
۲	ANFIS با داده‌های تجزیه‌نشده	ANFIS با داده‌های تجزیه‌شده	۰/۴۹	۳/۹۷۱	۰/۰۰۵۲
۳	MFNN با داده‌های تجزیه‌نشده	ANFIS با داده‌های تجزیه‌شده	۰/۳۲	۲/۳۰۴	۰/۰۴۱۹

منبع: یافته‌های تحقیق

نتایج جدول ۸ نشان می‌دهد هر دو دسته از مدل‌های شبکه عصبی مصنوعی چندلایه پیش‌خور و مدل شبکه عصبی فازی، با داده‌های تجزیه‌شده نتایج پذیرفتنی و معنادارتری از حالت مبتنی بر داده‌های تجزیه‌نشده داشته‌اند. همچنین در بین مدل‌های شبکه عصبی مصنوعی چندلایه پیش‌خور و مدل شبکه عصبی فازی که بر پایه داده‌های تجزیه‌شده سری بازدهی بورس را پیش‌بینی کردند، مدل شبکه عصبی چندلایه پیش‌خور نتایج برتری در مقایسه با مدل شبکه عصبی فازی داشته است.

۵. نتیجه‌گیری و ارائه پیشنهادها

در این مطالعه، آشوب تحلیل شده و عملکرد انواع مدل‌های شبکه عصبی با کمک داده‌های تجزیه‌شده با روش موجک، برای پیش‌بینی بازدهی شاخص قیمت و بازده نقدی بورس اوراق بهادار تهران ارزیابی شد. براساس نتایج این مطالعه، پیش‌بینی پذیر بودن، یعنی مارتننگلی نبودن و نیز غیرخطی بودن این سری تأیید شد؛ بنابراین فرضیه بازارهای کارا درباره این سری رد می‌شود. همچنین سری مطالعه‌شده آشوبی نیز بوده است و از این رو فرضیه بازارهای فرکتال درباره سری بازدهی بورس تأیید می‌شود. بر پایه این نتیجه، از سویی حد پیش‌بینی‌پذیری در این مطالعه، یعنی تعداد روزهای پیش‌بینی‌پذیر که برابر معکوس حداکثر نمای لیاپانوف است، برابر ۳۱ روز به دست آمد. از سوی دیگر، با استفاده از مدل‌های شبکه عصبی چندلایه پیش‌خور و شبکه عصبی فازی داده‌های تجزیه‌شده و تجزیه‌نشده، به کمک تجزیه موجک، شاخص بازدهی بورس برای ۳۱ روز به عنوان داده‌های خارج از نمونه، مدل‌سازی و پیش‌بینی شد.

از سویی، نتایج این پیش‌بینی‌ها براساس معیارهای MSE و RMSE حاکی از آن است که تجزیه موجک سبب ایجاد تفاوتی معنادار در عملکرد مدل‌های تحقیق شده و معناداری این تفاوت نیز براساس آزمون کلارک و وست (۲۰۰۶) تأیید شد. از سوی دیگر، در هر دو حالت به کارگیری داده‌های تجزیه‌شده و داده‌های تجزیه‌نشده، عملکرد مدل چندلایه پیش‌خور در مقایسه با مدل شبکه عصبی فازی بهتر و معنادارتر بوده است. گفتنی است این موضوع با توجه به آشوبی بودن سری بازدهی بورس، مسئله‌ای محتمل بوده است؛ زیرا در سری‌های آشوب‌گونه، مرحله فازی‌سازی سبب از بین رفتن بعد فرکتال در داده‌ها شده و بنابراین نتایج مدل‌سازی‌ها و پیش‌بینی‌ها را متأثر خواهد ساخت. بنابراین در کنار مقایسه کاربردی مدل‌های مذکور، یکی از دستاوردهای مهم این مطالعه، برتری مدل‌های شبکه عصبی (غیرفازی) از شبکه‌های فازی در مدل‌سازی و پیش‌بینی سری‌های آشوب‌گونه، از جمله بازارهای مالی بوده است که ممکن است برای سرمایه‌گذاران و تحلیل‌گران بسیار مهم باشد.

پیشنهاد برآمده از این تحقیق را می‌توان در قالب تبیین فرآیندی کارا برای ارائه شیوه‌ای مناسب در مدل‌سازی و پیش‌بینی سری‌های پیچیده و پرنوسان دانست. این فرآیند بدین صورت است که در ابتدا، آشوب‌گونه بودن آن بررسی می‌شود تا ضمن رد صلاحیت به کارگیری مدل‌های خطی، اول، بتوان حد پیش‌بینی‌پذیری را درباره آن تعیین کرد و دوم، مدل‌ها و روش‌های نامناسب برای آنها، مانند مدل‌های مبتنی بر منطق فازی یا روش‌های نرمال‌سازی، به کار گرفته نشود.

همچنین از سویی، در این فرآیند به کار بستن روش موجک برای سری‌هایی که آشوب‌گونه بودن آنها تأیید شد نیز می‌تواند نتایج پیش‌بینی‌ها را بهبود ببخشد. از سوی دیگر، به عنوان پیشنهادی تکنیکی نیز می‌توان قابلیت‌های مدل‌های مبتنی بر الگوریتم ژنتیک و مدل‌های رگرسیونی غیرخطی و مدل‌های فرکتالی را به عنوان اقسام پرکاربردی از مدل‌های غیرخطی در زمینه پیش‌بینی سری‌های آشوبی بررسی کرد.

منابع و مآخذ

- آذر، عادل و امیر افسر، ۱۳۸۵، «مدل‌سازی پیش‌بینی قیمت سهام با رویکرد شبکه‌های عصبی فازی»، *فصل‌نامه پژوهش‌های بازرگانی*، ش ۴۰.
- تهرانی، رضا، حجت‌اله انصاری و علیرضا سارنج، ۱۳۸۷، «بررسی وجود پدیده بازگشت به میانگین در بورس اوراق بهادار تهران با استفاده از آزمون نسبت واریانس»، *بررسی‌های حسابداری و حسابرسی*، دوره ۱۵، ش ۵۴.
- حیدری‌زارع، بهزاد و حمیدرضا کردلوئی، ۱۳۸۹، «پیش‌بینی قیمت سهام با استفاده از شبکه عصبی مصنوعی»، *فصل‌نامه مدیریت*، ش ۱۷.
- راسخی، سعید و امیر خانعلی‌پور، ۱۳۸۸، «تحلیل تجربی نوسانات و کارایی اطلاعاتی بازار سهام (مطالعه موردی؛ بورس اوراق بهادار تهران)»، *فصل‌نامه پژوهش‌های اقتصادی ایران*، س ۱۳، ش ۴۰، ص ۲۹ تا ۵۷.
- سلامی، امیربهداد، ۱۳۸۰، «بررسی کارایی بازار ارز ایران، ۱۳۷۰ تا ۱۳۷۸»، *آزمون شکل ضعیف*، مورد بازار آزاد ارز»، *فصل‌نامه پژوهش‌نامه اقتصادی*، ش ۳، ص ۱۰۳ تا ۱۱۶.
- سلیمی‌فر، مصطفی و زهرا شیرزور، ۱۳۸۹، «بررسی کارایی اطلاعاتی بازار بورس به روش آزمون نسبت واریانس»، *مجله دانش و توسعه*، س ۱۸، ش ۳۱.
- عباسی‌نژاد، حسین و احمد محمدی، ۱۳۸۶، «پیش‌بینی نرخ ارز با استفاده از شبکه‌های عصبی و تبدیل موجک»، *فصل‌نامه اقتصادی*، ش ۶۰، ص ۱۹ تا ۴۲.
- فلاح‌شمس، میرفیض و بیتا دلنواز صغری، ۱۳۸۸، «پیش‌بینی شاخص بورس اوراق بهادار تهران با استفاده از شبکه‌های عصبی»، *مجله فراسوی مدیریت*، س ۳، ش ۹.

فهیمی فرد، سیدمحمد و ماشاءالله سالارپور و محمود صبوخی صابونی، ۱۳۸۹، «کاربرد الگوهای ANFIS در مقایسه با الگوهای اقتصادسنجی ARIMA در پیش‌بینی قیمت خرده‌فروشی محصولات کشاورزی»، *اقتصاد کشاورزی*، ج ۴، ش ۲، ص ۱۶۵ تا ۱۸۳.

کمیحانی، اکبر و اسماعیل نادری، ۱۳۹۱، «مقایسه قابلیت‌های مدل‌های مبتنی بر حافظه بلندمدت و مدل‌های شبکه عصبی پویا در پیش‌بینی بازدهی بورس اوراق بهادار تهران»، *فصل‌نامه دانش مالی تحلیل بورس اوراق بهادار*، س ۵، ش ۱۴.

مشیری، سعید، ۱۳۸۱، «مروری بر نظریه آشوب و کاربردهای آن در اقتصاد»، *فصل‌نامه پژوهش‌های اقتصادی ایران*، ش ۱۲، ص ۲۹ تا ۷۱.

مشیری، سعید، کامران پاکیزه، منوچهر دبیریان و ابوالفضل جعفری، ۱۳۸۹، «بررسی رابطه میان بازدهی سهام و تورم با استفاده از تجزیه و تحلیل موجک در بورس اوراق بهادار تهران»، *فصل‌نامه پژوهش‌های اقتصادی ایران*، ش ۴۲، ص ۷۴ تا ۵۵.

مشیری، سعید و فائزه فروتن، ۱۳۸۳، «آزمون آشوب و پیش‌بینی قیمت آتی نفت خام»، *فصل‌نامه پژوهش‌های اقتصادی ایران*، ش ۲۱، ص ۶۷ تا ۹۰.

مشیری، سعید و حبیب مروت، ۱۳۸۴، «بررسی وجود فرآیند آشوبی در شاخص بازدهی کل قیمت سهام بازار بورس تهران»، *فصل‌نامه پژوهش‌های اقتصادی ایران*، ش ۲۵، ص ۴۷ تا ۶۴.

مشیری، سعید و حبیب مروت، ۱۳۸۵، «پیش‌بینی شاخص کل بازدهی سهام تهران با استفاده از مدل‌های خطی و غیرخطی»، *فصل‌نامه پژوهش‌نامه بازرگانی*.

معینی، علی و حمید ابریشمی و مهدی احراری، ۱۳۸۵، «به‌کارگیری نمای لیاپانوف برای مدل‌سازی سری‌زمانی قیمت نفت خام بر پایه توابع پویا»، *مجله تحقیقات اقتصادی*، ش ۷۶، ص ۷۷ تا ۱۰۰.

منجمی، سیدامیرحسین و مهدی ایزری و علیرضا رعیتی‌شوازی، ۱۳۸۸، «پیش‌بینی قیمت سهام در بازار بورس اوراق بهادار با استفاده از شبکه عصبی فازی و الگوریتم ژنتیک و مقایسه آن با شبکه عصبی مصنوعی»، *فصل‌نامه اقتصاد مقداری (بررسی‌های اقتصادی سابق)*، د ۶، ش ۳، ص ۱ تا ۲۶.

نادری، اسماعیل، ۱۳۹۱، *تحلیل آشوب و بررسی عملکرد مدل‌های خطی و غیرخطی سری‌زمانی در پیش‌بینی شاخص بازدهی بورس تهران*، پایان‌نامه کارشناسی ارشد، دانشکده اقتصاد، دانشگاه تهران.

Al Wadia, S., M. Tahir Ismail, 2011, "Selecting Wavelet Transforms Model in Forecasting Financial Time Series Data Based on ARIMA Model", *Applied Mathematical Sciences*, Vol. 5, No. 7, PP. 315-326.

Barnett, W.A., A. Serletis, 2000, "Martingales, nonlinearity, and chaos, *Journal of Economic Dynamics & Control*", Vol. 2, PP. 703-724.

Chin Chou, S. C. Lin Chen, 2011, "Integrated or segmented? Wavelets transform analysis on relationship between stock and real estate markets", *Economic Bulletin*, Issue. 3, Vol. 31, No. 3, PP. 11-38.

Clark, T.E., K.D. West, 2006, "Using Out-of-Sample Mean Squared Prediction Errors to Test the Martingale Difference Hypothesis", *Journal of Econometrics*, Vol. 135, No. 1-2, pp. 155-186.

Cornelis, A.L., R. Yalamova, 2004, "Multifractal Spectral Analysis of the 1987 Stock", *Market Crash*, Working Paper.

Esfahanipour, A., W. Aghamiri, 2010, "Adapted Neuro-Fuzzy Inference System on indirect approach TSK fuzzy rule base for stock market analysis", *Expert Systems with Applications*, No. 37, pp. 4742-4748.

Guresen, Erkam & Kayakutlu, Gulgun & Daim, u. Tugrul, 2011, *Using Artificial Neural Network Models in Stock Market Index Prediction*, Expert Systems with Applications.

Homayouni, N., A. Amiri, 2011, "Stock price prediction using a fusion model of wavelet", *fuzzy logic and ANN*, International Conference on E-business, Management and Economics, IPEDR Vol.25, IACSIT Press, Singapore, PP. 277-281.

Huang, S.C., 2010, "Return and Volatility Contagions of Financial Markets over Difference Time Scales", *International Research Journal of Finance and Economics*, Vol. 42, PP. 140-148.

Karim, S.A.A, B.A. Karim, M.T. Ismaeil, M.K. Hasan, J. Sulaiman, 2011, "Application of Wavelet Method in Stock Exchange Problem", *Journal of Applied Science*, Vol. 11, No. 8, PP. 1131-1135.

Lento, C., 2009, "Long-term Dependencies and the Profitability of Technical Analysis", *International Research Journal of Finance and Economics*, Vol. 269, PP. 126-133.

Lineesh M.C., C.J. John, 2010, "Analysis of Non-Stationary Time Series using Wavelet Decomposition", *Nature and Science*, Vol. 8, No. 1, PP. 53-59.

Lorenz, H.W., 1989, *Nonlinear Dynamical Economics and Chaotic Motion*, New York: Springer-Verlag.

Onali, E., J. Goddard, 2009, "Unifractality and multifractality in the Italian stock market", *International Review of Financial Analysis*, pp. 154-163.

Özer, Gökhan, Cengiz Ertokatli, 2010, "Chaotic processes of common stock index returns: An empirical examination on Istanbul Stock Exchange (ISE) market", *African Journal of Business Management*, Vol. 4, No. 6, pp. 1140-1148.

Peters, E.E., 1996, *Chaos and Order in the Capital Markets: A New View of Cycles, Prices, and Market Volatility*, U.S.A.: John Willey & Sons Inc.

Prokhorov, A.B., 2008, "Nonlinear Dynamics and Chaos Theory in Economics: A Historical Perspective", *Quantile*, Vol. 4, PP. 1-27.

Rubio, O.B., S.S. Rivero, F.F. Rodriguez, 2002, "Non-Linear Forecasting Methods: Some Applications to the Analysis of Financial Series", *Fundacion de Estudios Economia Aplicada (FEDEA)*, Vol. 01, PP. 1-23.

Schwarz, S.L., 2010, *Leverhulme Lecture Regulating Complexity in Financial Markets*, University of Oxford, Faculty of Law, 10 November.

Swanson, D.A., J. Tayman, T.M. Bryan, 2011, "MAPE-R: a Rescaled Measure of Accuracy for Cross-Sectional Subnational Population Forecasts", *J Pop Research*, Vol. 28, PP. 225–243.

Wadi, S., M.T. Ismail, 2011, "Selecting Wavelet Transforms Model in Forecasting Financial Time Series Data Based on ARIMA Model", *Applied Mathematical Sciences*, Vol. 5, No. 7, pp. 315 – 326.

Wanous, M., H. Boussabaine, J. Lewis, 2003, "A Neural Network Bid/No Bid Model: the Case for Contractors in Syria", *Construction Management and Economics*, Vol. 21, pp. 737–744.

Williams, B., 2005, *Trading Chaos: Applying Expert Techniques To Maximize Your Profits*, Press. John Wiley & Sons, 265 P., ISBN 0-471-11929-6.

Wolf, A., J. Swift, H. Swinney, J. Vastano, 1985, "Determining Lyapunov Exponents from Time Series", *Physica*, Vol. 16, PP. 285-317.

Ying Wei, L., T. Liang Chen, T. Hwa Ho, 2011, "A hybrid model based on adaptive-network-based fuzzy inference system to forecast Taiwan stock market", *Expert Systems with Applications*, No. 38, pp. 13625–13631.