بهبود مدل‌هاي تركيبي(*ANNs & ARIMA*) با بكارگيري شبكه‌هاي عصبي احتمالي به‌منظور پـيش‌بيـني سري‌هاي زمـاني

مهدي خاشعي [۱]، مهدي بيجاري*[۲] و غلامعلي رئيسي اردلي[3]
[۱] دانشجوي دكتـري تخصصي مهندسي صنايع- دانشگاه صنعتي اصفهان
[۲] دانشيار دانشكده مهندسي صنايع- دانشگاه صنعتي اصفهان
[۳] استـاديـار دانشكـده مهنـدسي صنايـع- دانشگـاه صنعـتي اصفهـان
(تاريخ دريافت ۸۵/۱۰/۱۶ ، تاريخ دريافت روايت اصلاح شده ۸۹/۲/۵ ، تاريخ تصويب ۸۹/۷/۱۱)

چكيده

دقت پيش‌بيني‌ها از مهمترين فاكتورهاي مؤثر در انتخاب روش‌هاي پيش‌بيني مي‌باشند. امروزه علي‌رغم وجود روش‌هاي متعدد پيش‌بيني، هنوز پيش‌بيني‌هاي دقيق، بويژه در بازارهاي مالي كار چندان ساده‌اي نبوده و اكثر محققان درصدد بكارگيري و تركيب روش‌هاي متفاوت به‌منظور حصول نتايج دقيق‌تر مي‌باشند. در سال‌هاي اخير تلاش‌هاي فراواني به‌منظور بهبود روش‌هاي پيش‌بيني سري‌هاي زماني صورت گرفته است. مدل‌هاي تركيبي ميانگين متحرك خودرگرسيون انباشته (*ARIMA*) با شبكه‌هاي عصبي مصنوعي(*ANNs*) از اين جمله مدل‌هاي بهبوديافته مي‌باشند. اين‌گونه از مدل‌ها با بهره‌گيري از مزاياي منحصر به فرد هر يک از روش‌هاي مدل‌سازي خطي و غيرخطي، نتايج حاصله را بهبود بخشيده‌اند. در اين مقاله با استفاده از شبكه‌هاي عصبي احتمالي(*PNNs*) روند تغييرات باقيمانده‌هاي سري زماني مورد مطالعه تشخيص و دقت روش تركيبي بهبود داده شده است. نتايج حاصله از بكارگيري روش پيشنهادي در پيش‌بيني نرخ ارز موجب ۱۰ % بهبود نسبت به مدل تركيبي ميانگين متحرك خودرگرسيون انباشته با شبكه‌هاي عصبي مصنوعي در ميانگين قدرمطلق خطا گرديده است.

واژه‌هاي كليدي: مدل‌هاي خودرگرسيون ميانگين متحرك انباشته *(ARIMA)*، شبكه‌هاي عصبي احتمالي *(PNNs)*، شبكه‌هاي عصبي مصنوعي *(ANNs)*، بازارهاي مالي، پيش‌بيني نرخ ارز

مقدمه

بكارگيري روش‌هاي كمي به‌منظور پيش‌بيني بازارهاي مالي، بهبود تصميم‌گيري‌ها و سرمايه‌گذاري‌ها به ضرورتي انكارناپذير در دنياي امروز تبديل شده است[۱]. نرخ ارز يكي از مهمترين متغيرهاي مؤثر در سيستم‌هاي مالي بوده و پيش‌بيني آن مي‌تواند باعث بهبود قابل توجهي در عملكرد اين‌گونه از سيستم‌ها گردد. تحقيقات بسياري در زمينه پيش‌بيني نرخ ارز انجام شده است[۵-۲] كه تعداد اين انتشارات بيانگر اهميت مسئله مذكور مي‌باشد. امروزه علي‌رغم وجود روش‌هاي كمي متعدد جهت پيش‌بيني‌هاي مالي، هنوز پيش‌بيني‌هاي دقيق نرخ ارز كار چندان ساده‌اي نيست و اكثر محققان درصدد بكارگيري و مقايسه روش‌هاي متفاوت به‌منظور حصول نتايج دقيق‌تر مي‌باشند[۱۰-۶].

پـيش‌بينـي سـري‌هـاي زمـاني يكـي از مهمتـرين و پركـاربردترين زمينـه‌هـاي پـيش‌بينـي اسـت كـه در آن مشاهدات گذشته يک متغير جمع‌آوري و به‌منظور بدسـت آوردن روابط اساسي بين مشـاهدات و تعيـين يـک مـدل توصيفي، مورد تجزيه و تحليل قرارگرفتـه و سـپس مـدل حاصله به‌منظور برون‌يابي سري‌هاي زماني مـورد اسـتفاده قرار مي‌گيرد. اين روش مدل‌سازي مخصوصاً زمـاني مفيـد است كه در مورد فرآيند اساسي توليد داده‌ها دانش كمـي در دسترس باشد و يا هنگـامي كـه هـيچ مـدل توضـيحي رضايت‌بخشي كه بتواند متغير وابسته را به ساير متغيرهاي توضيحي مرتبط سازد وجود نداشته باشد.

در چند دهه اخير تلاش‌هاي بسياري به‌منظور توسعه و بهبود مدل‌هاي پيش‌بيني سري‌هاي زمـاني انجـام شـده است. يكي از مهمترين و پركـاربردترين مـدل‌هـاي خطـي سري زماني، مدل‌هـاي خودرگرسـيون ميـانگين متحـرك انباشته مي‌باشند. عموميت اين‌گونـه از مـدل‌هـا بـه دليـل خواص آماريشان و همچنـين متـدولوژي معـروف بـاكس-جنكينز [۱۱] در فرآيند مدل‌سازي ايـن‌گونـه از مـدل‌هـا مي‌باشد. اگرچه مدل‌هاي خودرگرسيون ميانگين متحـرك

*نويسنده مسئول : تلفن : ۰۳۱۱-۳۹۱۵۵۱۰ , فاكس : ۰۳۱۱-۳۹۱۵۵۲۶ ، Email: bijari@cc.iut.ac.ir

انباشته، اساساً به‌منظور مدل‌سازي ساختارهاي خطي طراحي گرديده‌اند، اما قابليت مدل‌سازي هر ساختار غيرخطي قابل تبديل به خطي، را نيز دارا مي‌باشند.

اخيراً شبكه‌هاي عصبي مصنوعي بطورگسترده‌اي مورد مطالعه قرارگرفته و در پيش‌بيني سري‌هاي زماني بكارگرفته شده‌اند، بطور مثال *زانگ* [۱۲] در مقاله‌اي اين‌گونه مدل‌ها را بطور كامل مرورکرده است. مزيت اصلي شبكه‌هاي عصبي قابليت مدل‌سازي غيرخطي انعطاف پذيرشان مي‌باشد. در شبكه‌هاي عصبي مصنوعي ديگر نيازي به تشخيص شكل خاص مدل نبوده و مدل براساس اطلاعات موجود درداده‌ها شكل مي‌گيرد[۱۳]. اين رويكرد مبتني بر داده براي بسياري از مجموعه داده‌هاي تجربي بالاخص زمانيكه هيچ اطلاعات تئوريكي براي پيشنهاد يک فرآيند توليد داده مناسب در دسترس نباشد، بسيار مناسب است.

دقت پيش‌بيني‌ها از مهمترين فاكتورهاي مؤثر در انتخاب روش‌هاي پيش‌بيني مي‌باشند. استفاده از مدل‌هاي تركيبي يا تركيب مدل‌هاي مختلف يک راه معمول در بهبود دقت پيش‌بيني‌ها مي‌باشد. ادبيات موضوع مربوط به مدل‌هاي تركيبي بسيار گسترده بوده و مطالعات فراواني از زمان اولين تحقيقات انجام شده در اين زمينه توسط *رید* [۱٤]، *بیتس و گرانجر* [۱۵] تاكنون صورت‌گرفته است. *کلمن*[۱٦] يک مرور كلي در اين زمينه انجام داده است. ايده اصلي تركيب چندين مدل در پيش‌بيني اين است كه از هر يک از مدل‌هاي تكي براي مدل‌سازي الگوهاي متفاوت موجود در داده‌ها استفاده گردند. يافته‌هاي تجربي و تئوريک نشان مي‌دهند كه تركيب مدل‌هاي متفاوت يک راه مؤثر و كارا براي بهبود دقت پيش‌بيني‌ها مي‌باشد[۱۹-۱۷].

در تحقيقات مربوط به پيش‌بيني با شبكه‌هاي عصبي مصنوعي مدل‌هاي تركيبي متعددي ارائه شده است. زانگ يک روش تركيبي شبكه‌هاي عصبي مصنوعي و روش ميانگين متحرک خودرگرسيون انباشته به‌منظور پيش‌بيني سري‌هاي زماني ارائه نموده است[۲۰]. *ودینگ و سیوس* [۲۱] يک روش تركيبي با استفاده از *شبکه‌های عصبی شعاعی محور* و مدل‌هاي *باکس-جنکینز* ارائه داده‌اند. *پای* [۲۲] رويكردي تركيبي از *ماشین‌های بردار پشتیبان* و مدل‌هاي خودرگرسيون ميانگين متحرک انباشته را به‌منظور پيش‌بيني مورد استفاده قرار داده است. *فانگ و همکارانش* نيز روشي تركيبي با استفاده از مدل‌هاي سري‌هاي زماني فصلي با شبكه‌هاي عصبي مصنوعي پيشنهاد كرده‌اند[۲۳]. *گینزبرگ و هورن* [۲٤] نيز تركيب چند شبكه عصبي پيشرو جهت بهبود دقت پيش‌بيني سري‌هاي زماني را پيشنهاد داده‌اند.

شناخت و طبقه‌بندي الگوها به مسئله‌اي مهم و قابل توجه در دنياي امروز تبديل‌شده است و تعداد تحقيقات متنوع انجام‌شده در اين زمينه در سال‌هاي اخير مبين اهميت اين موضوع مي‌باشد. شبكه‌هاي عصبي مصنوعي از جمله مهمترين و دقيق‌ترين روش‌هاي حال حاضر جهت شناخت و طبقه‌بندي الگوها مي‌باشند[۱۳]. بررسي ادبيات موضوع مربوط به پيش‌بيني، شناخت و طبقه‌بندي الگوها در محيط‌هاي مالي توسط شبكه‌هاي عصبي مصنوعي و تحقيقات متعدد انجام‌شده در انواع بازارهاي مالي همگي بيانگر اهمييت موضوع مورد بحث مي‌باشند[۲۷-۲۵].

شبكه‌هاي متعددي در زمينه شناخت الگو وجود دارند كه در يک تقسيم‌بندي كلي به دو دسته عمده باناظر و بدون ناظر تقسيم مي‌گردند. از جمله مهمترين شبكه‌هاي عصبي كه به‌منظور شناخت و طبقه‌بندي الگوها مورد استفاده قرارمي‌گيرند، مي‌توان به *شبکه‌های خودسازمان‌ده*، *شبکه‌های عصبی بیزین*، *شبکه‌های چندلایه پیشخور*، *شبکه‌های عصبی شعاعی محور* و *شبکه‌های عصبی احتمالی* اشاره نمود[۲۸]. شبكه‌هاي عصبي احتمالي يكي از موفقترين و كاربردي‌ترين نوع از اين شبكه‌ها بوده كه بر اساس نظر كارشناسان با در دسترس داشتن داده‌هاي مشخص ابزارهاي قدرتمندي جهت شناخت و طبقه‌بندي الگوها با بيشترين احتمال موفقيت مي‌باشند[۲۹].

شبكه‌هاي عصبي احتمالي نيز در سال‌هاي اخير در مقالات بسياري به‌عنوان ابزار پيش‌بيني و شناخت الگو مورد توجه قرارگرفته و نتايج مطلوبي نيز در مقايسه با ساير روش‌هاي ارائه نموده است[۳۰]. چن و همكارانش از شبكه‌هاي عصبي احتمالي به‌منظور تشخيص روند و پيش‌بيني شاخص بورس اوراق بهادار استفاده نموده و نتايج حاصله را با روش‌هاي ديگر مقايسه نموده‌اند. مطابق با نظرات آنها شبكه‌هاي عصبي احتمالي ابزارهاي مناسب‌تري در مقايسه با ساير روش‌هاي بكارگرفته‌شده در مسئله مورد مطالعه آنها بوده است[۳۱]. *کیم و چان* نيز تحقيقي مشابه از بكارگيري شبكه‌هاي عصبي احتمالي در

بارزار بورس ارائه نموده‌اند[۳۲]. *یانگ و همکارانش* نیز از شبکه‌هاي عصبي احتمالي به‌منظور پيش‌بيني و تشخيص ورشکستگي بانک‌ها استفاده نموده‌اند[۳۳].

بر اساس مطالب بيان شده، در اين مقاله به‌منظور تشخيص روند موجود در باقيمانده‌هاي سري زماني مورد مطالعه و بهبود نتايج حاصله، از شبکه‌هاي عصبي احتمالي، استفاده شده است. در روش پيشنهادي، ابتدا با استفاده از روش ترکيبي خودرگرسيون ميانگين متحرک انباشته و شبکه‌هاي عصبي مصنوعي مقادير سري زماني پيش‌بيني مي‌گردد، سپس با بکارگيري مقادير بدست آمده از مدل ترکيبي به‌عنوان ورودي‌هاي شبکه عصبي احتمالي روند تغييرات باقيمانده‌هاي سري زماني تشخيص داده مي‌شوند. سپس با انتخاب طول گام مناسب و بر اساس روند تشخيصي مقادير پيش‌بيني‌شده توسط روش ترکيبي اصلاح مي‌گردند.

ساير قسمتهاي اين مقاله بدين صورت مي‌باشند: روش ترکيبي خودرگرسيون ميانگين متحرک انباشته با شبکه‌هاي عصبي مصنوعي به همراه خلاصه‌اي از مفاهيم مدل‌هاي خودرگرسيون ميانگين متحرک انباشته و شبکه‌هاي عصبي مصنوعي به‌منظور مدل‌سازي سري‌هاي زماني در بخش دوم شرح داده‌شده‌اند. مفاهيم پايه‌اي شبکه‌هاي عصبي احتمالي در طبقه‌بندي الگوها در بخش سوم توضيح داده‌شده‌اند. در بخش چهارم مراحل مدل‌سازي روش پيشنهادي ارائه‌شده است. در بخش پنجم با استفاده از روش پيشنهادي، مقادير مربوط به نرخ ارز (يورو در مقابل ريال ايران) پيش‌بيني‌شده و عملکرد آن با مدل ترکيبي مقايسه شده است، در نهايت نيز نتيجه‌گيري آورده شده است.

مدل ترکيبي ميانگين متحرک خودرگرسيون انباشته با شبکه‌هاي عصبي مصنوعي

به‌منظور تشريح مدل ترکيبي ميانگين متحرک خودرگرسيون انباشته با شبکه‌هاي عصبي مصنوعي، در اين قسمت ابتدا به اختصار دو روش خودرگرسيون ميانگين متحرک انباشته کلاسيک و شبکه‌هاي عصبي مصنوعي توضيح داده شده‌اند.

مدل خودرگرسيون ميانگين متحرک انباشته (ARIMA)

در مدل‌هاي خودرگرسيون ميانگين متحرک انباشته، مقادير آينده متغير به‌عنوان تابعي خطي، از مشاهدات گذشته و خطاهاي تصادفي فرض مي‌شوند، يعني اينکه فرآيند اساسي که سري زماني را توليد مي‌نمايد بدين صورت مي‌باشد :

$$y_t = \theta_0 + \phi_1 y_{t-1} + ... + \phi_p y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - ... - \theta_q \varepsilon_{t-q} \qquad (۱)$$

بطوريکه ε_t, y_t به‌ترتيب مقادير واقعي و خطاهاي تصادفي در دوره t، $\phi_i \ (i = 1,2,..., p)$ و $\theta_j \ (j = 1,2,..., q)$ پارامترهاي مدل و p ، q اعداد صحيح و بيانگر مرتبه مدل مي‌باشند. خطاي تصادفي ε_t نيز مستقل و داراي توزيع يکنواخت با ميانگين صفر و واريانس ثابت σ^2 فرض مي‌شود. معادله (۱) چندين حالت خاص از خانواده مدل‌هاي خودرگرسيون ميانگين متحرک انباشته را شامل مي‌گردد، اگر $q=0$ باشد معادله (۱)، يک معادله خودرگرسيون از درجه p مي‌باشد و وقتي $p=0$ باشد مدل به يک مدل ميانگين متحرك از درجه q تبديل مي‌شود.

روش شبکه‌هاي عصبي مصنوعي(ANNs)

شبکه‌هاي عصبي مصنوعي يکي از جمله روش‌هاي غيرخطي مي‌باشند که قادر به تخمين موارد غيرخطي متعدد در داده‌ها بوده و يک چارچوب محاسبه‌اي انعطاف‌پذير براي دامنه وسيعي از مسائل غيرخطي مي‌باشند[۱۳]. يکي از مزيت‌هاي بارز اين‌گونه مدل‌ها نسبت به ساير مدل‌هاي ديگر غيرخطي، اين است که شبکه‌هاي عصبي مصنوعي يک *تقريب‌زننده جهاني* هستند که مي‌توانند هر نوع تابعي را با دقت دلخواه تقريب بزنند. اين‌گونه از شبکه‌ها نياز به هيچ‌گونه پيش فرضي در مورد شکل مدل در فرآيند مدل‌سازي نداشته و بطور کلي يک مدل مبتني بر داده مي‌باشند. شبکه عصبي پيشرو با يک لايه مخفي يکي از پرکاربردترين مدل‌هاي شبکه‌هاي عصبي به‌منظور پيش‌بيني سري‌هاي زماني مي‌باشند[۳٤]. اين‌گونه مدل‌ها از سه لايه پردازش ساده اطلاعات متصل به‌هم تشکيل شده‌اند. رابطه بين خروجي (y_t) و ورودیها ($y_{t-1},...,y_{t-p}$) بصورت زير مي‌باشد :

$$y_t = \alpha_t + \sum_{j=1}^{q} \alpha_j g(Boj + \sum_{i=1}^{p} Bijy_{t-i}) + \varepsilon_t \qquad (۲)$$

بطوريكه β_{ij}, α_j پارامترهاي مدل بوده كه غالباً وزن‌هـاي اتصالي ناميده مي‌شوند، P تعداد گره‌هاي ورودي و q تعداد گره‌هاي مخفي مي‌باشند. تابع سيگموئيدي اغلـب بعنـوان تابع فعال‌سازي لايه مخفي مورد استفاده قرار مي‌گيرد.

$$g(x)=\frac{1}{1+\exp(-x)} \qquad (۳)$$

از اينرو مدل شـبكه‌هـاي عصـبي مصـنوعي رابطـه (۲) در حقيقـت بـه‌عنـوان يـک نگاشـت غيرخطـي از مشـاهدات گذشته به مقدار آينده خواهد بود يعني

$$y_t = f(y_{t-1},...,y_{t-p}, w)+\varepsilon_t \qquad (٤)$$

بطوريكه w بردار همـه پارامترهـا و f تـابعي اسـت كـه توسط ساختار شـبكه عصـبي و وزن‌هـاي اتصـالي تعيـين مي‌گردد، از اينرو شـبكه‌هـاي عصـبي معـادل يـک مـدل خودرگرسيون غيرخطي هستند.

روش تركيبي (ANNs & ARIMA)

هر دو مدل خودرگرسيون ميانگين متحرک انباشـته و شبكه‌هاي عصبي مصنوعي در دامنه‌هاي خطي و غيرخطي خودشان مدل‌هاي موفقي مي‌باشند، هر چند هيچ‌كـدام از آنها يک مدل كلي كه بـراي همـه مـوارد مناسـب باشـند، نيستند. تخمين مدل‌هاي خودرگرسيون ميانگين متحـرک انباشته براي مسائل غيرخطي پيچيده ممكن است مناسب نباشد، از طرف ديگر بكارگيري شبكه‌هاي عصبي مصنوعي براي مدل‌سازي مسائل خطي نتـايج متفـاوتي دربرداشـته است[۳۵]. لذا روش تركيبي كه قابليت مدل‌سازي توام هر دوي مدل‌هاي خطي و غيرخطـي را دارد، مـي‌توانـد يـک استراتژي مناسب براي استفاده‌هاي عملي باشد. با تركيـب مدل‌هاي مختلف جنبـه‌هـاي مختلـف الگوهـاي زيربنـايي داده‌ها ممكن اسـت بطـور كـاملتري بدسـت آيـد و شـايد معقول باشد كه يک سري زماني را بصـورت تركيـب يـک سـاختار خودهمبسـته خطـي و يـک جـزء غيرخطـي در نظرگرفته شود، يعني :

$$y_t = N_t + L_t \qquad (۵)$$

بطوريكه L_t جزء خطي و N_t جزء غيرخطي مي‌باشـد كه بايد توسط داده‌ها تخمين زده شوند. بدين منظور ابتدا با بكارگيري مدل خودرگرسيون ميانگين متحرک انباشـته جزء خطي مدل، مدل‌سازي مي‌گردد، لـذا باقيمانـده‌هـاي مدل خطي فقط شامل روابط غيرخطي خواهند بود. حـال اگر e_t باقيمانده مدل خطي در زمان t باشد لـذا خـواهيم داشت :

$$e_t = y_t - \hat{L}_t \qquad (٦)$$

بطوريكـه $\hat{L}_t$ مقـادير پـيش‌بينـي‌شـده در زمـان t، تخمين‌زده شده از رابطه (۱) مي‌باشند. حال با مدل‌سـازي باقيمانده‌ها توسط شبكه‌هـاي عصـبي مصـنوعي مـي‌تـوان روابط غيرخطي موجود در باقيمانده‌ها را كشـف نمـود. بـا فرض n گره ورودي، مدل شبكه‌هاي عصبي مصنوعي براي باقيمانده‌ها بصورت زير خواهد بود :

$$e_t = f(e_{t-1},...,e_{t-n}) + \varepsilon_t \qquad (۷)$$

بطوريكه f يک تـابع غيرخطـي مشـخص‌شـده توسـط شبكه عصبي مي‌باشد و e_t خطـاي تصـادفي اسـت. قابـل توجه است كه اگر مدل f مناسب نباشد جمله خطا به‌اندازه كافي تصادفي نمي‌باشد بنـابراين تشـخيص صـحيح مـدل مساله‌اي بحراني است. توجه كنيد كـه بـا تخمـين N_t از معادله شماره (۷)، پيش‌بيني تركيبي بصورت زيـر خواهـد بود :

$$\hat{y}_t = \hat{L}_t + \hat{N}_t \qquad (۸)$$

شبكه‌هاي عصبي احتمالي (PNN)

شبكه‌هاي عصبي كه به‌منظور شـناخت و طبقـه‌بنـدي الگوها مورد استفاده قرار مـي‌گيرنـد، بطـوركلي الگـوهـاي موجود در داده‌هاي آموزش را يادگرفته، سپس نمونه‌هـاي جديد را بر اساس ايـن الگـوهـا دسـته‌بنـدي مـي‌نماينـد. شبكه‌هاي عصبي احتمالي از مهمتـرين روش‌هـاي باناظر بوده كه بـه‌منظـور شـناخت و طبقـه‌بنـدي الگوهـا مـورد استفاده قرار مي‌گيرند. اين‌گونه از شبكه‌ها براي اولين بـار در سـال ۱۹۸۸ توسـط *دونالـد اسـپيچت* معرفـي گرديدند[۳٦]. شبكه‌هـاي عصـبي احتمـالي الگوهـا را بـر اساس استراتژي بيزي و تخمين‌زننده‌هاي غيـرپارامتريـک توابع چگالي احتمال، طبقـه‌بنـدي مـي‌نماينـد و از جملـه روش‌هايي هستند كه مبتني بر الگوهاي آماري موجـود در داده عمل مي‌نمايند.

اين‌گونه از شـبكه‌هـا از الگـوريتم‌هـاي يـادگيري يـک بارگذر از داده‌ها استفاده نمـوده و ايـن يكـي از بزرگتـرين مزيت‌هاي آنها به حساب مي‌آيد، چرا كه روش‌هايي كـه از رويكردهاي ذهني به‌منظور بدست آوردن الگوهاي موجـود

در داده‌ها استفاده می‌نمایند معمولاً مستلزم ایجاد مقدار زیادی از تغییرات کوچک در پارامترهای شبکه به‌منظور اصلاح تدریجی بازده خود می‌باشند و این به معنای زمان یادگیری طولانی می‌باشد. همچنین در الگوریتم یادگیری شبکه‌های عصبی احتمالی تضمین می‌گردد که با افزایش تعداد نمونه‌های آموزشی سطوح تصمیم‌گیری به مرزهای تصمیم‌گیری بهینه میل نمایند. بعلاوه با انتخاب مناسب *فاکتور هموارسازی* می‌توان سطوح تصمیم‌گیری را بر حسب نیاز بسیار ساده یا بسیار پیچیده تنظیم نمود[۳۷]. شبکه‌های عصبی احتمالی یک اشکال عمده نیز دارند و آن نیاز به ذخیره‌سازی تمامی نمونه‌های آموزشی به‌منظور طبقه‌بندی الگوهای جدید می‌باشد که این خود باعث اشغال حجم بزرگی از حافظه می‌گردد.

استراتژی بیزی

به‌منظور درک بهتر مفاهیم و نحوه عملکرد شبکه‌های عصبی احتمالی لازم است آشنایی‌های اولیه‌ای با استراتژی بیزی وجود داشته باشد، لذا در این قسمت ابتدا به بیان مختصری در مورد استراتژی بیزی پرداخته‌شده است. استراتژی بیزی به مجموعه‌ای از قوائد و استراتژی‌هایی اطلاق می‌گردد که به‌منظور طبقه‌بندی الگوها از مینیمم‌کردن ریسک مورد انتظار استفاده می‌نمایند[۳۸]. یک تکنیک طبقه‌بندی الگو در حالت کلی با استفاده از یک مجموعه از ورودی‌های n بعدی، به تصمیم‌گیری در مورد تعلق یک مشاهده به یک دسته خاص می‌پردازد. فائده تصمیم‌گیری بیزی جهت طبقه‌بندی یک الگوی مشخص (X) و تعلق آن الگو به یک طبقه خاص عبارت است از

$$X \in C_r \quad if \quad h_r l_r f_r(X) \geq h_s l_s f_s(X) \quad for\ \forall s, s \neq r \quad 1 \leq r \leq q \qquad (۹)$$

به قسمی که l_i ضرر متناظر با تعلق اشتباه الگوی X به کلاسiام، h_i یک احتمال اولیه از تعلق الگوی X به کلاس iام و $f_i(X)$ تابع چگالی احتمال کلاس iام برای ورودی X می‌باشد. در حالت کلی سطوح تصمیم‌گیری را می‌توان به دلخواه پیچیده انتخاب نمود، چرا که هیچ محدودیتی برای تابع چگالی احتمال به جز شرایط عمومی این‌گونه از توابع (نامنفی، انتگرال‌پذیر بودن در تمامی نقاط و مساوی یک بودن انتگرال آنها در دامنه تعریف) وجود ندارد. *پارزن* نشان داده است که یک کلاس از تخمین‌زننده‌های توابع چگالی احتمال هموار و پیوسته وجود دارند که بطور مجانبی به توابع چگالی اصلی میل می‌کنند[۳۹].

شبکه‌های عصبی احتمالی

شبکه‌های عصبی احتمالی بر اساس استراتژی بیزی در دسته‌بندی الگوها ساخته‌شده‌اند و با در دسترس داشتن داده‌های مشخص ابزارهای قدرتمندی جهت شناخت و طبقه‌بندی الگوها با بیشترین احتمال موفقیت می‌باشند[۲۹]. اساس سایر دسته‌بندی کننده‌های بیزین بر انتخاب کلاسی با بزرگترین‌ترم حاصله از قاعده استراتژی بیزین می‌باشد.

$$\underset{i}{Max}\{h_i l_i f_i(X)\} \qquad (۱۰)$$

رابطه (۱۰) قانون تصمیم‌گیریی که جهت شناخت تابع چگالی احتمال مورد نیاز می‌باشد را پیشنهاد نمی‌نماید. یک تخمین‌زننده خاص از این نوع که در شبکه‌های عصبی احتمالی مورد استفاده قرار می‌گیرد مطابق زیر می‌باشد

$$f_i(X) = \frac{1}{(2\pi)^{\frac{k}{2}}\sigma^k} \cdot \frac{1}{n_i}\sum_{i=1}^{n_i} \exp\left[-\frac{(X - Y_{i,j})^T \cdot (X - Y_{i,j})}{2\sigma^2}\right] \qquad (۱۱)$$

به‌قسمی که X بردار ورودی، k تعداد متغیرهای موجود در بردار ورودی (بعد بردار ورودی)، n_i تعداد الگوهای آموزشی موجود در کلاس iام، $Y_{i,j}$ زامین الگوی آموزشی در کلاس iام و σ پارامتر هموارسازی است. تابع چگالی احتمال فوق‌الذکر با بکارگیری روش تقریب پارزن مستقیماً از مجموعه داده‌های آموزشی برآورد می‌گردد. اگرچه تابع رابطه (۱۱) بصورت مجموعی از توزیع‌های گوسی چندمتغیره کوچک می‌باشد امّا این دلیلی برگوسی‌بودن مجموع آنها نبوده و و این مجموع می‌تواند هر تابع چگالی احتمال را تقریب بزند.

توپولوژی شبکه‌های عصبی احتمالی

شبکه‌های عصبی احتمالی با استفاده از منطق دسته‌بندی مذکور و به‌منظور اجرای آنها، طراحی و ساخته‌شده‌اند. ساختار شبکه‌های عصبی احتمالی در حالت کلی شامل چهار لایه می‌باشند، یک لایه ورودی و سه لایه پردازش اطلاعات شامل لایه الگو، لایه کلاس‌بندی و لایه خروجی. ساختار کلی یک شبکه عصبی احتمالی در شکل

(۱) آورده‌شده است. نرون‌هاي لايه ورودي صرفاً وظيفه انتقال مقادير ورودي به تمام نرون‌هاي لايه دوم را بر عهده داشته و هيچ‌گونه پردازشي در اين لايه بر روي داده‌ها صورت نمي‌گيرد. هر يک از نرون‌هاي لايه دوم، حاصل‌ضرب نقطه‌اي بردار ورودي را در يک بردار وزن محاسبه مي‌نمايد و پس انجام يک عمل غيرخطي برروي حاصل‌ضرب مذكور نتيجه را در اختيار لايه سوم قرار مي‌دهد. تابع غيرخطي اين لايه اگر مقادير مربوط به ورودي‌ها و اوزان به طول واحد نرماليزه‌شده باشند مطابق زير خواهد بود.

$$\exp(-(W_i - X)^T (W_i - X)/2\sigma^2) \qquad (۱۲)$$

نرون‌هاي لايه سوم ورودي‌هاي متناظر با دسته‌اي كه الگوي آموزش به آن تعلق دارد را با هم جمع مي‌نمايد. در نهايت نيز نرون‌هاي لايه خروجي با بدست آوردن يک مجموع وزني از دو ورودي خود و با استفاده از يک تابع فعاليت دوحالته، كلاس و طبقه ورودي مورد نظر را مشخص مي‌نمايند.

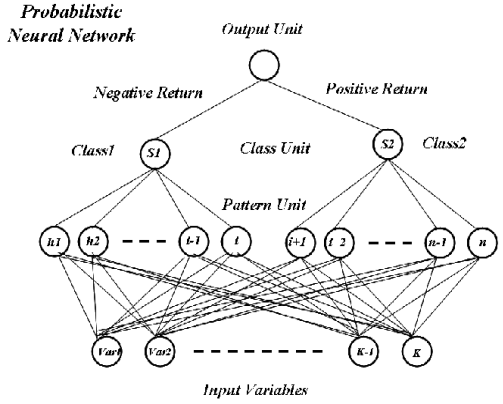

شكل۱: ساختار كلي يک شبـكه عصبي احتمالي.

نرمال‌كردن ورودیها و انتخاب فاكتور هموارسازي

از آنجايي كه توابع چگـالي احتمـال تخمـين‌زده‌شـده داراي يک هسـته بـا پهنـاي ثابـت در دو سـمت هسـتند، معمولاً لازم است به‌عنوان يک پيش‌پردازش داده‌ها، تمـام متغيرهاي ورودي بگونه‌اي تغيير مقيـاس داده شـوند كـه همگي داراي يـک واريـانس ثابـت باشـند. پـس از تغييـر مقياس نوبت به انتخاب پهناي تابع چگالي احتمال تخمين زده‌شده (σ) مي‌رسد. انتخاب اين پهنا در نحـوه تخمـين تابع چگالي احتمال و در نتيجـه در تصـميم‌گيـري بسـيار مـوثر اسـت. يـک روش مرسـوم جهـت انتخـاب σ *روش كنارگذاشتن نمونه‌ها* است. در اين روش براي يـک مقـدار خاص σ ، در هر زمان يک نمونه كنارگذاشته‌شده و شـبكه بر اساس ساير نمونه‌ها ساخته مـي‌شـود. سـپس از شـبكه حاصل جهت تخمين y متناظر با نمونه كنارگذاشـته‌شـده استفاده مي‌گـردد. بـا تكـرار ايـن رويـه بـراي هـر نمونـه، *ميانگين مربعات خطا*(*MSE*) در مقدار مشخص σ محاسـبه مي‌گردد. سپس با تغيير σ اعمال فـوق تكـرار مـي‌گـردد. نهايتاً شبكه اصلي بـر اسـاس مقـداري از σ كـه كمتـرين خطاي متناظر را داراست، ايجاد مي‌گردد[٤٠].

روش پيشنهادي (ANNs/ARIM & PNNs)

امروزه علي‌رغم وجود روش‌هاي كمي متعدد جهت پيش‌بيني‌هاي مالي، هنوز پيش‌بيني‌هاي دقيق در بازارهاي مالي كار چندان ساده‌اي نيست و اكثر محققان درصدد بكارگيري و تركيب روش‌هاي متفاوت به‌منظور حصول نتايج دقيق‌تر مي‌باشند. شناخت و طبقه‌بندي الگوها به مسئله‌اي مهم و قابل توجه در دنياي امروز تبديل‌شده است و تعداد تحقيقات متنوع انجام‌شده در اين زمينه، در سال‌هاي اخير مبين اهميت اين موضوع مي‌باشد. شبكه‌هاي عصبي احتمالي يكي از موفقترين و كاربردي‌ترين نوع از اين شبكه‌ها بوده كه بر اساس نظر كارشناسان با در دسترس داشتن داده‌هاي مشخص ابزارهاي قدرتمندي جهت شناخت و طبقه‌بندي الگوها با بيشترين احتمال موفقيت مي‌باشند[۲۹].

در اين مقاله، استفاده از قدرت تشخيص شبكه‌هاي عصبي احتمالي به‌منظور تشخيص روند موجود در باقيمانده‌هاي سري زماني و بهبود نتايج پيش‌بيني‌شده از روش تركيبي خودرگرسيون ميانگين متحرک انباشته با پرسپترون‌هاي چندلايه، پيشنهاد شده است. در روش پيشنهادي در ابتدا يک مدل خودرگرسيون ميانگين متحرک انباشته بر روي داده‌هاي سري زماني مورد مطالعه $\{Z_t\}$ برازش مي‌گردد. نتيجه اين مرحله مدل‌سازي ساختارهاي خطي موجود در داده‌ها و برآوردي از مقادير واقعي سري زماني مطابق زير خواهد بود.

$$\hat{L}_t = \varphi_1 W_{t-1} + \varphi_2 W_{t-2} + ... + \varphi_p W_{t-p} - \theta_{p+1} a_{t-1} - \theta_{p+2} a_{t-2} - ... - \theta_{p+q} a_{t-q} \qquad (۱۳)$$

به قسمي كه $\varphi_1, \varphi_2, ..., \varphi_p$ و $\theta_1, \theta_2, ..., \theta_q$ پارامترهاي مدل خودرگرسيون ميانگين متحرک انباشته و

$W_t = (1-B)^d (Z_t - \mu)$ مي‌باشند. در مرحله بعدي با استفاده از يک شبکه پرسپترون چندلايه ساختارهاي غيرخطي موجود در باقيمانده‌هاي مدل خطي، مدل‌سازي مي‌گردند ($\hat{N}_t = f(e_{t-1},...,e_{t-n})$). سپس نتايج مراحل اول و دوم مطابق رابطه زير با هم ترکيب مي‌گردند.

$$Fit(Com)_t = \hat{y}_t = \hat{L}_t + \hat{N}_t \qquad (١٤)$$

به قسمي که $Fit(Com)_t$ مقدار پيش‌بيني شده مدل ترکيبي براي داده tام مي‌باشد.

در مرحله بعدي با انتخاب *طول گام* مطلوب، مقادير بدست آمده از روش ترکيبي به منظور بکارگيري در شبکه عصبي احتمالي، به سه قسمت تقسيم مي‌گردند که به عنوان مقادير *هدف* شبکه عصبي احتمالي درنظرگرفته مي‌شوند. دسته اول *(target=0)*، مقادير پيش‌بيني شده‌اي هستند که در فاصله يک گام از مقادير واقعي سري زماني قرار دارند. دسته دوم و سوم، مقادير پيش‌بيني شده‌اي هستند که فاصله آنها از مقادير واقعي سري زماني از طول يک گام بيشتر بوده و به ترتيب در بالا *(target=-1)* و پايين *(target=+1)* مقـادير واقعي قراردارند (رابطه ۲۵). ساير داده‌اي موجود که شامل نتايج بدست آمده از روش خودرگرسيون ميانگين متحرک انباشته، شبکه پرسپترون چندلايه و مقادير سري زماني مورد مطالعه مي‌باشند، نيز به عنوان داده‌هاي آموزش درنظرگرفته مي‌شوند. در انتها يک شبکه عصبي احتمالي طراحي شده و آموزش مي‌بيند تا روند موجود در باقيمانده‌ها را تشخيص دهد. نتيجه اين مرحله حرکت مقادير براورد شده با توجه به روند پيش‌بيني شده و به سمت مقادير واقعي مي‌باشد.

$$tar = \begin{cases} -1 & if \quad fit(Com)_t > y_t + pitch \ , \\ 0 & if \quad y_t - pitch \le fit(Com)_t \le y_t + pitch \\ +1 & if \quad fit(Com)_t < y_t - pitch \ , \end{cases} \qquad (١٥)$$

اولين مسئله در طراحي يک شبکه عصبي احتمالي تعيين تعداد نرون‌هاي ورودي يا به عبارت ديگر تعيين ورودي‌هاي شبکه است که بي‌شک مهمترين قسمت در طراحي اينگونه از شبکه‌ها مي‌باشد. اصولاً هيچ روش سيستماتيکي به‌منظور تعيين ورودي‌هاي شبکه در حالت کلي وجود نداشته و اغلب محققان از طريق آزمايش و خطا، متغيرهاي مؤثر و ورودي‌هاي شبکه را از ميان مجموعه متغيرهاي ممکن انتخاب مي‌نمايند. بطورکلي مجموعه کليه متغيرهايي که کانديداي ورود به شبکه احتمالي در اين مرحله هستند، عبارتند از:

۱- وقفه‌هاي اول تا pام سري زماني در زمان t ($Z_{t-1}, Z_{t-2}, ..., Z_{t-p}$).

۲- وقفه‌هاي اول تا qام خطاي خالص در زمان t ($a_{t-1}, a_{t-2}, ..., a_{t-q}$).

۳- مقدار پيش‌بيني‌شده سري زماني در زمانt ($\hat{L}_t, \hat{N}_t$).

٤- وقفه‌هاي مقدار پيش‌بيني‌شده سري زماني در زمان t ($\hat{L}_{t-1}, \hat{L}_{t-2}, ..., \hat{L}_{t-m}, \hat{N}_{t-1}, \hat{N}_{t-2}, ..., \hat{N}_{t-m}$).

به قسمي که m عددي دلخواه و p,q به ترتيب پارامتر تعريف شده در قسمت‌هاي قبلي و تعداد ورودي‌هاي شبکه پرسپترون چندلايه مي‌باشند. مسئله بعدي در طراحي شبکه تعيين تعداد نرون‌هاي خروجي است. در حالت کلي تعداد نرونهاي خروجي در مسئله‌اي با k کلاس متفاوت برابر با *k-1* مي‌باشد[٤١]، شکل (۲)، لذا در مسئله مورد نظر، تعداد نرون‌هاي خروجي برابر با دو خواهد بود. در انتها با بررسي ساختارهاي مختلف و با توجه به درصد تشخيص صحيح روند در داده‌هاي تست، ساختار شبکه بهينه و همچنين مقدار بهينه پارامتر هموارسازي معيين مي‌گردد.

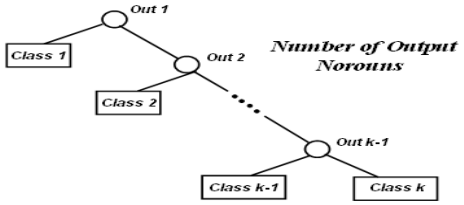

شکل۲: تعداد نرونهاي خروجي در مسئله‌اي با **k** کلاس متفاوت.

پس از تشخيص روند تغييرات سري زماني مورد مطالعه توسط شبکه احتمالي طراحي شده، مقادير پيش‌بيني شده با توجه به طول گام و روند تشخيصي مطابق رابطه زير اصلاح مي‌گردند.

$$Fit_{new} = Fit_{old} + trend \cdot pitch \qquad (١٦)$$

به قسمي که Fit_{new}, Fit_{old} به ترتيب مقادير جديد و قديم پيش‌بيني‌شده، $trend \in \{-1,0,+1\}$ روند تشخيص‌داده شده توسط شبکه احتمالي و $pitch$ طول گام درنظرگرفته‌شده مي‌باشند. طبق رابطه فوق عملکرد روش

پيشنهادي در ميانگين قدرمطلق خطا و در داده‌هاي تست مطابق رابطه زير خواهد بود.

$$MAE_p = MAE_c + \frac{1}{n}\left[\sum_{t=1}^{n} D(target, trend)\cdot target\cdot pitch\right] \quad (۱۷)$$

به قسمي كه MAE_p, MAE_c به ترتيب مقادير ميانگين قدرمطلق خطاي مدل‌هاي پيشنهادي و تركيبي در داده‌هاي تست و $D(target, trend)$ تابعي مطابق زير مي‌باشد.

$$D(target, trend) = \begin{cases} +1 & if \quad target = trend, \\ -1 & if \quad target \neq trend, \end{cases} \quad (۱۸)$$

همانگونه كه از رابطه فوق مشخص است $\alpha = \sum_{t=1}^{n} D(target, trend)\cdot|target|$ معياري از عملكرد شبكه در داده‌هاي تست مي‌باشند و شرط لازم و كافي براي بهبود عملكرد روش پيشنهادي در ميانگين قدرمطلق خطا نسبت به مدل تركيبي اين است كه ميزان اين معيار در داده‌هاي تست(α) بزرگتر ازصفر باشد، لذا تغييرات مذكور مشروط بر آنكه شرط فوق‌الذكر برقرار باشد، بر روي مقادير پيش‌بيني‌شده اعمال مي‌گردند و در غير اينصورت پروسه متوقف خواهد شد. همچنين در صورت نياز به دقت بالاتر، اين پروسه مي‌تواند تا زماني كه معيار مذكور بزرگتر ازصفر باشد ادامه يابد.

فرموله‌كردن مساله

با توجه به مطالب بيان شده، در اين بخش نرخ ارز(يورو در مقابل ريال ايران) با استفاده از روش پيشنهادي پيش‌بيني شده و نتايج حاصله با مدل تركيبي، مدل خودرگرسيون ميانگين متحرک انباشته و همچنين پرسپترون‌هاي چندلايه ازجهت دقت پيش‌بيني، مقايسه شده است.

مجموعه داده‌ها

داده‌هاي استفاده شده در اين مقاله، داده‌هاي روزانه نرخ ارز (يورو در مقابل ريال) مربوط به سيزدهم بهمن ماه ۱۳۸٤ تا هجدهم خرداد ماه ۱۳۸۵ مطابق با *2 Feb 2006* تا *8 Jun 2006* بوده و جمعاً شامل ۱۲۰ داده مي‌باشد. نمودار مربوط به نرخ ارز (يورو در مقابل ريال) بر اساس زمان در شكل (۳) آورده شده است.

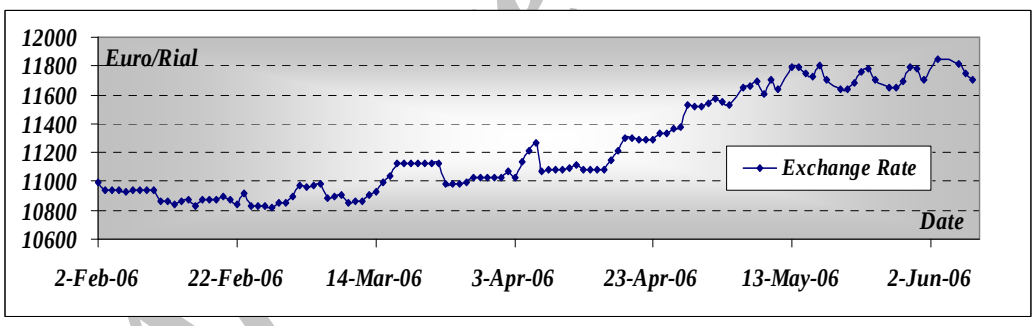

شكل ۳: نرخ ارز مربوط به ۱۳ بهمن ماه ۱۳۸٤ تا ۱۸ خرداد ماه۱۳۸۵.
منبع: بانک مركزي جمهوري اسلامي ايران.

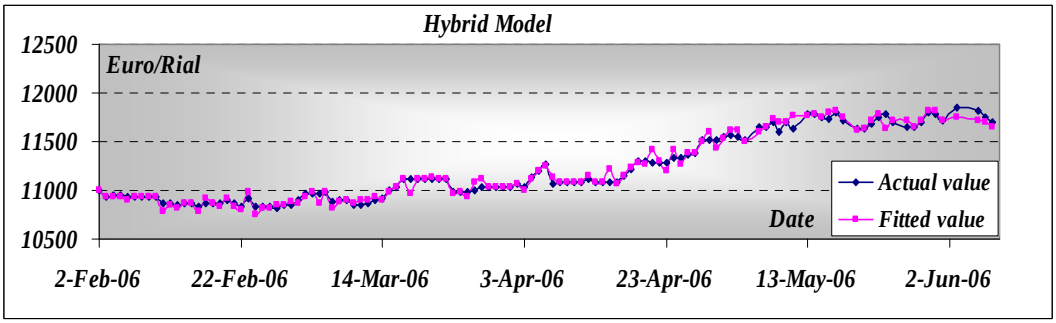

شكل٤: مقادير واقعي و پيش‌بيني‌شده مدل تركيبي.

نتایج حاصله

در این قسمت نتایج سه مدل خودرگرسیون میانگین متحرک انباشته، شبکه‌های عصبی مصنوعی و مدل ترکیبی آورده شده است. در این مطالعه تمامی مدل‌سازي‌هاي مدل‌هاي خودرگرسیون میانگین متحرک انباشته توسط نرم‌افزار *Eviews* و مدل‌سازي‌هاي شبکه‌های عصبي توسط نرم‌افزار *MATLAB7* انجام شده است. همچنین دو معیار *میانگین مربعات خطا*(*MSE*) و *میانگین قدرمطلق خطا*(*MAE*) به‌عنوان معیار سنجش عملکرد و تصمیم‌گیري درنظرگرفته شده‌اند.

۱- میانگین مربعات خطا $MSE = \frac{1}{N}\sum_{i=1}^{N}(e_i)^2$

۲- میانگین مطلق خطا $MAE = \frac{1}{N}\sum_{i=1}^{N}|e_i|$

با توجه به تعداد داده‌ها (سایز نمونه) و مراحل اجراي روش ترکیبي، در مرحله اول یك مدل *ARIMA(2,1,0)* به‌منظور مدل‌سازي قسمت خطي داده‌ها مورد استفاده قرارگرفته و در مرحله دوم یك شبکه پرسپترون تك لایه $N^{(3\text{-}3\text{-}1)}$ به‌منظور مدل‌سازي ساختارهاي غیرخطي موجود در باقیمانده‌هاي مدل خودرگرسیون میانگین متحرک انباشته مورد استفاده قرارگرفته است. تقسیم‌بندي داده‌ها به داده‌هاي تست و آموزش در جدول (۱) آورده شده است.

جدول ۱: تقسیم‌بندي داده‌ها به داده‌هاي تست و آموزش.

سري زماني	سایز نمونه	آموزش	تست
نرخ ارز	۱۲۰	۱۰۰	۲۰

معیارهاي عملکرد مدل ترکیبي در پیش‌بیني نرخ ارز (یورو در مقابل ریال) براي هر یک از مجموعه‌هاي تست و آموزش در جدول (۲) آورده شده است. اطلاعات مربوط به مقادیر حقیقي و پیش‌بیني شده مدل ترکیبي نیز در شکل (٤) آورده شده است.

پس از اجراي مدل ترکیبي، شبکه عصبي احتمالي بکارگرفته مي‌شود. همچون مرحله قبل ۱۰۰ مشاهده به منظور آموزش شبکه و سپس ۲۰ مشاهده به‌منظور بررسي عملکرد شبکه مورد استفاده قرارگرفته است. طول گام در این مسئله خاص ۱۳ = *pitch* درنظرگرفته شده است، لذا با توجه به مطالب بیان شده در قسمت قبلي و انجام آزمایشات متعدد، شبکه بهینه، شبکه‌اي با چهار ورودي و دو خروجي مي‌باشد. ساختار شبکه مذکور در شکل (۵) آورده شده است. ورودي‌هاي شبکه با توجه به مجموعه اولیه متغیرهاي موجود و بر اساس شرایط مسئله مورد نظر انتخاب شده‌اند. خروجي شبکه نیز مقادیر (۱+و ۰ و۱-) مي‌باشند. همچنین داده‌هاي ورودي به بازه [۱و۰] نرمالیزه شده‌اند.

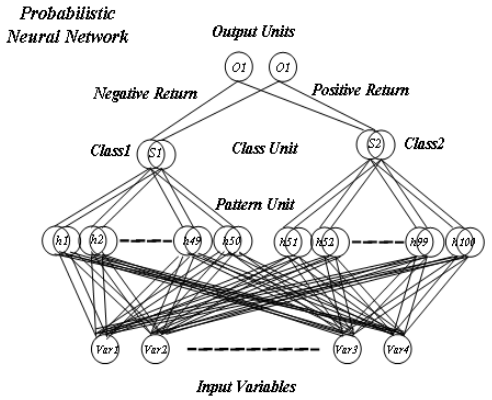

شکل ۵: ساختار شبکه عصبي احتمالي طراحي شده.

به قسمي که در انتها نیز با توجه به درصد تشخیص صحیح روند موجود در در داده‌هاي تست مقدار بهینه پارامتر هموارسازي($\delta = 0.47$) تعیین گردیده است. با توجه به شبکه عصبي احتمالي طراحي‌شده در مرحله قبلي وشبیه‌سازي شبکه مذکور در نرم‌افزار MATLAB7 با بکارگیري داده‌هاي تست، روند موجود در داده‌ها تشخیص داده شده‌اند. نتایج حاصله مطابق جدول زیر مي‌باشد.

همانطوري که در جدول فوق مشاهده مي‌گردد، شبکه عصبي احتمالي قادر است ٦۰ % از شکست‌ها را به درستي تشخیص دهد و معیار عملکردي شبکه مذکور نیز $\alpha = ٦$ مي‌باشد، لذا تغییرات فوق‌الذکر بر روي داده‌ها اعمال مي‌گردد. حال با توجه به روندهاي بدست آمده از شبکه عصبي احتمالي و مقادیر پیش‌بیني شده توسط مدل ترکیبي، نتایج روش پیشنهادي براي داده‌هاي تست و آموزش در شکل(٦) آورده شده‌اند. همچنین با توجه به تغییرات اعمال شده برروي داده‌ها معیارهاي عملکردي روش پیشنهادي در جدول (٤) آورده شده است.

جدول۲:معيارهاي عملكرد مدل تركيبي در پيش‌بيني نرخ ارز.

تست					آموزش				
MAE	MAPE	ME	RMSE	SSE	**MSE**	**MAE**	HQC	BIC	AIC	**MSE**
۳۸/۵۰	۰/۳۲۸	-۵/۴۲	۵۲/۱۳	۵۴۳۵۵	۲۷۱۸	۳۰/۱۱	۳/۴۱	۳/٦٤	۳/٦٤	۲۰۹۰

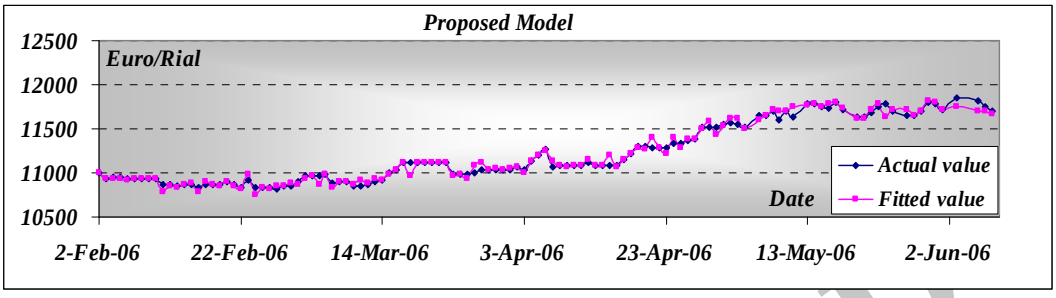

شكل٦:مقادير واقعي و پيش‌بيني شده از روش پيشنهادي.

جدول۳: روند و مقادير واقعي و پيش‌بيني‌شده براي داده‌هاي تست.

تـاريـخ	واقعي		تشخيص‌داده شده		تـاريـخ	واقعي		تشخيص‌داده شده	
	روند	مقدار	روند	مقدار		روند	مقدار	روند	مقدار
۲۵- اردیبهشت	۰	۱۱۷۵۰	۰	۱۱۷۴٦	٦- خرداد	-۱	۱۱٦۵۳	۰	۱۱۷۱٦
۲٦- اردیبهشت	-۱	۱۱۷۲۹	-۱	۱۱۷۸۳	۷- خرداد	۰	۱۱٦۵۳	۰	۱۱٦۵۰
۲۷- اردیبهشت	۰	۱۱۸۰۷	۰	۱۱۸۰۹	۸- خرداد	-۱	۱۱٦۹۳	-۱	۱۱٦۹۸
۲۸- اردیبهشت	-۱	۱۱۷۱۰	۰	۱۱۷۴٤	۹- خرداد	-۱	۱۱۷۹۳	۰	۱۱۸۱۵
۳۰- اردیبهشت	۰	۱۱٦۳٤	۰	۱۱٦۲٤	۱۰- خرداد	-۱	۱۱۷۸۲	-۱	۱۱۸۰۱
۳۱- اردیبهشت	۰	۱۱٦۳۵	-۱	۱۱٦۱٦	۱۱- خرداد	-۱	۱۱۷۰۹	-۱	۱۱۷۰۹
۱- خرداد	-۱	۱۱٦۸٤	۰	۱۱۷۱۵	۱۳- خرداد	+۱	۱۱۸٤۵	۰	۱۱۷۵٦
۲- خرداد	-۱	۱۱۷۵۸	-۱	۱۱۷۷۵	۱٦- خرداد	+۱	۱۱۸۱۳	-۱	۱۱۷۰۵
۳- خرداد	+۱	۱۱۷۷٦	۰	۱۱٦۳۹	۱۷- خرداد	+۱	۱۱۷٤۵	+۱	۱۱۷۱۱
٤- خرداد	-۱	۱۱۷۰٤	-۱	۱۱۷۰۸	۱۸- خرداد	+۱	۱۱۷۰٤	+۱	۱۱٦٦۸

جدول٤:معيارهاي عملكرد مدل پيشنهادي در پيش‌بيني نرخ ارز.

تست					آموزش				
MAE	*MAPE*	*ME*	*RMSE*	*SSE*	***MSE***	***MAE***	*HQC*	*BIC*	*AIC*	***MSE***
۳٤/٦۱	۰/۳۰٦	۹/۳۲	۵۰/۷۷	۵۱۵۵۰	۲۵۷۷	۲۵/۹۲	۳/۳۳	۳/۵۵	۳/۵۵	۱٦۹۵

جدول ۵: نتايج بدست آمده از مدل‌ها.

معيار ارزيابي	داده‌هاي تست					
روش	***MAE***	*MAPE*	*ME*	*RMSE*	*SSE*	***MSE***
مدل خودرگرسيون ميانگين متحرک انباشته	۵۵/۹۰	۰/٤۷٦	-۹/۲۷	٦٤/۷۵	۸۳۸۵۲	٤۱۹۲
مدل شبكه عصبي مصنوعي	٤۳/۵۳	۰/۳۸۷	-٤/۳۹	٦۲/۵۹	۷۸۳٤۹	۳۹۱۷
مدل تركيبي	۳۸/۵۰	۰/۳۲۸	-۵/٤۲	۵۲/۱۳	۵٤۳۵۵	۲۷۱۸
مدل پيشنهادي	۳٤/٦۱	۰/۳۰٦	۹/۳۲	۵۰/۷۷	۵۱۵۵۰	۲۵۷۷

مقايسه روش تركيبي با روش‌هاي خودرگرسيون ميانگين متحرک انباشته و شبكه‌هاي عصبي

در اين قسمت به‌منظور نشان‌دادن برتري مدل پيشنهادي نسبت به مدل‌هاي تشكيل‌دهنده، نتايج سه مدل با يكديگر مقايسه شده‌اند. معيارهاي عملكرد بدست آمده از روش‌هاي خودرگرسيون ميانگين متحرک انباشته، شبكه‌هاي عصبي و مدل تركيبي براي داده‌هاي تست در جدول (۵) آورده شده است.

نتايج بدست آمده از مقايسه روش پيشنهادي با

روش‌هاي خودرگرسيون ميانگين متحـرک انباشـته، شبکه‌هاي عصبي مصنوعي و مدل ترکيبي بيـانگر برتـري روش پيشنهادي بر سه روش ديگر مـي‌باشـد. بکـارگيري روش پيشنهادي به‌منظور پيش‌بيني نرخ ارز نتايج حاصله را بـه ترتيـب بـه ميـزان ۳۹% ، ۳٤% و ۵% در ميـانگين مربعات خطا و به ميـزان ۳۸% ، ۲۰% و ۱۰% در ميـانگين قدرمطلق خطا نسبت به مدل‌هاي خودرگرسيون ميانگين متحرک انباشـته، شـبکه‌هـاي عصـبي مصـنوعي و روش ترکيبي بهبود داده است.

نتيجه‌گيري

تحليل سري‌هاي زماني و پيش‌بيني موضوع بسـياري از تحقيقات در چند دهه گذشته بوده است. پيش‌بينـي از ابزارها و راهکارهاي مؤثر به‌منظور برنامـه‌ريـزي و تـدوين استراتژي‌هاي مالي مي‌باشد. دقت پيش‌بينـي سـري‌هـاي زمـاني در بسـياري از فرآينـدهاي تصـميم‌گيـري نقـش اساسي داشته و با وجود روش‌هاي متعدد پيش‌بيني هنوز پيش‌بيني‌هاي دقيق در بازارهاي مالي کار چندان ساده‌اي نمي‌باشد. از اينرو تحقيقات بسياري به‌منظور بهبود دقـت مدل‌هاي پـيش‌بينـي انجـام شـده اسـت. در ايـن مقالـه، به‌منظور بهبود عملکرد و حصول نتايج دقيق‌تر يـك روش جديد به‌منظور پيش‌بيني در محيط‌هـاي مـالي پيشـنهاد شده است. روش پيشنهادي از قدرت تشخيص شبکه‌هاي عصـبي احتمـالي بـه‌منظـور تشـخيص رونـد موجـود در باقيمانده‌هاي سري زماني مـورد مطالعـه و بهبـود نتـايج پيش‌بيني شده از روش ترکيبي خودرگرسـيون ميـانگين متحرک انباشـته بـا پرسـپترون‌هـاي چندلايـه، اسـتفاده مي‌کند. نتايج حاصله از پيش‌بيني نرخ ارز(يورو در مقابـل ريـال) بـا روش پيشـنهادي بيـانگر بهبـود در دقـت پيش‌بيني‌ها نسبت به مدل‌هـاي خودرگرسـيون ميـانگين متحرک انباشـته، شـبکه‌هـاي عصـبي مصـنوعي و مـدل ترکيبي در معيارهاي سنجش عملکرد انتخابي شده است. بکارگيري روش پيشنهادي به منظور پيش‌بينـي نـرخ ارز نتايج حاصله را به ترتيب به ميزان ۱۹% و ۵% در ميانگين مربعـات خطـا و بـه ميـزان ۱٤% و ۱۰% در ميـانگين قدرمطلق خطا بـه ترتيـب در داده‌هـاي آمـوزش و تسـت نسبت به روش ترکيبي بهبود داده است.

تشکر و قدرداني

در اينجا جا دارد از همکاري‌ها و حمايـت‌هـاي جنـاب آقاي مهندس مجيد رفيعي به جهت ارائه اطلاعات و آمـار مورد نياز تشکر و قدرداني نماييم.

مراجع

1 - Khashei, M. (2005) "*Forecasting the Isfahan Steel Company production price in Tehran Metals Exchange using Artificial Neural Networks (ANNs).*" Master of Science Thesis, Isfahan University of Technology.

2 - Huseyin I. and Theodore, T. (2006), "A hybrid model for exchange rate prediction." *Decision Support Systems*, Vol. 42, No. 2, PP. 1054-1062.

3 - An-Sing C. and Mark, L. (2004), "Regression neural network for error correction in foreign exchange forecasting and trading." *Computers & Operations Research*, Vol. 31, No. 7, PP. 1049-1068.

4 - Balkin, S. (2001), "On Forecasting Exchange Rates Using Neural Networks: P.H. Franses and P.V. Homelen, Applied Financial Economics." *International Journal of Forecasting*, Vol. 17, No. 1, PP. 139-140.

5 - Martens, M. (2001), "Forecasting daily exchange rate volatility using intraday returns." *Journal of International Money and Finance*, Vol. 20, No. 1, PP. 1-23.

6 - Yu, L., Wang Sh. and Lai, K. K. (2005), "A novel nonlinear ensemble forecasting model incorporating GLAR and ANN for foreign exchange rates." *Computers & Operations Research*, Vol. 32, No. 10, PP. 2523-2541.

7 - Balaban, E. (2004), "Comparative forecasting performance of symmetric and asymmetric conditional volatility models of an exchange rate." *Economics Letters*, Vol. 83, No. 1, PP. 99-105.

8 - Faust, J., Rogers J. H. and Wright, J. H. (2003), "Exchange rate forecasting: the errors we've really made." *Journal of International Economics*, Vol. 60, No. 1, PP. 35-59.

9 - Meade, N. (2002), "A comparison of the accuracy of short term foreign exchange forecasting methods." *International Journal of Forecasting*, Vol. 18, No. 1, PP. 67-83.

10 - Khashei, M. and Bijari, M. (2006) "Using Fuzzy Auto Regressive Integrated Moving Average model to exchange rate forecasting." *6th Iranian Fuzzy Systems Conference*, PP. 26-35.

11 - Box, G.E.P. and Jenkins, G. (1970), "*Time Series Analysis, Forecasting and Contro.l*" Holden-Day, San Francisco, CA.

12 - Zhang, G., Patuwo, B. and Hu, M. Y. (1998), "Forecasting with artificial neural networks: The state of the art." *International Journal of Forecasting*, Vol. 56, 205 – 232.

13 –Khashei, M., Bijari, M. and Raissi, GH. A. (2009), "Improvement of Auto-Regressive Integrated Moving Average Models Using Fuzzy Logic and Artificial Neural Networks (ANNs)." *Neurocomputing*, Vol. 72, PP. 956- 967.

14 - Reid, M. J. (1968), "Combining three estimates of gross domestic product." *Economica*, Vol. 35, PP. 431–444.

15 - Bates, J.M. C. and Granger, W.J. (1969), "The combination of forecasts." Operations Research Quarterly, Vol. 20, PP. 451–468.

16 - Clemen, R. (1989), "Combining forecasts: a review and annotated bibliography with discussion." *International Journal of Forecasting*, Vol. 5, PP. 559–608.

17 - Khashei, M., Hejazi, S. R. and Bijari, M. (2008), "A new hybrid artificial neural networks and fuzzy regression model for time series forecasting." *Fuzzy Sets and Systems*, Vol. 159, PP. 769 – 786.

18 - Armano, G., Marchesi, M. and Murru, A. (2005), "A hybrid genetic-neural architecture for stock indexes forecasting." *Information Sciences*, Vol. 170, PP. 3–33.

19 - Chen, K. and Wang, C. (2007), "A hybrid SARIMA and support vector machines in forecasting the production values of the machinery industry in Taiwan." *Expert Systems with Applications*, Vol. 32, PP. 254–264.

20 - Zhang, G. (2003), "Time series forecasting using a hybrid ARIMA and neural network model." *Neurocomputing*, Vol. 50, PP. 159– 175.

21 - Wedding, D. K. and Cios, K. J. (1996), "Time series forecasting by combining RBF networks, certainty factors, and the Box–Jenkins model." *Neurocomputing*, Vol. 10, PP. 149–168.

22 - Pai, P. and Lin, C. (2005), "A hybrid ARIMA and support vector machines model in stock price forecasting." *Omega*, Vol. 33, PP. 497 – 505.

23 - Tseng, F., and Yu, H. and Tzeng, G. (2002), "Combining neural network model with seasonal time series ARIMA model." *Technological Forecasting & Social Change*, Vol. 69, PP. 71–87.

24 - Ginzburg, I. and Horn, D. (1994), "Combined neural networks for time series analysis." *Adv. Neural Inf. Process.Systems*, Vol. 6, PP. 224–231.

25 - Khemchandanib, J. R. and Chandra, S. (2005), "Fuzzy linear proximal support vector machines for multi-category data classification." *Neurocomputing*, Vol. 67, PP. 426–435.

26 - Rodrı´gueza, J., Alonsob, C. J. and Maestro, J. A. (2005), "Support vector machines of interval-based features for time series classification." *Knowledge-Based Systems*, Vol. 18, PP. 171–178.

27 - Huang, W., Nakamoria, Y. and Wang, S. Y. (2005), "Forecasting stock market movement direction with support vector machine." *Computers & Operations Research*, Vol. 32, PP. 2513–2522.

28 - Sun, G., Dong, X. and Xu, G. (2006), "Tumor tNo. identification based on gene expression data using DWT feature extraction and PNN classifier." *Neurocomputing*,Vol. 69, PP. 387–402.

29 - Wasserman, P. (1993), "*Advanced methods in neural computing*." New York: Van Nostrand Reinhold.

30 - Kalatzis, I., Piliouras, N., Ventouras, E., Papageorgiou, C. and Liappas, I. (2005), "Design and implementation of a multi-PNN structure for discriminating one-month abstinent heroin addicts from healthy controls using the P600 component of ERP signals." *Pattern Recognition Letters*, Vol. 26, PP. 1691–1700.

31 - Chen; A., Leung, M. T. and Daouk, H. (2003), "Application of neural networks to an emerging financial market: forecasting and trading the Taiwan Stock Index." *Computers & Operations Research*, Vol. 30, PP. 901–923.

32 - Kim S. and Chun, S. (1998), "Graded forecasting using an array of bipolar predictions: application of probabilistic neural networks to a stock market index." *International Journal of Forecasting*, Vol. 14, PP. 323–337.

33 - Yang, B., Marjorie, Z. and Platt, D. (1999), "Probabilistic Neural Networks in Bankruptcy Prediction." *Journal of Business Research*, Vol. 44, PP. 67–74.

34 - Zhang, P. and Min, G. (2005), "Neural network forecasting for seasonal and trend time series." *European Journal of Operational Research*, Vol. 160, PP. 501–514.

35 - Bijari, M., Khashei, M. and Salehi, A.(2006), "World wide billet price forecasting using hybrid Artificial Neural Networks and Auto Regressive Integrated Moving Average models." *Steel Symposium 84*, PP. 992-1005.

36 - Specht, D. (1988), "Probabilistic neural networks for classification, mapping, or associative memory." *IEEE International Conference on Neural Networks*; PP. 525–532.

37 - Ghavam-Zadeh, M. (1998), "*Forecasting in contracts organized markets*." Master of Science Thesis, Tehran University, Electric and Electronic Engineering Department.

38 - Cho, G., Kim, T., Seo, Y. and Chan, M. (2006), "Integrated machining error compensation method using OMM data and modified PNN algorithm." *International Journal of Machine Tools & Manufacture*, Vol. 46, No. 12-13, PP. 1417-1427.

39 - Parzen, E. (1962), "On estimation of a probability density function and mode ", *Annals of Mathematical Statistics*; Vol. 33, PP. 1065–76.

40 - Khashei, M. (2006), "Using General Regression Neural Networks (GRNNs) for forecasting." *Behbod Journal, Isfahan University of Technology*, Vol. 22, PP. 42-45.

41 - Yuan, S. F. and Chu, F. L. (2006), "Support vector machines-based fault diagnosis for turbo-pump rotor." *Mechanical Systems and Signal Processing*, Vol. 20, PP. 939–952.