به كارگيري مدل تركيبي شبكه‌هاي عصبي مصنوعي با رگرسيون فازي با هدف پيش‌بيني قيمت طلا

مهدي خاشعي [*۱] و مهدي بيجاري [۲]

[۱] دانشجوي دكتري تخصصي مهندسي صنايع، دانشگاه صنعتي اصفهان

[۲] دانشيار دانشكده مهندسي صنايع، دانشگاه صنعتي اصفهان

(تاريخ دريافت ۸۵/۴/۱۰ ، تاريخ دريافت روايت اصلاح شده ۸۸/۱۰/۱۵ ، تاريخ تصويب۸۹/۱/۱۸)

چكيده

يكي از مشكلات مهم در پيش‌بيني با شبكه‌هاي عصبي مصنوعي، فراهم كردن داده‌هاي لازم براى پيش‌بينـي اسـت؛ چـرا كـه شـبكه‌هـاي عصبي براى حصول نتايج دقيق نياز به داده‌هاي زيادي دارند. اما بايد توجه داشت كه جمع‌آوري داده‌هـاي مـورد نيـاز شـبكه، نخسـت، بسـيار هزينه‌بر است و دوم، مدت زمان طولاني را طلب مي‌كند. بنابراين با توجه به تغييـرات سـريع در محـيط‌هـاي واقعـي و بـه ويـژه سيسـتم‌هـاي اقتصادي و مالي، پيش‌بيني در اين‌گونه محيط‌ها نيازمند روش‌هايي است كه با تعداد داده‌هـاي قابـل حصـول كـم نيـز كارآمـد و كـارا باشـند. روش‌هاي پيش‌بيني فازي، به دليل استفاده از اعداد فازي به جاي اعداد قطعي، نسبت به ساير روش‌هاي مشابه به داده‌هاي كمتري نياز داشـته، اما عملكرد آنها هميشه رضايت‌بخش نيست. در اين مقاله براى بر طرف كردن محدوديت تعداد داده‌هاي مورد نياز شبكه و حصول نتايج دقيق‌تر براى پيش‌بيني قيمت طلا، مدل تركيبي شبكه‌هاي عصبي مصنوعي با رگرسيون فازي پيشنهاد شده است. نتايج تجربي بيـانگر كارآمـدي ايـن روش در پيش‌بيني قيمت طلا است.

واژه‌هاي‌كليدي: شبكه‌هاي عصبي مصنوعي(*ANNs*)، رگرسيون فازي، مدل‌هاي تركيبي، پيش‌بيني سري‌هاي زماني

مقدمه

به تازگی شبكه‌هاي عصبي مصنوعي به طور گسترده‌اي مورد مطالعه قرار گرفته و محققـان بسـياري ايـن گونـه از شبكه‌ها را براى پيش‌بيني سري‌هاي زماني مورد اسـتفاده قرارداده‌اند. زانگ در مقاله‌اي ايـن گونـه از مـدل‌هـا را بـه طوركامل مرورکـرده اسـت[۱]. مزيـت اصـلي شـبكه‌هـاي عصـبي مصـنوعي، قابليـت مـدل‌سـازي غيرخطـي و انعطاف‌پذيرشان است. در اين‌گونه از شبكه‌ها ديگر نيـازي به تشخيص شكل خـاص مـدل نبـوده و مـدل بـر اسـاس اطلاعات موجود در داده‌ها شـكل مـي‌گيـرد. ايـن رويكـرد مبتني بر داده براي بسياري از مجموعه داده‌هـاي تجربـي بخصوص زماني كه هيچ اطلاعات تئوريكي بـراي پيشـنهاد يک فرآيند توليد داده مناسب در دسـترس نباشـد، بسـيار كارآمد و كارا هستند. با وجود همه مزيت‌هـايي كـه بـراي شبكه‌هاي عصبي مصنوعي در نظرگرفته مي‌شود، اين‌گونـه از شبكه‌ها معايبي نيز دارند كه از جملـه مهـم‌تـرين آنهـا مي‌توان به نياز به داده‌هاي زياد براى حصول نتـايج دقيـق اشاره كرد.

هر چند قانون تعريف شـده‌اي بـراي تعيـين تعـداد داده‌هاي مورد نياز شـبكه، بـراي مسـائل مختلـف تبيـين نشده است، اما در حالت كلي تعـداد داده‌هـاي مـورد نيـاز شبكه بـه سـاختار شـبكه، الگـوريتم آمـوزش، پيچيـدگي مسئله مورد نظر و اختلال‌هاى موجـود در داده‌هـا وابسـته اسـت. نـام و اسـكيفر [۲] تـأثيرات انـدازه‌هـاى متفـاوت داده‌هاي مورد نياز شبكه را آزمايش كرده و دريافتنـد كـه افزايش تعداد داده‌ها، عملكرد شبكه عصبي مصنوعي را در مسائل پيش‌بيني بهتر خواهد كرد و به دست آوردن سطح معيني از دقت، نياز به داده‌هاي آمـوزش بـا مقـدار معـين دارد.

با تعداد داده‌هاي كافي، شبكه‌هاي عصبي مـي‌تواننـد سـاختارهاي پيچيـده موجـود در داده‌هـا را مـدل كننـد. بنـابراين، بـراي نمونـه‌هـاي بـزرگ شـبكه‌هـاي عصـبي سودمندتر از ساير مدل‌هاي آماري خطي خواهند بود. البته اين نكته هـم قابـل توجـه اسـت كـه شـبكه‌هـاي عصـبي مصـنوعي نيـاز بـه تعـداد داده‌هـاي بيشـتري نسـبت بـه مدل‌هاي خطي براى رسيدن به عملكرد مناسب را ندارنـد. "كانـگ" دريافـت كـه شـبكه‌هـاي عصـبي مصـنوعي پيش‌بيني‌هاي كاملاً خوبي با داده‌هاي كمتر از ۵۰ خواهند داشت، در صـورتي كـه مـدل‌هـاي بـاكس- جكينـز بـراي

* نويسنده مسئول : تلفن : ۰۳۱۱ -۳۹۱۲۵۵۰۱, فاكس : ۰۳۱۱ -۳۹۱۵۵۲۶ Email: Khashei@in.iut.ac.ir

پیش‌بینی‌های موفق، دست کم احتیاج به ۵۰ داده، دارند[۳].

روش‌های پیش‌بینی فازی همچون رگرسیون فازی به دلیل استفاده از اعداد فازی به جای اعداد قطعی نیاز به داده‌های کمتری نسبت به سایر مدل‌های پیش‌بینی دارند، اما عملکرد این گونه از روش‌ها در حالت کلی، به ویژه در محیط‌هایی با تغییرات سریع، داده‌های پرت و یا تغییرات معنی‌دار بین داده‌ها، چندان رضایت‌بخش نیست. تاناکا [۵-۴] برای جلوگیری از خطای مدل‌سازی، رگرسیون فازی را که یک مدل پیش‌بینی فاصله‌ای است پیشنهاد داده است، اما این مدل نیز معایبی دارد که از جمله مهم‌ترین آنها می‌توان به وسیع‌شدن بیش از حد فاصله پیش‌بینی که به دلیل وجود برخی از مقادیر پرت ایجاد می‌شود، اشاره کرد. سری‌های زمانی فازی توسط سانگ و چیزوم [۷-۶] بر اساس معادلات فازی و منطق تقریبی مدلسازی و مطرح شدند. چن[۸] نیز یک روش سری زمانی بر اساس سری‌های زمانی و مفاهیم سانگ و چیزوم، پیشنهاد داده است.

استفاده از مدل‌های ترکیبی یا ترکیب مدل‌های مختلف، یک راه معمول در بهبود دقت پیش‌بینی‌ها است. شبکه‌های عصبی- فازی، کلاس خاصی از مدل‌های ترکیبی هستند که از ترکیب شبکه‌های عصبی مصنوعی و سیستم‌های منطق فازی تشکیل می‌شوند[۱۰-۹]. در این گونه از روش‌ها از الگوریتم‌های یادگیری شبکه‌های عصبی برای تعیین عوامل سیستم منطق فازی استفاده می‌شود. شبکه‌های عصبی- فازی همچون *ANFIS* [۱۱] از زمان معرفی تا به امروز، در بسیاری از مسائل پیش‌بینی در زمینه‌های مختلف علوم مورد استفاده قرار گرفته‌اند و نتایج مطلوبی نیز ارائه کرده‌اند [۱۲].

هانگ و لی با استفاده از شبکه‌های عصبی- فازی قیمت الکتریسیته مصرفی را پیش‌بینی کرده‌اند[۱۳]. آبراهام و نس تقاضای مصرف الکتریسیته را با استفاده از مدل‌های عصبی- فازی مدل‌سازی کرده‌اند[۱۴]. لی و وانگ نیز با به کارگیری سیستم‌های عصبی- فازی چند متغیره مسئله مدیریت ریسک در بازارهای مالی را بررسی کرده‌اند[۱۵]. با وجود اینکه شبکه‌های عصبی- فازی، نتایج دقیق‌تری نسبت به سایر مدل‌های فازی ارائه می‌کنند، اما معایبی همچون به کارگیری در شرایط خاص (محیط‌هایی با تغییرات سریع، داده‌های پرت و یا تغییرات معنی‌دار بین داده‌ها)، همچنان در این گونه از مدل‌ها وجود دارد.

در این مقاله برای پیش‌بینی‌های بهتر، حصول نتایج دقیق‌تر و همچنین نیاز به تعداد داده‌های کمتر، از مفاهیم روش رگرسیون فازی استفاده شده است تا بتوان از مزایای موجود در این روش برای پیش‌بینی‌های بهتر استفاده کرده و محدودیت نیاز به داده‌های زیاد در شبکه‌های عصبی مصنوعی را نیز تا حد امکان رفع کرد.

سایر قسمت‌های این مقاله بدین ترتیب است: در بخش دوم، روش شبکه‌های عصبی مصنوعی در مدل‌سازی سری‌های زمانی شرح داده شده است. مدل رگرسیون فازی در بخش سوم توضیح داده شده است. در بخش چهارم مدل ترکیبی شبکه‌های عصبی مصنوعی با رگرسیون فازی تشریح شده است. استفاده از مدل ترکیبی در پیش‌بینی قیمت طلا و مقایسه‌ی عملکرد آن با مدل شبکه‌های عصبی مصنوعی، رگرسیون فازی و شبکه‌های عصبی- فازی در بخش پنجم آورده شده است، در نهایت نیز نتایج حاصله مورد تجزیه و تحلیل قرارگرفته‌اند.

شبکه‌های عصبی مصنوعی در مدل‌سازی سری‌های زمانی

شبکه‌های عصبی مصنوعی از جمله روش‌هایی هستند که قادر به تخمین موارد غیرخطی متعدد در داده‌ها بوده و یک چارچوب محاسبه‌ای انعطاف‌پذیر برای دامنه وسیعی از مسائل غیرخطی هستند.. یکی از مزیت‌های بارز این گونه از مدل‌ها نسبت به مدل‌های غیرخطی دیگر، این است که شبکه‌های عصبی مصنوعی یک تقریب‌زننده جهانی هستند که می‌توانند هر نوع تابعی را با دقت دلخواه تقریب بزنند[۱۶].

این‌گونه از شبکه‌ها به هیچ‌گونه پیش‌فرضی در مورد شکل مدل در فرآیند مدل‌سازی نیاز ندارند و به طور کلی یک مدل مبتنی بر داده هستند. شبکه‌های عصبی پیشرو با یک لایه مخفی یکی از پرکاربردترین مدل‌های شبکه‌های عصبی برای پیش‌بینی سری‌های زمانی هستند[۱۷].

این‌گونه مدل‌ها از سه لایه پردازش ساده اطلاعات متصل به هم تشکیل شده‌اند. رابطه بین خروجی (y_t) و ورودی‌ها ($y_{t-1},...,y_{t-p}$) در این‌گونه از شبکه‌ها به این ترتیب است:

$$y_t = b_0 + \sum_{j=1}^{q} w_j \cdot g(b_{0j} + \sum_{i=1}^{p} w_{i,j} \cdot y_{t-i}) + \varepsilon_t \qquad (۱)$$

به طوري كه $w_{i,j}, w_j$ عوامل مدل بوده كه اغلب وزن‌هـاي اتصالي ناميده مي‌شوند، p تعداد گره‌هاي ورودي و q تعداد گره‌هاي مخفي هستند. توابـع سـيگموئيدي(رابطـه ۲) و خطي از جمله توابعي هستند كـه اغلـب بـه عنـوان توابـع فعال‌سازي براي لايه‌هاي مخفي و خروجي مـورد اسـتفاده قرار مي‌گيرند.

$$Sig(x) = \frac{1}{1 + exp(-x)} \qquad (۲)$$

از اين رو مدل شبكه‌هاي عصبي مصنوعي رابطه (۱) در حقيقت به عنوان يک نگاشت غيرخطي از مشاهده‌های گذشته به مقدار آينده خواهند بود، به عبارت ديگر:

$$y_t = f(y_{t-1}, ..., y_{t-p}, w) + \varepsilon_t \qquad (۳)$$

به طوري كه w بردار همه عوامل و f تابعي است كه توسط ساختار شبكه عصبي و وزن‌هاي اتصالي تعيين مي‌شود.

بنابراين شبكه‌ی عصبي معادل يک مدل خودرگرسيون غيرخطي است. رابطه‌ی(۳) همچنين بيانگر اين موضوع است كه يک نرون (خروجي) در لايه خروجي براي پيش‌بيني يک مرحله‌اي مورد استفاده قرار مي‌گيرد. مدل ساده بيان‌شده توسط رابطه‌ی(۳) قدرت تقريب بسيار زيادی دارد؛ چرا كه به شرط آنكه تعداد گره‌هاي مخفي (q) به اندازه كافي بزرگ باشند، قادر است هر تابع دلخواه را تقريب بزند. در عمل اغلب ساختار شبكه عصبي ساده كه تعداد نرون كمتري در لايه مخفي دارد، در پيش‌بيني‌هاي خارج از نمونه (داده‌هاي آزمون) بهتر عمل مي‌كند و اين به دليل دوري جستن از مسئله برازش بيش از حد است كه اغلب در فرآيند مدل‌سازي شبكه‌هاي عصبي رخ مي‌دهد[۱۸].

يک مدل بيش از حد برازش شده، براي داده‌هايي كه براي ساخت مدل استفاده شده باشند، برازش خوبي نشان مي‌دهد، اما توانايي تعميم آن، براي داده‌هاي خارج از نمونه، بسيار ضعيف خواهد بود. انتخاب تعداد نرون‌هاي لايه مخفي، وابسته به داده‌ها بوده و هيچ قانون سيستماتيكي برای تعيين اين عامل در طراحي شبكه‌هاي عصبـــي وجود ندارد. علاوه بر اين، مرحله مهم ديگر مدل‌سازي شبكه‌هاي عصبي، انتخاب تعداد وقفه‌هاي موجود در مشاهده‌ها به عنوان بردار ورودي شبكه است كه شايد مهم‌ترين عامل در طراحي مدل‌هاي شبكه‌هاي عصبي باشد؛ چرا كه اين عامل در تعيين ساختار خودهمبسته غيرخطي سري‌هاي زماني نقش اساسي دارد[۱۹].

هيچ تئوري خاصي برای انتخاب p وجود ندارد. از اين رو تجربه و آزمايش‌ها، مشخص‌كننده مقدار مناسب p و همچنين q خواهد بود. وقتي يک ساختار شبكه‌اي p و q مشخص شد، شبكه آماده آموزش و تخمين عوامل است. همانند مدل‌سازي خودرگرسيون ميانگين متحرک انباشته*(ARIMA)* عوامل طوري تخمين‌زده مي‌شوند كه معيار دقت مانند ميانگين مربع‌های خطاها *(MSE)* حداقل شود. فرآيند اين آموزش توسط الگوريتم‌هاي بهينه‌سازي غيرخطي همچون پس‌انتشار خطا انجام مي‌گيرد.

مدل برآوردشده اغلب توسط يک نمونه جداگانه كه در فرآيند آموزش مورد استفاده قرار نگرفته است(داده‌هاي آزمون) ارزيابي می‌شودو اين با فرآيند مدل‌سازي مدل خودرگرسيون ميانگين متحرک انباشته كه از يک نمونه برای شناسايي، تخمين و ارزيابي مدل استفاده مي‌كند متفاوت است. دليل اين موضوع نيز آن است كه شكل كلي مدل (خطي) براي مدل‌سازي اريما از قبل مشخص است[۲۰]، در صورتي كه در مدل‌سازي شبكه‌هاي عصبي اين طور نبوده و در مدل‌سازي با شبكه‌هاي عصبي مصنوعي مدل غيرخطي همانند مرتبه مدل بايد تخمين زده شود و ممكن است شبكه دچار برازش بيش از حد شود.

مدل رگرسيون فازي

مدل‌هاي كلاسيك از مفهوم عبارت خطا استفاده مي‌كنند. به عبارت ديگر، تخمين‌هاي اين گونه از مدل‌ها مقادير دقيقي بوده و شامل جمله خطا نمي‌شوند. اين همان مفهوم پايه‌اي رگرسيون فازي است كه توسط تاناكا و همكارانش [۴] پيشنهاد شده است. مفهوم اساسي تئوري فازي و رگرسيون فازي اين است كه جمله خطا از باقيمانده‌هاي بين مقادير تخمين‌زده شده و مقادير اصلي يا مشاهده‌ها توليد نمی‌شود، بلكه در نبود قطعيت عوامل مدل و امكان توزيع در ارتباط با مشاهده‌های حقيقي به كارگرفته مي‌شوند. يک مدل رگرسيون خطي فازي در حالت كلي به اين ترتيب است:

$$\widetilde{Y} = \widetilde{\beta}_0 + \widetilde{\beta}_1 x_1 + ... + \widetilde{\beta}_n x_n = \sum_{i=1}^{n} \widetilde{\beta}_i x_i = X'\widetilde{\beta} \qquad (۴)$$

به طوري كه X بردار متغيرهاي مستقل، علامت پريم "' " عملگر ترانهاده، n تعداد متغيرها و $\widetilde{\beta}_i$ مجموعه‌هاي فازي بيانگر i امين عامل مدل هستند. اين اعداد فازي (عوامل $\widetilde{\beta}_i$) به شكل اعداد فازي نوع- ال دابيوس و پريس [۲۱] $(\alpha_i, c_i)_L$ با توزيع احتمال به شكل زير هستند:

$$\mu_{\widetilde{\beta}_i}(\beta_i) = L\{(\alpha_i - \beta_i / c)\} \qquad (۵)$$

به طوري كه L يک تابع است. عوامل فازي نيز به شكل اعداد فازي مثلثي به كار گرفته شده‌اند.

$$\mu_{\widetilde{\beta}_i}(\beta_i) = \begin{cases} 1 - \dfrac{|\alpha_i - \beta_i|}{c_i} & \alpha_i - c_i \le \beta_i \le \alpha_i + c_i, \\ 0 & otherwise, \end{cases} \qquad (۶)$$

به طوري كه $\mu_{\widetilde{\beta}_i}(\beta_i)$ تابع عضويت مجموعه فازي بيانگر عوامل β_i است. α_i نيز مركز عدد فازي و c_i گسترش حول مركز هستند. حال با توجه به اصل گسترش، تابع عضويت عدد فازي $\widetilde{y}_t = X_t'\widetilde{\beta}$ را مي‌توان بدين ترتيب تعريف كرد:

$$\mu_{\widetilde{y}}(y_t) = \begin{cases} 1 - \dfrac{|y_t - X_t\alpha|}{c'|X_t|} & for \;\; X_t \neq 0, \\ 1 & for \;\; X_t = 0, \;\; y_t = 0, \\ 0 & for \;\; X_t = 0, \;\; y_t \neq 0, \end{cases} \qquad (۷)$$

به طوري كه α و c به ترتيب بردار مقادير مربوط به عوامل و گسترش‌هاي آنها حول مركز هستند. به طور كلي مدل از حداقل‌كردن كل ابهام‌ها(كه برابر با مجموع گسترش‌هاي تكي و مربوط به هر يک از عوامل فازي مدل است) استفاده مي‌كند.

$$Minimize \quad S = \sum_{t=1}^{k} c'|X_t| \qquad (۸)$$

اين روش همچنين به طور همزمان شرايطي را كه مقدار عضويت به ازاي هر مشاهده y_t بزرگ‌تر از يک حد آستانه تعيين شده در سطح h است($h \in [0,1]$) را نيز در نظر مي‌گيرد. اين معيار، بيانگر اين حقيقت است كه خروجي فازي مدل بايد براي همه نقاط داده‌اي $y_1, y_2, ..., y_k$ بيشتر از مقدار انتخابي سطح h باشد. انتخاب مقدار سطح h بر گسترش‌هاي عوامل فازي مدل مؤثر است.

$$\mu_{\widetilde{y}}(y_t) \ge h \qquad for \;\; t = 1,2,...,k \qquad (۹)$$

شاخص t به تعداد داده‌هاي غيرفازي به كار گرفته شده در ساخت مدل بر مي‌گردد. مسئله‌ی پيداكردن عوامل رگرسيون فازي توسط تاناكا به شكل يک برنامه‌ريزي خطي فرموله شده است[۵]:

$$\begin{aligned} Min \quad & S = \sum_{t=1}^{k} c'|X_t| \\ & X_t'\alpha + (1-h)c'|X_t| \ge y_t \qquad t = 1,2,....,k \\ sub.to \quad & X_t'\alpha - (1-h)c'|X_t| \le y_t \qquad t = 1,2,...,k \\ & c \ge 0 \end{aligned} \qquad (۱۰)$$

به طوري كه $\alpha' = (\alpha_1, \alpha_2, ..., \alpha_n)$ و $c' = (c_1, c_2, ..., c_n)$ بردار متغيرهاي مجهول و S كل ابهامي است كه پيش از اين تعريف شده است.

فرموله‌كردن مدل تركيبي

شبكه‌هاي عصبي مصنوعي، مدل‌هاي پيش‌بيني دقيقي براي دامنه وسيعي از مسائل هستند، اما داراي محدوديت تعداد زياد داده‌هاي گذشته براى حصول نتايج دقيق هستند. در صورتي كه امروزه به دليل نبود قطعيت محيط و توسعه سريع تكنولوژي‌هاي نوين، اغلب بايد موقعيت‌هاي آينده را با استفاده از داده‌هاي كم و در بازه‌هاي زماني كوتاه‌مدت پيش‌بيني كرد. بنابراين در دنياي امروز به روش‌هاي پيش‌بيني نياز است كه به داده‌هاي كمتري نياز داشته و در اين گونه از شرايط نيز كارآمد و كارا باشند. مدل رگرسيون فازي يک مدل پيش‌بيني بازه‌اي مناسب در شرايط داده‌هاي قابل حصول كم است، اما هميشه عملكرد مناسبي ندارند. هدف اين مقاله بهره‌گيري از مزيت‌هاي رگرسيون فازي براي پيش‌بيني سري‌هاي زماني و بر طرف كردن محدوديت نياز به داده‌هاي زياد در روش شبكه‌هاي عصبي مصنوعي براى پيش‌بيني است. عوامل شبكه‌هاي عصبي (وزن‌ها و بايا‌س‌ها) مقاديري قطعي هستند($w_j, w_{i,j}$ و $b_0, b_{0,j}$)، در صورتي كه در روش پيشنهادي به جاي به كارگيري اين مقادير قطعي، عوامل مربوط به لايه نهايي به صورت

اعداد فازي مثلثي در نظرگرفته شده‌اند($\widetilde{w}_j, \widetilde{b}_0$). علاوه بر این، در این مقاله متدولوژي ارائه شده توسط ایشیبوچي و تاناکا [۲۲] براي شرایطي که دامنه پیش‌بیني وسیع می‌شود، به کار گرفته شده است. یک مدل ترکیبي با توابع و عوامل فازي در حالت کلي به این ترتیب است.

$$\widetilde{y}_t = \widetilde{b}_0 + \sum_{j=1}^{q} \widetilde{w}_j \cdot g(b_{0j} + \sum_{i=1}^{p} w_{i,j} \cdot y_{t-i}) \qquad (۱۱)$$

که y_t مشاهدها و $\widetilde{b}_0, \widetilde{w}_j$ اعداد فازي هستند. حال معادله(۱۱) با جایگذاري $u_{t,j} = g(b_{0,j} + \sum_{i=1}^{p} w_{i,j} \cdot y_{t-i})$ به شکل زیر تبدیل می‌شود:

$$\widetilde{y}_t = \widetilde{b}_0 + \sum_{j=1}^{q} \widetilde{w}_j \cdot u_{t,j} = \sum_{j=0}^{q} \widetilde{w}_j \cdot u_{t,j} \qquad (۱۲)$$

عوامل فازي در این معادله به شکل اعداد فازي مثلثي مطابق زیر در نظرگرفته شده‌اند:

$$\mu_{\widetilde{\beta}_i}(\beta_i) = \begin{cases} 1 - \dfrac{|\alpha_i - \beta_i|}{c_i} & \alpha_i - c_i \le \beta_i \le \alpha_i + c_i, \\ 0 & otherwise \end{cases} \qquad (۱۳)$$

تابع عضویت مجموعه فازي است $\mu_{\widetilde{\beta}}(\beta_i)$؛به طوري که مشخص می‌شود. حال با استفاده از عوامل β_i که با عوامل به صورت اعداد فازي مثلثي و همچنین اصل β_i فازي مطابق ذیل خواهد بود[۵]. y_tگسترش، تابع عضویت

$$\mu_{\widetilde{y}}(y_t) = \begin{cases} 1 - \dfrac{\left| y_t - \sum_{j=0}^{q} \alpha_j \cdot u_{t,j} \right|}{\sum_{j=0}^{q} c_j |u_{t,j}|} & for \;\; u_{t,j} \neq 0 \\ 0 & otherwise \end{cases} \qquad (۱۴)$$

حال با در نظر گرفتن سطح آستانه‌ي h براي میزان توابع عضویت همه‌ی مشاهده‌ها مطابق رابطه‌ی (۱۵)

$$\mu_{\widetilde{y}}(y_t) \ge h \qquad for \;\; t = 1,2,....,k \qquad (۱۵)$$

و مقدار تابع هدف S مطابق رابطه‌ی زیر:

$$S = \sum_{j=0}^{q} \sum_{t=1}^{k} c_j |w_j| |u_{t,j}| \qquad (۱۶)$$

به قسمي که w_j وزن‌هاي ارتباطي بین نرون خروجي و نرون jام لایه میاني هستند، خواهیم داشت.

$$\begin{aligned} Min \quad & S = \sum_{j=0}^{q} \sum_{t=1}^{k} c_j |w_j| |u_{t,j}| \\ & \sum_{j=0}^{q} \alpha_j u_{t,j} + (1-h)\left(\sum_{j=0}^{q} c_j |u_{t,j}| \right) \ge y_t \\ S.T \quad & \sum_{j=0}^{q} \alpha_j u_{t,j} - (1-h)\left(\sum_{j=0}^{q} c_j |u_{t,j}| \right) \le y_t \\ & c_j \ge 0 \qquad for \; j = 0,1,...,q \quad t = 1,2,..,k \end{aligned} \qquad (۱۷)$$

مراحل روش ترکیبي به طور خلاصه به ای‌ن شرح است:

مرحله اول: آموزش یک مدل شبکه عصبي با استفاده از اطلاعات موجود در مشاهده‌ها(که به صورت غیرفازي هستند). نتیجه مرحله اول، جواب بهینه عوامل $w^* = \left(w_0^*, w_1^*, ..., w_q^*\right)$ است که به عنوان یکي از مجموعه داده‌هاي ورودي در مرحله دوم مورد استفاده قرار مي‌گیرند.

مرحله دوم: تعیین حداقل ابهام با استفاده از معادله‌ی (۱۷) و وزن‌هاي حاصله از مرحله‌ی اول $w^* = \left(w_0^*, w_1^*, ..., w_q^*\right)$. تعداد محدودیت‌ها برابر با تعداد مشاهده‌ها است و مدل ترکیبي بدین ترتیب خواهد بود:

$$\widetilde{y}_t = \langle \alpha_0, c_0 \rangle u_{0,t} + \langle \alpha_1, c_1 \rangle u_{1,t} + ... + \langle \alpha_q, c_q \rangle u_{q,t} \qquad (۱۸)$$

که α_i, c_i به ترتیب مراکز و گسترش‌هاي اعداد فازي هستند.

مرحله سوم: با توجه به نظرات ایشیبوچي داده‌هاي حد بالا و پایین مدل وقتي که دامنه مدل ترکیبي وسیع شود، حذف خواهند شد. برای ساختن مدلي شامل همه شرایط ممکن، اگر مجموعه داده‌ها شامل تفاوت‌هاي مشخص یا موارد خارج از محدوده باشند، c_jها بسیار گسترده خواهند شد. طبق نظرات ایشیبوچي [۲۲] داده‌هاي اطراف مرزهاي بالا و پایین مدل حذف می‌شود، سپس مدل بار دیگر فرمول‌بندي می‌شود.

به کارگیري مدل ترکیبي برای پیش‌بیني قیمت طلا

از مدل حاصله، در این قسمت برای پیش‌بیني دامنه تغییرات قیمت طلا استفاده شده است. اطلاعات

استفاده‌شده در اين تحقيق شامل ۴۰ داده روزانه قيمت طلا(يک مثقال طلاي ۱۸عيار) از شنبه پنجم آذرماه تا چهارشنبه بيست و هشتم دي‌ماه سال ۱۳۸۴ است که در شکل(۱) نمايش داده شده است. لازم به ذکر است داده‌ها مربوط به روزهاي شنبه تا چهارشنبه هر هفته بوده و براي روزهاي ديگر قيمتي اعلام نشده است.

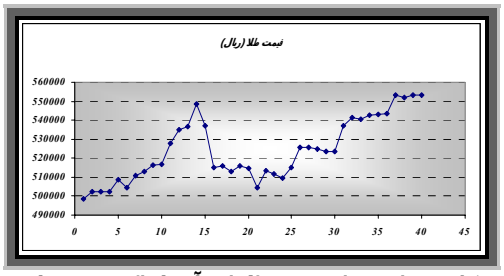

شکل ۱:: داده روزانه قيمت طلا از۵ آذرماه الي ۲۸ دي‌ماه ۱۳۸۴(ريال).

پيش‌بيني

با به کارگيري مدل ترکيبي ابتدا ۳۵ مشاهده (پنج هفته اول) براي آموزش شبکه و سپس ۵ مشاهده (هفته آخر) براي آزمايش عملکرد مدل مورد استفاده قرار گرفته‌اند.

مرحله اول: با توجه به اصول طراحي شبکه‌هاي عصبي مصنوعي[۲۳] و به کارگيري نرم‌افزار *MATLAB7* شبکه ايدآل، شبکه $N^{(2-3-1)}$ بوده است. مدل حاصله در شکل(۲) نشان داده شده است: وزن‌ها و بايا‌س‌هاي شبکه ذکرشده در جدول(۱) آورده شده است.

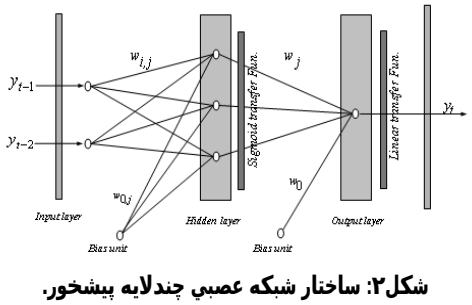

شکل۲: ساختار شبکه عصبي چندلايه پيشخور.

همچنين مقادير واقعي و برازش‌شده توسط شبکه را مي‌توانيد در شکل(۳) مشاهده کنيد. معيارهاي عملکردي اين شبکه نيز در جدول(۲) آورده شده است.

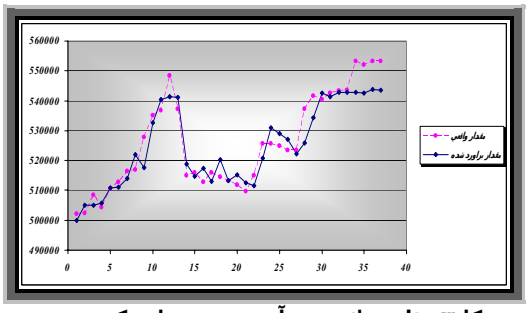

شکل۳: مقادير واقعي و برآوردشده توسط شبکه عصبي.

مرحله دوم (تعيين حداقل ابهام): با قراردادن وزن‌هاي مرحله اول $(w_0^*, w_1^*, w_2^*, w_3^*) = (-11.712, -5.280, 0.5096, 17.275)$ عوامل فازي مدل با استفاده از معادله‌ی (۱۷) به دست آمده‌اند($h=0$). نتايج حاصله در شکل (۴) آورده شده است.

$$\tilde{y}_t = \langle -19.852, 0.000 \rangle u_{1,t} + \langle 0.6175, 0.000 \rangle u_{2,t} + \langle 20.133, 0.1649 \rangle u_{3,t} \qquad (۱۹)$$

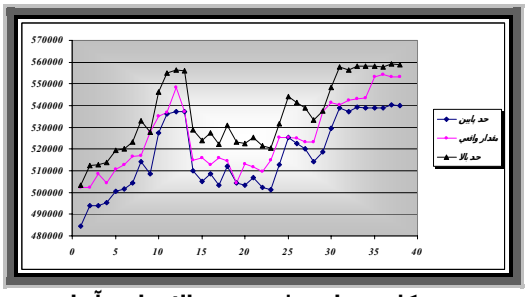

شکل ۴: مقادير واقعي و حد بالا و پايين آنها.

همان طور که در شکل(۴) مشاهده مي‌شود، مقادير واقعي در فواصل فازي قرار گرفته‌اند، اما طول فواصل فازي وسيع شده و مدل ترکيبي فواصل مناسبي را به دست نمي‌دهد.

مرحله سوم: از نتايج به دست آمده مشخص مي‌شود که مشاهده مربوط به بيست و پنجم آذرماه(شماره ۱۹) در مرز پايييني قرار گرفته است، بنابراين محدوديت خطي که توسط اين مشاهده توليد شده است را حذف کرده و سپس مرحله دوم بار ديگر تکرار مي‌شود($h=0$). نتايج حاصله در شکل (۴) آورده شده است.

$$\tilde{y}_t = \langle -20.666, 0.000 \rangle u_{1,t} + \langle 0.5158, 0.000 \rangle u_{2,t} + \langle 23.020, 0.1366 \rangle u_{3,t} \qquad (۲۰)$$

جدول۱:مقادیر مربوط به وزن‌ها و بایاس‌هاي شبکه نهايي پيش‌بيني قيمت.

Input Weights			*Hidden*	*Biases*	
$W^1_{i,1}$	$W^1_{i,2}$	$W^1_{i,3}$	*Weights*	$W_{0,i}$	W_0
۱/۳۱۱۳	۳۱/۹۸۹	-۶/۲۲۳۳	-۵/۲۷۹۸	۲۰/۹۷۸۸	-۱۱/۷۱۱۵
-۶/۷۵۸۵	-۲۱/۴۳۲۵	۱۰/۳۹۶۱	۰/۵۰۹۶۴	-۴/۷۶۶۳	
			۱۷/۲۷۵۲	۴/۳۰۶۲	

جدول۲:معيارهاي عملكرد شبكه عصبي در پيش‌بيني قيمت.

آموزش		تست					
MSE	*MAE*	*MSE*	*SSE*	*RMSE*	*ME*	*MAPE*	*MAE*
۱/۸*۱۰^{۷}	**۳۴۰۷**	۸/۶*۱۰^{۷}	۴/۳*۱۰^{۸}	۴۲۹۱	**۸۴۱۶**	۱/۵۲۰	**۸۴۱۶**

جدول۳: حدود بالا و پايين و مقادير اصلي داده‌هاي آزمايش.

تاريخ	مقادير واقعي	حدپايين مقادير		حد بالاي مقادير	
		بعد از حذف	قبل از حذف	بعد از حذف	قبل از حذف
شنبه ۲۴-دي	۵۴۳۶۰۰	۵۳۹۱۰۰	۵۳۹۱۰۰	۵۵۴۸۰۰	۵۵۸۱۰۰
يكشنبه۲۵-دي	۵۵۳۲۰۰	۵۳۹۲۰۰	۵۳۹۱۰۰	۵۵۴۹۰۰	۵۵۸۱۰۰
دوشنبه ۲۶-دي	۵۵۴۴۰۰	۵۳۸۷۰۰	۵۳۹۰۰۰	۵۵۴۴۰۰	۵۵۷۹۰۰
سه‌شنبه ۲۷-دي	۵۵۳۲۰۰	۵۴۰۱۰۰	۵۴۰۲۰۰	۵۵۵۹۰۰	۵۵۹۲۰۰
چهارشنبه۲۸-دي	۵۵۳۲۰۰	۵۴۰۰۰۰	۵۳۹۹۰۰	۵۵۵۷۰۰	۵۵۸۹۰۰

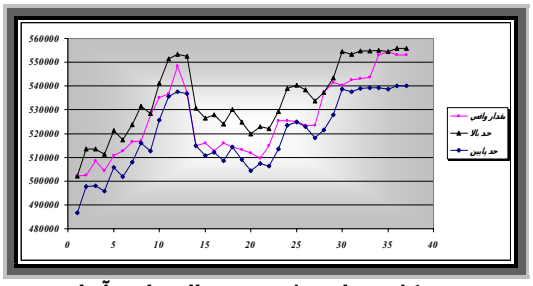

شكل۵: مقادير واقعي و حد بالا و پايين آنها.

در انتها نيز با استفاده از مدل تركيبي بازپيني‌شده، مقادير آينده متغير وابسته پيش‌بيني شده‌اند. نتايج مقادير پيش‌بيني‌شده در جدول(۳) آورده شده است. اين نكته قابل ذكر است كه داده‌هاي مربوط به حد بالا و پايين مقادير در جدول تا دو رقم گرد شده‌اند. همان طور كه مشاهده می‌شود، نتايج حاصله و فواصل فازي نسبت به مدل قبلي مطلوب‌تر است.

از مقايسه طول بازه پيش‌بيني‌شده توسط روش تركيبي با ميانگين قدرمطلق خطاي شبكه چندلايه پيشخور، با فرض توزيع يكنواخت مقادير واقعي در اطراف تابع برآورد شده و فضاي پيش‌بيني، نتايج حاصله بيانگر برتري اكيد روش تركيبي بر شبكه‌هاي عصبي مصنوعي است. همچنين پيش‌پردازش انجام‌شده بر داده‌هاي خام اوليه توسط شبكه‌هاي عصبي باعث بهبود نتايج روش تركيبي نسبت به روش رگرسيون فازي شده است. قابل ذكر است كه بازه به دست آمده از رگرسيون فازي بدون استفاده از شبكه‌هاي عصبي، بازه‌اي به طول ۲۸۰۰ تومان بوده است، در صورتي كه طول بازه پيش‌بيني‌شده توسط روش تركيبي ۱۶۰۰ تومان است و اين خود بيانگر بيش از ۷۵درصد بهبود در دقت نتايج است. مدل سري زماني فازي در شكل (۶) آورده شده است. مقايسه بين ميانگين مربع‌های خطاي مدل پيشنهادي (MSE= ۸/۶*۱۰^{۷}) و شبكه‌هاي عصبي- فازي (MSE= ۹/۹*۱۰^{۷}) نيز بيانگر بيش از ۱۳درصد بهبود در دقت نتايج و برتري مدل پيشنهادي بر مدل‌هاي عصبي- فازي در پيش‌بيني نقطه‌اي است و اين در حالي است كه مدل پيشنهادي در اساس براي پيش‌بيني بازه‌اي طراحي شده است.

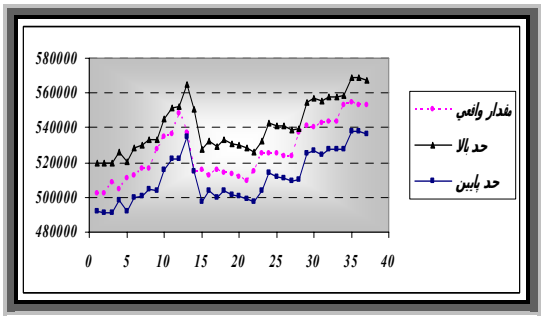

شكل۶: مدل سري زماني فازي.

نتيجه‌گيري

تغييرات تكنولوژيكي و جهاني‌شدن تجارت و بازارهاي مالي باعث شده است تا توانايي در پيش‌بيني دقيق‌تر و سريع‌تر الگوهاي موجود در حفظ توان رقابتي اهميت بيشتري پيدا كند. اما تغييرات سريع اين گونه از محيط‌هاي ناشناخته و به ويژه بازارهاي مالي، پيش‌بيني‌كنندگان را از نظر تأمين داده‌هاي لازم براى حصول نتايج مطلوب دچار مشكل كرده است. در اين مقاله بر اساس اصول و مفاهيم پايه‌اي شبكه‌هاي عصبي مصنوعي (*ANNs*) و رگرسيون فازي، مدلي از تركيب دو روش مزبور براى پيش‌بيني سري‌هاي زماني پيشنهاد شده است. مدل پيشنهادي با فازي در نظرگرفتن عوامل لايه ميانى شبكه چندلايه پيشخور(*FFNN*)، داده‌هاي مورد نياز براى حصول نتايج مطلوب را كاهش داده است. نتايج به دست آمده بيانگر آن است كه مدل تركيبي نه تنها توانايي انجام يک پيش‌بيني مناسب را داشته، بلكه براي تصميم‌گيرندگان بهترين و بدترين حالت ممكن را نيز فراهم مى‌كند. مدل پيشنهادي همچنين در شرايط برابر، عملكرد بهتري نسبت به شبكه‌هاي چندلايه پيشخور و رگرسيون فازي داشته است. بنابراين مدل پيشنهادي را مي‌توان به عنوان يک گزينه مناسب در پيش‌بيني سري‌هاي زماني، به ويژه در محيط‌هاي مالي و در شرايط داده‌هاي قابل حصول كم در نظر گرفت. در حالت كلي مزاياي روش تركيبي كه با به كارگيري شبكه‌هاي عصبي و منطق فازي در اين روش حاصل شده است را مي توان در موارد زير خلاصه كرد:

۱- بر طرف كردن مسئله كمبود داده‌ها
۲- ارائه بهترين و بدترين حالات ممكن
۳- حصول نتايج دقيق‌تر

مراجع

1- Zhang, G., Patuwo, B. E. and Hu, M Y. (1998), "Forecasting with artificial neural networks: The state of the art." *International Journal of Forecasting* 14, PP. 35- 62.

2- Nam, K. and Schaefer, T. (1995), "Forecasting international airline passenger traffic using neural networks."*Logistics and Trans portation* 31 (3), PP. 239–251.

3- Kang, S. (1991), *An Investigation of the Use of Feedforward Neural Networks for Forecasting*, Ph.D. Thesis, Kent State University.

4- Tanaka, H. (1987), "Fuzzy data analysis by possibility linear models.", *Fuzzy Sets and Systems*, 24(3), PP. 363- 375.

5- Tanaka, H. and Ishibuchi, H. (1992), *Possibility regression analysis based on linear programming*, in: J. Kacprzyk, M. Fedrizzi (Eds.), Fuzzy Regression Analysis, Omnitech Press, Warsaw and Physica-Verlag, Heidelberg, PP. 47 -60.

6- Song, Q. and Chissom, B.S. (1993), "Forecasting enrollments with fuzzy time series - part I," *Fuzzy Sets and Systems* 54(1), PP. 1- 9.

7- Song, Q. and Chissom, B.S. (1994), "Forecasting enrollments with fuzzy time series - part II", *Fuzzy Sets and Systems*, 62(1), PP. 1- 8.

8- Chen, S.M. (1996), "Forecasting enrollments based on fuzzy time series." *Fuzzy Sets and Systems*, 81(3), PP. 311-319.

9- Padmakumari, K., Mohandas, K. and Thiruvengadam, S. (1999), "Long term distribution demand forecasting using neuro fuzzy computations." *Electrical Power and Energy Systems* 21, PP. 315–322.

10- Nauck, D. and Kruse, R. (1999), "Neuro-fuzzy systems for function approximation." *Fuzzy Sets and Systems* 101, PP. 261-271.

11- JSR, J. (1993), ANFIS: Adaptive-network-based fuzzy inference system*, IEEE Trans Systems, Man, Cyb*. 23, PP. 665–85.

12- Wang, W. and Chen, Z. (2007), "A neuro-fuzzy based forecasting approach for rush order control applications." *Expert Systems with Applications* xxx, PP. xxx–xxx.

13- Hong, Y. and Lee, C. (2005), "A neuro-fuzzy price forecasting approach in deregulated electricity markets." *Electric Power Systems Research* 73, PP. 151–157.

14- Abraham, A. and Nath, B. (2001), "A neuro-fuzzy approach for modeling electricity demand in Victoria." *Applied Soft Computing* 1, PP. 127–138.

15- Lee, V. and Wong, H. (2007), "A multivariate neuro-fuzzy system for foreign currency risk management decision making." *Neurocomputing* 70, PP. 942–951.

16- Smith, K., Gupta, N. and Jatinder, D. (2000) "Neural networks in business: techniques and applications for the operations researcher." *Computers & Operations Research* 27, PP.1045-1076.

17- Hwarng, H B. and Ang, H. T. (2001), "A simple neural network for ARMA (p; q) time series." *Omega* 29, PP. 319 – 333.

18- Demuth, H. and Beale, B. (2004) *Neural Network Toolbox User Guide*, The Mathworks Inc, Natick.

19- Thawornwong, S. and Enke, D. (2000), "The adaptive selection of financial and economic variables for use with artificial neural networks." *Neurocomputing* 31, PP. 1-13.

20- Nasr, G., Badr, E.A. and Joun, C. (2003) "Back propagation neural networks for modeling gasoline consumption." *Energy Conversion and Management* 44, PP. 893 –905.

21- Dubois, D. and Prade, H. (1980), "Theory and Applications." *Fuzzy Sets and Systems*, Academic Press, New York.

22- Ishibuchi, H. and Tanaka, H. (1988) "Interval regression analysis based on mixed 0-1 integer programming problem." *J. Japan Soc. Ind. Eng*40, (5), PP. 312 - 319.

23- Khashei, M. (2005), *Forecasting and analysis of Esfahan Steel Company productions price in Tehran Metals Exchange using Artificial Neural Networks*, Master of Science Thesis, Isfahan University of Technology.