

پیش‌بینی نرخ ارز با به‌کارگیری مدل‌های ترکیبی پرسپترون‌های چندلایه (MLPs)  
و طبقه‌بندی‌کننده‌های عصبی احتمالی (PNNs)

مهدی خاشعی\*، مهدی بیجاری و فریماه مخاطب رفیعی  
دانشکده مهندسی صنایع، دانشگاه صنعتی اصفهان

(دریافت مقاله: ۱۳۹۰/۰۹/۰۶ - دریافت نسخه نهایی: ۱۳۹۱/۰۹/۲۲)

چکیده -

واژگان کلیدی: (MLP) (PNNs)

---

\*: مسئول مکاتبات، پست الکترونیکی: khashei@in.iut.ac.ir

## Exchange Rate Forecasting Using Hybrid Models of Multilayer Perceptrons (MLPs) and Probabilistic Neural Networks (PNNs)

M. Khashei, M. Bijari and F. Mokhatab Rafiei

Industrial Engineering Department, Isfahan University of Technology

**Abstract:** Forecasting is one of the effective tools for planning and establishing the financial strategies. Forecasting accuracy is also one of the most important factors in choosing the forecasting method. Nowadays, despite the numerous forecasting models available, accurate forecasting is not yet a simple task, especially in financial markets. Thus, different models have been combined together in order to achieve more accurate results. Combining different models or using hybrid forecasting models is a common way for overcoming deficiencies of the single models and improving their performance. In the literature, several hybrid models of multilayer perceptrons have been proposed in order to overcome the disadvantages of these models. In this paper, a new hybrid model of multilayer perceptrons is proposed using probabilistic neural classifiers. The proposed model improves the performance of the multilayer perceptrons using the unique advantages of the probabilistic neural classifiers in detecting the break points and better and more complete modeling of the specific patterns in the under-study time series. Empirical results of exchange rate forecasting indicate the efficiency of the proposed model in comparison with other models.

**Keywords:** Multilayer perceptrons (MLPs); Probabilistic Neural Networks (PNNs); Hybrid models; Time series forecasting; Financial markets; Exchange rate.

### ۱- مقدمه

نسبت به سایر مدل‌های غیرخطی، این است که شبکه‌های عصبی مصنوعی یک تقریب‌زننده جهانی هستند که می‌توانند هر نوع تابعی را با دقت دلخواه تقریب بزنند. در شبکه‌های عصبی مصنوعی دیگر نیازی به تشخیص شکل خاص مدل نیست و مدل بر اساس اطلاعات موجود در داده‌ها شکل می‌گیرد. این رویکرد مبتنی بر داده برای بسیاری از مجموعه داده‌های تجربی بالاخص زمانی که هیچ اطلاعات نظری برای پیشنهاد یک فرایند تولید داده مناسب در دسترس نباشد، بسیار مناسب است [۲].

علی‌رغم تمامی مزایای منحصر به فردی که برای شبکه‌های عصبی مصنوعی در نظر گرفته شده است، این گونه از مدل‌ها معایبی نیز دارند که از جمله آنها می‌توان به محدودیت تعداد داده‌های مورد نیاز و یا محدودیت در مدل‌سازی‌های خطی این گونه از مدل‌ها اشاره کرد. [۳].

استفاده از مدل‌های ترکیبی یا ترکیب مدل‌های مختلف یک راه معمول در بهبود دقت پیش‌بینی‌ها و غلبه بر محدودیت‌های مدل‌های تکی است. ادبیات موضوع مربوط به مدل‌های ترکیبی بسیار گسترده بوده و مطالعات فراوانی از زمان اولین تحقیقات انجام شده در این زمینه توسط رید [۴] و بیتس و گرانجر [۵] تاکنون صورت گرفته است. ایده اساسی در ترکیب مدل‌ها بر این

به‌کارگیری روش‌های سری‌های زمانی به‌منظور پیش‌بینی بازارهای مالی، بهبود تصمیم‌گیری‌ها و سرمایه‌گذاری‌ها به ضرورتی انکارناپذیر در دنیای امروز تبدیل شده است. پیش‌بینی سری‌های زمانی یکی از مهم‌ترین زمینه‌های پیش‌بینی است که در آن مشاهدات گذشته یک متغیر جمع‌آوری و به‌منظور به‌دست آوردن روابط اساسی بین مشاهدات و تعیین یک مدل توصیفی، مورد تجزیه و تحلیل قرار گرفته و سپس مدل حاصله به‌منظور برون‌یابی سری‌های زمانی مورد استفاده قرار می‌گیرد. این روش مدل‌سازی مخصوصاً زمانی مفید است که در مورد فرایند اساسی تولید داده‌ها دانش کمی در دسترس باشد و یا هنگامی که هیچ مدل توضیحی رضایت‌بخشی که متغیر وابسته را به سایر متغیرهای توضیحی مرتبط سازد وجود نداشته باشد [۱].

تلاش‌های زیادی در چند دهه اخیر به‌منظور توسعه و بهبود مدل‌های پیش‌بینی سری‌های زمانی انجام شده است. یکی از مهم‌ترین و پرکاربردترین مدل‌های سری‌های زمانی، شبکه‌های عصبی مصنوعی‌اند. یکی از مزیت‌های بارز این گونه از مدل‌ها

پیش‌بینی قیمت سهام در بورس اوراق بهادار، یک روش ترکیبی پیشنهاد کرده‌اند که ترکیبی از مدل‌های الگوهای مشابه از گروه روش‌های تشخیص الگو و پرسپترون‌های چندلایه از گروه روش‌های هوش مصنوعی بوده است. تسنگ و همکاران [۱۴] یک روش ترکیبی با به‌کارگیری روش‌های میانگین متحرک خودرگرسیون انباشته فصلی و پرسپترون‌های چندلایه به‌منظور پیش‌بینی سری‌های زمانی فصلی ارائه کرده‌اند.

در این مقاله به‌منظور افزایش دقت و بهبود عملکرد پرسپترون‌های چندلایه، ایده‌ای جدید برای ساختن یک مدل ترکیبی از پرسپترون‌های چندلایه ارائه شده است. در روش پیشنهادی بر خلاف روش‌های سنتی ترکیبی پیش‌بینی که روش‌های سری‌های زمانی را با یکدیگر ترکیب می‌کنند، پرسپترون‌های چندلایه را با طبقه‌بندی‌کننده‌های عصبی احتمالی ترکیب می‌کند. هدف اساسی روش پیشنهادی استفاده از مزایای منحصربه‌فرد شبکه‌های عصبی احتمالی به‌عنوان یک طبقه‌بندی‌کننده به‌منظور مشخص کردن روندهای موجود در باقی‌مانده‌های پرسپترون‌های چندلایه و بهبود نتایج حاصله از این مدل است. سایر قسمت‌های این مقاله بدین صورت‌اند: در بخش‌های دوم و سوم به ترتیب برخی از مفاهیم اساسی و نحوه مدل‌سازی پرسپترون‌های چندلایه و شبکه‌های عصبی احتمالی به‌اختصار شرح داده شده است. روش ترکیبی پیشنهادی در بخش چهارم توضیح داده شده است. در بخش پنجم، به کارگیری روش ترکیبی پیشنهادی به‌منظور پیش‌بینی بازارهای ارز (یورو در مقابل ریال) ارائه شده و نتایج حاصله با روش‌های خودرگرسیون میانگین متحرک انباشته، خودرگرسیون میانگین متحرک انباشته فازی، پرسپترون‌های چندلایه و سیستم‌های عصبی-فازی تطبیقی مقایسه شده است. در انتها و در بخش ششم نیز نتیجه‌گیری آورده شده است.

## ۲- روش شبکه‌های عصبی مصنوعی (ANNs)

شبکه‌های عصبی مصنوعی از جمله روش‌هایی هستند که قادر به تخمین موارد غیرخطی متعدد در داده‌ها بوده و یک

اصل استوار است که هیچ‌یک از روش‌های موجود، یک روش جامع برای پیش‌بینی نبوده و قابلیت به‌کارگیری در هر شرایط و هر نوع داده را ندارد. لذا با ترکیب مدل‌های مختلف می‌توان نقاط ضعف یک مدل را با استفاده از نقاط قوت مدل دیگر بهبود بخشید. یافته‌های تجربی و نظری نیز نشان می‌دهند که ترکیب مدل‌های متفاوت یک راه مؤثر و کارآ برای بهبود دقت پیش‌بینی‌ها است [۶].

در تحقیقات مربوط به پیش‌بینی با پرسپترون‌های چندلایه نیز مدل‌های ترکیبی متعددی به‌منظور مرتفع‌سازی محدودیت‌های موجود در این‌گونه از مدل‌ها و حصول نتایج دقیق‌تر ارائه شده و با موفقیت در بازارهای مالی به‌کارگرفته شده‌اند. خاشعی و همکاران [۷] به‌منظور غلبه بر محدودیت تعداد داده‌های مورد نیاز در پرسپترون‌های چندلایه این‌گونه از مدل‌ها را با رگرسیون فازی ترکیب کرده‌اند. امین ناصری و سروش [۸] یک روش ترکیبی از پرسپترون‌های چندلایه با استفاده از نگاشت‌های خودسازمانده به‌منظور پیش‌بینی پیک‌های روزانه مصرف الکتریسیته ارائه کرده‌اند. لین و یو [۹] در کاری مشابه، به‌منظور پیش‌بینی باران‌های سیل‌آسا، یک روش ترکیبی از پرسپترون‌های چندلایه و نگاشت‌های خودسازمانده را پیشنهاد کرده‌اند.

خاشعی و بیجاری [۱۰] یک روش ترکیبی از پرسپترون‌های چندلایه و مدل‌های میانگین متحرک خودرگرسیون انباشته به‌منظور برطرف‌سازی محدودیت مدل‌سازی‌های خطی شبکه‌های عصبی در پیش‌بینی ارائه کرده‌اند. تسای و همکاران [۱۱] یک مدل ترکیبی هوش مصنوعی که از ترکیب پرسپترون‌های چندلایه با تکنیک سیستم‌های قانون محور به‌منظور غلبه بر محدودیت‌های موجود در هر دو مدل ارائه کرده و از مدل پیشنهادی در پیش‌بینی تغییرات قیمت سهام استفاده کرده‌اند. یو و همکاران [۱۲] یک روش ترکیبی با استفاده از مدل‌های رگرسیون خطی تعمیم‌یافته (GLAR) و پرسپترون‌های چندلایه به‌منظور حصول پیش‌بینی‌های دقیق‌تر در بازارهای ارز ارائه کرده‌اند. لیانگ و همکاران [۱۳] نیز برای

رابطه بین خروجی  $(y_t)$  و ورودی‌ها  $(y_{t-1}, y_{t-2}, \dots, y_{t-p})$  به صورت زیر است:

$$y_t = b_0 + \sum_{j=1}^Q w_j \cdot g(b_{0j} + \sum_{i=1}^P w_{i,j} \cdot y_{t-i}) + \varepsilon_t \quad (1)$$

به طوری که  $w_{ij}, w_j$  پارامترهای مدل بوده که غالباً وزن‌های اتصالی نامیده می‌شوند،  $P$  تعداد گره‌های ورودی و  $Q$  تعداد گره‌های مخفی‌اند. تابع سیگموئیدی اغلب به عنوان تابع فعال‌سازی لایه مخفی مورد استفاده قرار می‌گیرد.


$$g(x) = \frac{1}{1 + \exp(-x)} \quad (2)$$

از این رو پرسپترون چندلایه اشاره شده در معادله (1) در حقیقت به عنوان یک نگاشت غیرخطی از مشاهدات گذشته به مقدار آینده خواهد بود. یعنی

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-p}, W) + \varepsilon_t \quad (3)$$

به طوری که  $W$  بردار همه پارامترها و  $f$  تابعی است که توسط ساختار شبکه عصبی و وزن‌های اتصالی تعیین می‌شود، از این رو شبکه‌های عصبی معادل مدل‌های خودرگرسیون غیرخطی هستند [17]. مدل ساده بیان شده توسط معادله (1) دارای قدرت تقریب بسیار زیادی بوده، چراکه قادر است هر تابع دلخواه را به شرط آنکه تعداد گره‌های مخفی ( $Q$ ) به اندازه کافی بزرگ باشد را تقریب بزند. در عمل ساختار یک شبکه عصبی ساده که تعداد نرون کمتری در لایه مخفی خود دارد، غالباً در پیش‌بینی‌های خارج از نمونه بهتر عمل خواهد کرد و این به دلیل دوری جستن از مسئله برازش بیش از حد است که عمدتاً در فرایند مدل‌سازی شبکه‌ها عصبی مصنوعی رخ می‌دهد.

یک مدل بیش از حد برازش شده، برای داده‌هایی که برای ساخت مدل (داده‌های آموزشی) استفاده شده‌اند برازش خوبی نشان می‌دهد اما توانایی تعمیم آن، برای داده‌های خارج از نمونه بسیار ضعیف است. انتخاب تعداد نرون‌های لایه مخفی وابسته به داده‌ها بوده و هیچ قانون سیستماتیکی به منظور تعیین این پارامتر در طراحی شبکه‌های عصبی در ادبیات موضوع



شکل ۱- ساختار کلی یک پرسپترون چندلایه  $(N^{(p-q-1)})$ .

چارچوب محاسبه‌ای انعطاف‌پذیر برای دامنه وسیعی از مسائل غیرخطی‌اند. یکی از مزیت‌های بارز این گونه مدل‌ها نسبت به مدل‌های دیگر غیرخطی، این است که شبکه‌های عصبی مصنوعی یک تقریب‌زننده جهانی هستند که می‌توانند هر نوع تابعی را با دقت دلخواه تقریب بزنند. این گونه از شبکه‌ها نیاز به هیچ گونه پیش‌فرضی در مورد شکل مدل در فرایند مدل‌سازی نداشته و به طور کلی یک مدل مبتنی بر داده هستند. نقطه قوت شبکه‌های عصبی پردازش موازی اطلاعات موجود در داده‌هاست، این گونه از شبکه‌ها نیازمند هیچ گونه پیش‌فرضی در مورد شکل و ساختار مدل در فرایند مدل‌سازی خود نیستند و به طور کلی یک مدل کاملاً مبتنی بر داده هستند [15].

انواع مختلفی از شبکه‌های عصبی مصنوعی وجود دارند که به منظور پیش‌بینی مورد استفاده قرار می‌گیرند که از آن جمله می‌توان به شبکه‌های عصبی چندلایه پیشخور (FFNN)، شبکه‌های عصبی شعاعی محور (RBF)، شبکه‌های عصبی احتمالی (PNN) و شبکه‌های عصبی رگرسیون عمومی (GRNN) اشاره کرد [16]. هر یک از مدل‌های مذکور دارای مزایا و معایبی بوده و عملکردهای متفاوتی نیز در قبال مسائل مختلف داشته‌اند، اما در حالت کلی برتری هیچ‌کدام بر دیگری ثابت نشده است. پرسپترون‌های چندلایه، شبکه‌هایی پیشرو با یک لایه مخفی هستند که جزو پرکاربردترین مدل‌های شبکه‌های عصبی به منظور پیش‌بینی سری‌های زمانی به حساب می‌آیند [15]. این گونه مدل‌ها از سه لایه پردازش ساده اطلاعات متصل به هم تشکیل شده‌اند، شکل (1). در این گونه از شبکه‌ها،

به عبارت دیگر در این گونه از شبکه‌ها می‌توان تضمین کرد که به شرط وجود تعداد داده‌های لازم، حصول هر سطحی از دقت امکان‌پذیر خواهد بود. به علاوه با انتخاب مناسب فاکتور هموارسازی می‌توان سطوح تصمیم‌گیری را بر حسب نیاز بسیار ساده یا بسیار پیچیده تنظیم کرد [۲۱]. شبکه‌های عصبی احتمالی یک اشکال عمده نیز دارند و آن نیاز به ذخیره‌سازی تمامی نمونه‌های آموزشی به منظور طبقه‌بندی الگوهای جدید است که این خود باعث اشغال حجم بزرگی از حافظه می‌شود.

### ۳-۱- استراتژی بیزی

به منظور درک بهتر مفاهیم و نحوه‌ی 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 پرداخته شده است. استراتژی بیزی به مجموعه‌ای از قواعد و استراتژی‌هایی اطلاق می‌شود که به منظور طبقه‌بندی الگوها از مینیم کردن ریسک مورد انتظار استفاده می‌کنند [۲۲]. 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. قاعده‌ی تصمیم‌گیری بیزی برای طبقه‌بندی یک الگوی مشخص ( $X$ ) و تعلق آن الگو به یک طبقه خاص عبارت است از

$$X \in C_r \quad \text{if} \quad h_r I_r f_r(X) \geq h_s I_s f_s(X) \quad (4)$$

for  $\forall s, s \neq r \quad 1 \leq r \leq q$

به قسمی که  $I_i$  ضرر متناظر با تعلق اشتباه الگوی  $X$  به کلاس  $i$ ام،  $h_i$  یک احتمال اولیه از تعلق الگوی  $X$  به کلاس  $i$ ام و  $f_i(X)$  تابع چگالی احتمال کلاس  $i$ ام برای ورودی  $X$  است. در حالت کلی سطوح تصمیم‌گیری را می‌توان به دلخواه پیچیده انتخاب کرد، چرا که هیچ محدودیتی برای تابع چگالی احتمال به جز شرایط عمومی این گونه از توابع (نامنفی، انتگرال‌پذیر بودن در تمامی نقاط و مساوی یک بودن انتگرال آنها در دامنه‌ی تعریف) وجود ندارد. پارزن نشان داده است که یک کلاس از تخمین‌زنده‌های PDF هموار و پیوسته وجود دارند که به‌طور

وجود ندارد. مرحله مهم دیگر مدل‌سازی شبکه‌های عصبی، انتخاب تعداد وقفه‌های موجود در مشاهدات به‌عنوان بردار ورودی شبکه است که شاید مهم‌ترین پارامتر در طراحی شبکه‌های عصبی باشد، چراکه این پارامتر در تعیین ساختارهای خودهمبسته غیرخطی موجود در سری‌های زمانی نقش اساسی دارند. هیچ نظریه خاصی برای انتخاب  $P$  وجود ندارد، از این رو تجربه و آزمون و خطا مشخص‌کننده مقدار مناسب  $P$  و  $Q$  خواهند بود. وقتی یک ساختار شبکه‌ای  $P$  و  $Q$  مشخص شد، شبکه آماده آموزش فرایند تخمین پارامترهاست. همانند مدل‌سازی خودرگرسیون میانگین متحرک انباشته پارامترها طوری تخمین‌زده می‌شوند که معیار دقت شبکه مانند میانگین مربعات خطا حداقل شود. این فریند توسط الگوریتم‌های بهینه‌سازی غیرخطی همچون پس‌انتشار خطا انجام می‌شود [۱۸].

### ۳- شبکه‌های عصبی احتمالی (PNN)

شبکه‌های عصبی که به منظور شناخت و طبقه‌بندی الگوها مورد استفاده قرار می‌گیرند، به‌طور کلی الگوهای موجود در داده‌های آموزش را یادگرفته، سپس نمونه‌های جدید را بر اساس این الگوها دسته‌بندی می‌کنند. شبکه‌های عصبی احتمالی از مهم‌ترین روش‌های باناظر بوده که به‌منظور شناخت و طبقه‌بندی الگوها مورد استفاده قرار می‌گیرند. این‌گونه از شبکه‌ها برای اولین بار در سال ۱۹۸۸ توسط دونالد اسپیچت [۱۹] معرفی شدند. شبکه‌های عصبی احتمالی الگوها را بر اساس استراتژی بیزی و تخمین‌زنده‌های غیرپارامتریک توابع چگالی احتمال طبقه‌بندی می‌کنند و از جمله روش‌هایی هستند که مبتنی بر الگوهای آماری موجود در داده عمل می‌کنند. این‌گونه از شبکه‌ها از الگوریتم‌های یادگیری یک بارگذر از داده‌ها استفاده کرده و این یکی از بزرگترین مزیت‌های آنها به حساب می‌آید [۲۰].

همچنین در الگوریتم یادگیری شبکه‌های عصبی احتمالی تضمین می‌شود که با افزایش تعداد نمونه‌های آموزشی، سطوح تصمیم‌گیری به مرزهای تصمیم‌گیری بهینه میل خواهند کرد.

به کارگیری روش تقریب پارزن مستقیماً از مجموعه داده‌های آموزشی برآورد می‌شود. لازم به ذکر است، اگرچه تابع (۶) به صورت مجموعی از توزیع‌های گوسی چندمتغیره کوچک است. اما این دلیلی برگوسی بودن مجموع آنها نبوده و این مجموع می‌تواند هر تابع چگالی احتمالی را تقریب بزند [۲۶].

### ۳-۲-۱- توپولوژی شبکه‌های عصبی احتمالی


شبکه‌های عصبی احتمالی با استفاده از منطق دسته‌بندی مذکور و به منظور اجرای آنها، طراحی و ساخته شده‌اند. ساختار شبکه‌های عصبی احتمالی در حالت کلی شامل چهار لایه است، یک لایه ورودی و سه لایه پردازش اطلاعات شامل لایه الگو، لایه کلاس‌بندی و لایه خروجی. ساختار کلی یک شبکه عصبی احتمالی در شکل (۲) آورده شده است. نرونهای لایه ورودی صرفاً وظیفه انتقال مقادیر ورودی به تمام نرونهای لایه دوم را بر عهده داشته و هیچ‌گونه پردازشی در این لایه بر روی داده‌ها صورت نمی‌گیرد. هر یک از نرونهای لایه دوم، حاصل ضرب نقطه‌ای بردار ورودی را در یک بردار وزن محاسبه می‌کند و پس انجام یک عمل غیرخطی بر روی حاصل ضرب مذکور نتیجه را در اختیار لایه سوم قرار می‌دهد. تابع غیرخطی این لایه اگر مقادیر مربوط به ورودی‌ها و اوزان به طول واحد نرمالیزه شده باشند مطابق زیر خواهد بود [۲۷].

$$\exp(-(W_i - X)^T (W_i - X) / 2\sigma^2). \quad (7)$$

نرون‌های لایه سوم ورودی‌های متناظر با دسته‌ای که الگوی آموزش به آن تعلق دارد را با هم جمع می‌کند. در نهایت نیز نرون‌های لایه خروجی با به دست آوردن یک مجموع وزنی از دو ورودی خود و با استفاده از یک تابع فعالیت دوحالته، کلاس و طبقه ورودی مورد نظر را مشخص می‌کنند [۲۸].

### ۳-۲-۲- نرمال کردن ورودی‌ها و انتخاب فاکتور هموارسازی

از آنجایی که توابع چگالی احتمالی تخمین زده شده دارای



شکل ۲- ساختار کلی یک شبکه عصبی احتمالی.

مجانبی به تابع چگالی‌های اصلی میل می‌کنند [۲۳]. این توابع همچنین می‌توانند در مورد تابع چگالی‌های چند بعدی نیز مورد استفاده قرار گیرند.

### ۳-۲-۳- شبکه‌های عصبی احتمالی

شبکه‌های عصبی احتمالی بر اساس استراتژی بیزی در دسته‌بندی الگوها ساخته شده‌اند و با در دسترس داشتن داده‌های مشخص ابزارهای قدرتمندی برای شناخت و طبقه‌بندی الگوها با بیشترین احتمال موفقیت‌اند [۲۴]. اساس سایر دسته‌بندی کننده‌های بیزی بر انتخاب کلاسی با بزرگترین جمله حاصله از قاعده‌ی استراتژی بیزی است [۲۵].

$$\text{Max}_i \{h_i | f_i(X)\} \quad (8)$$

معادله فوق قانون تصمیم‌گیری که برای شناخت تابع چگالی احتمال مورد نیاز است را پیشنهاد نمی‌کند. یک تخمین‌زننده خاص از این نوع که در شبکه‌های عصبی احتمالی مورد استفاده قرار می‌گیرند مطابق زیرند

$$f_i(X) = \frac{1}{(2\pi)^{\frac{k}{2}} \sigma^k} \cdot \frac{1}{n_i} \sum_{j=1}^{n_i} \exp \left[ -\frac{(X - Y_{i,j})^T \cdot (X - Y_{i,j})}{2\sigma^2} \right] \quad (9)$$

به قسمی که  $X$  بردار ورودی،  $k$  تعداد متغیرهای موجود در بردار ورودی (بعد بردار ورودی)،  $n_i$  تعداد الگوهای آموزشی موجود در کلاس  $i$  ام،  $Y_{i,j}$  زمین الگوی آموزشی در کلاس  $i$  ام و  $\sigma$  پارامتر هموارسازی است. تابع چگالی احتمال فوق‌الذکر با

این مدل است. فرایند مدل‌سازی روش پیشنهادی را می‌توان در پنج مرحله خلاصه کرد. در مرحله اول، سری زمانی مورد مطالعه  $\{y_t\}$  ابتدا توسط یک مدل پرسپترون چندلایه مطابق زیر مدل‌سازی می‌شود.

$$y_t = \text{Fit}_{\text{MLP}}(t) + e_t = \hat{y}_t + e_t \quad (8)$$

به قسمی که  $\text{Fit}_{\text{MLP}}(t)$  یا  $\hat{y}_t$  مقادیر برآورد شده توسط مدل پرسپترون چندلایه در زمان  $t$  و  $e_t$  مقادیر باقیمانده‌های مدل در زمان  $t$  هستند.

در مرحله دوم، بر اساس مقادیر به دست آمده از مرحله اول و سطح مطلوب خطا (DLE)، باقیمانده‌های مدل پرسپترون چندلایه مطابق روابط زیر به سه دسته طبقه‌بندی می‌شوند. این نکته قابل ذکر است که سطح مطلوب خطا، عددی است نامنفی که بیانگر میزان حساسیت مدل پیشنهادی نسبت به نتایج مرحله اول است و توسط پیش‌بینی‌کننده و یا تصمیم‌گیرنده تعیین می‌شود.

الف) باقیمانده‌هایی که اکیداً بزرگتر از سطح مطلوب خطا هستند  $\{e_i / e_i > \text{DLE}\}$ ، در کلاس و طبقه اول قرار گرفته و مقدار مثبت یک به آن‌ها تخصیص داده می‌شود ( $\text{trend} = +1$ ).  
ب) باقیمانده‌هایی که اکیداً از قرینه سطح مطلوب خطا کوچکتر هستند  $\{e_i / e_i < -\text{DLE}\}$ ، در کلاس و طبقه دوم قرار گرفته و مقدار منفی یک به آن‌ها تخصیص داده می‌شود ( $\text{trend} = -1$ ).

ج) باقیمانده‌هایی که کوچکتر و یا مساوی با سطح مطلوب خطا هستند و یا بزرگتر و یا مساوی با قرینه سطح مطلوب خطا هستند  $\{e_i / -\text{DLE} \leq e_i \leq \text{DLE} \text{ or } |e_i| \leq \text{DLE}\}$ ، در کلاس و طبقه سوم قرار گرفته و مقدار صفر به آن‌ها تخصیص داده می‌شود ( $\text{trend} = 0$ ).

در مرحله سوم، یک شبکه عصبی احتمالی به منظور تعیین روند موجود در باقیمانده‌ها طراحی و آموزش داده می‌شود. شبکه‌های عصبی احتمالی یکی از موفق‌ترین و کاربردی‌ترین نوع از این شبکه‌ها بوده که بر اساس نظر کارشناسان با در

یک هسته با پهنای ثابت در دو سمت هستند، معمولاً لازم است به عنوان یک پیش‌پردازش داده‌ها، تمام متغیرهای ورودی به گونه‌ای تغییر مقیاس داده شوند که همگی دارای یک واریانس ثابت باشند. پس از تغییر مقیاس نوبت به انتخاب پهنای تابع چگالی احتمال تخمین زده شده ( $\sigma$ ) می‌رسد [۲۹]. انتخاب این پهنای در نحوه‌ی تخمین تابع چگالی احتمال و در نتیجه در تصمیم‌گیری بسیار موثر است. یک روش مرسوم برای انتخاب  $\sigma$  روش "کنار گذاشتن نمونه‌هاست". در این روش برای یک مقدار خاص  $\sigma$ ، در هر زمان یک نمونه کنار گذاشته شده و شبکه بر اساس سایر نمونه‌ها ساخته می‌شود. سپس از شبکه حاصل برای تخمین  $\sigma$  متناظر با نمونه کنار گذاشته شده استفاده می‌گردد. با تکرار این رویه برای هر نمونه، میانگین مربعات خطا (MSE) در مقدار مشخص  $\sigma$  محاسبه می‌شود. سپس با تغییر  $\sigma$  اعمال فوق چندین بار تکرار می‌شود. نهایتاً شبکه اصلی بر اساس مقداری از  $\sigma$  که کمترین خطای متناظر را داراست، ایجاد می‌شود [۲۹].

#### ۴- روش ترکیبی پیشنهادی

امروزه علی‌رغم وجود روش‌های کمی متعدد برای پیش‌بینی‌های مالی، هنوز پیش‌بینی‌های دقیق در بازارهای مالی کار چندان ساده‌ای نیست و اکثر محققان درصدد به کارگیری و ترکیب روش‌های متفاوت به منظور حصول نتایج دقیق‌ترند. در ادبیات موضوع، روش‌های ترکیبی بسیاری به منظور غلبه بر محدودیت‌های روش‌ها و مدل‌های تکی و همچنین حصول نتایج دقیق‌تر ارائه شده است [۳۰]. در این مقاله بر خلاف روش‌های سنتی پیش‌بینی که روش‌های متفاوت سری‌های زمانی را با یکدیگر ترکیب می‌کنند، پرسپترون‌های چندلایه به عنوان یک روش سری‌های زمانی، با مدل‌های کلاس‌بندی داده‌ها ترکیب شده است. هدف اساسی روش پیشنهادی استفاده از مزایای منحصر به فرد شبکه‌های عصبی احتمالی به عنوان یک طبقه‌بندی‌کننده به منظور مشخص کردن روندهای موجود در باقیمانده‌های پرسپترون‌های چندلایه و بهبود نتایج حاصله از

در داده‌های آزمون، ساختار شبکه بهینه و همچنین مقدار بهینه پارامتر هموارسازی معین می‌شود.

در مرحله چهارم، بر اساس نتایج به دست آمده از مراحل قبلی، طول گام بهینه (OSL) با استفاده مدل‌های برنامه‌ریزی ریاضی زیر محاسبه می‌شود.

$$\text{Minimize } Z = \sum_{t=1}^n d_t$$

$$\text{subto } \begin{cases} d_t \geq y_t - \hat{y}_t - \text{tar}(t) \times \text{CLS} & \text{for } t=1,2,\dots,n \\ d_t \geq \hat{y}_t - y_t + \text{tar}(t) \times \text{CLS} & \text{for } t=1,2,\dots,n \\ x_t d_t \leq x_t y_t - x_t \hat{y}_t - x_t \text{tar}(t) \times \text{CLS} & \text{for } t=1,2,\dots,n \\ (1-x_t) d_t \leq (1-x_t) \hat{y}_t - (1-x_t) y_t + (1-x_t) \text{tar}(t) \times \text{CLS} & \text{for } t=1,2,\dots,n \\ \text{OSL}, d_t \geq 0, \quad x_t \in \{0,1\} & t=1,2,\dots,n. \end{cases} \quad (9)$$

$$\text{Minimize } Z = \sum_{t=1}^n d_t$$

$$\text{subto } \begin{cases} d_t \geq y_t - \hat{y}_t - \text{tar}(t) \times \text{CLS} & \text{for } t=1,2,\dots,n \\ d_t \geq \hat{y}_t - y_t + \text{tar}(t) \times \text{CLS} & \text{for } t=1,2,\dots,n \\ x_t d_t \leq x_t y_t - x_t \hat{y}_t - x_t \text{tar}(t) \times \text{CLS} & \text{for } t=1,2,\dots,n \\ (1-x_t) d_t \leq (1-x_t) \hat{y}_t - (1-x_t) y_t + (1-x_t) \text{tar}(t) \times \text{CLS} & \text{for } t=1,2,\dots,n \\ \text{OSL}, d_t \geq 0, \quad x_t \in \{0,1\} & t=1,2,\dots,n. \end{cases} \quad (10)$$

به قسمی که  $\text{tar}(t)$  مقادیر به دست آمده از شبکه عصبی احتمالی در زمان  $t$  هستند. در مرحله نهمی نیز بر اساس نتایج حاصله از قسمت‌های قبلی، مقادیر برآورده شده توسط پرسپترون چندلایه مطابق معادله زیر اصلاح شده و مقادیر حاصله از مدل ترکیبی محاسبه می‌شود.


$$\text{Fit}_p(t) = \text{Fit}_{\text{MLP}}(t) + [\text{tar}(t) \times \text{OSL}] \quad (11)$$

به قسمی که  $\text{Fit}_p(t)$  و  $\text{Fit}_{\text{MLP}}(t)$  به ترتیب مقادیر برآورده شده توسط مدل ترکیبی و پرسپترون چندلایه در زمان  $t$  هستند.

$$\text{MAE}_p = \text{MAE}_{\text{MLP}} + \frac{1}{n} \left[ \sum_{t=1}^n D(\text{tar}(t), \text{trade}(t)) \times |\text{tar}(t)| \times \text{OSL} \right] \quad (12)$$

$$\text{MSE}_p = \text{MSE}_{\text{MLP}} + \frac{1}{n} \left[ \sum_{t=1}^n (D(\text{tar}(t), \text{trend}(t)) \times |\text{tar}(t)| \times \text{OSL})^2 \right] \quad (13)$$

به قسمی که  $\text{MAE}_{\text{MLP}}$ ،  $\text{MAE}_p$ ،  $\text{MSE}_{\text{MLP}}$  و  $\text{MSE}_p$  به ترتیب میانگین قدرمطلق خطا و میانگین مربعات خطای



شکل ۳- تعداد نرون‌های خروجی در مسئله‌ای با  $k$  کلاس متفاوت.

دسترس داشتن داده‌های مشخص ابزارهای قدرتمندی برای شناخت و طبقه‌بندی الگوها با بیشترین احتمال موفقیت‌اند [۲۴]. اولین مسئله در طراحی یک شبکه عصبی احتمالی تعیین تعداد نرون‌های ورودی یا به عبارت دیگر تعیین ورودی‌های شبکه است که بی‌شک مهم‌ترین قسمت در طراحی این‌گونه از شبکه‌هاست. اصولاً هیچ روش سیستماتیکی به منظور تعیین ورودی‌های شبکه در حالت کلی وجود نداشته و اغلب محققان از طریق آزمایش و خطا، متغیرهای مؤثر و ورودی‌های شبکه را از میان مجموعه متغیرهای ممکن انتخاب می‌کنند. به‌طور کلی مجموعه کلیه متغیرهایی که کاندیدای ورود به شبکه احتمالی در این مرحله هستند، عبارت‌اند از

- ۱- وقفه‌های اول تا  $p$ ام سری زمانی در زمان  $t$   $(y_{t-1}, y_{t-2}, \dots, y_{t-p})$ .
- ۲- وقفه‌های اول تا  $q$ ام باقیمانده‌ها در زمان  $t$   $(e_{t-1}, e_{t-2}, \dots, e_{t-q})$ .
- ۳- مقدار پیش‌بینی شده سری زمانی در زمان  $t$   $(\hat{y}_t)$ .
- ۴- وقفه‌های اول تا  $r$ ام مقدار پیش‌بینی شده سری زمانی در زمان  $t$   $(\hat{y}_{t-1}, \hat{y}_{t-2}, \dots, \hat{y}_{t-r})$ .

به قسمی که  $p, q$  و  $r$  اعداد طبیعی‌اند. مسئله بعدی در طراحی شبکه تعیین تعداد نرون‌های خروجی است. در حالت کلی تعداد نرون‌های خروجی در مسئله‌ای با  $k$  کلاس متفاوت برابر با  $k-1$  است [۳۱]، شکل (۳)، لذا در مسئله‌ی مورد نظر، تعداد نرون‌های خروجی برابر با دو خواهد بود. در انتها با بررسی ساختارهای مختلف و با توجه به درصد تشخیص صحیح روند




جدول ۱- تقسیم‌بندی داده‌ها به داده‌های آزمون و آموزش.

سری زمانی	سایز نمونه	آموزش	آزمون
نرخ ارز (یورو در مقابل ریال)	۱۲۰	۱۰۰	۲۰

جدول ۲- معیارهای عملکرد پرسپترون چندلایه در پیش‌بینی نرخ ارز.

آموزش		آزمون					
MSE	MAE	MSE	SSE	RMSE	ME	MAPE	MAE
۲۱۴۴	۳۲/۴۴	۳۹۱۷	۷۸۳۴۹	۶۲/۵۹	-۴/۳۹	۰/۳۸۷	۴۳/۵۳



شکل ۴- نرخ ارز مربوط به ۱۳ بهمن ماه ۱۳۸۴ تا ۱۸ خرداد ماه ۱۳۸۵.

#### ۵-۱- مجموعه داده‌ها

داده‌های استفاده شده در این مقاله، داده‌های روزانه نرخ ارز (یورو در مقابل ریال) مربوط به سیزدهم بهمن ماه ۱۳۸۴ تا هجدهم خرداد ماه ۱۳۸۵ مطابق با دوم فوریه ۲۰۰۶ تا هشتم ژوئن ۲۰۰۶ بوده و جمعاً شامل ۱۲۰ داده است. نمودار مربوط به نرخ ارز (یورو در مقابل ریال) بر اساس زمان در شکل (۴) آورده شده است.

#### ۵-۲- نتایج حاصله


در این قسمت نتایج پنج مدل خودرگرسیون میانگین متحرک انباشته، خودرگرسیون میانگین متحرک انباشته فازی، پرسپترون‌های چندلایه، سیستم‌های عصبی-فازی تطبیقی و مدل ترکیبی پیشنهادی آورده شده است. در این مطالعه تمامی مدل‌سازی‌های مدل‌های خودرگرسیون میانگین متحرک انباشته

مدل‌های ترکیبی و پرسپترون‌های چندلایه و  $D(x, y)$  تابعی مطابق رابطه زیر است.

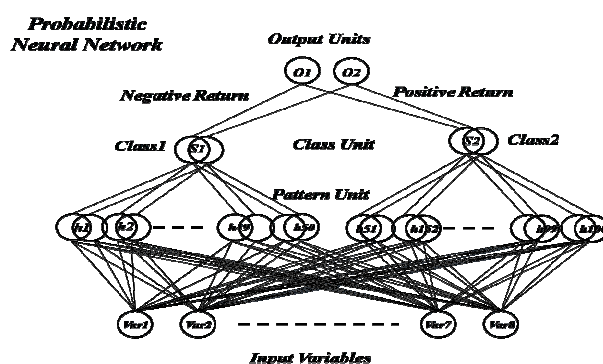
$$D(x, y) = \begin{cases} +1 & \text{if } x = y \\ -1 & \text{if } x \neq y \end{cases} \quad (14)$$

#### ۵-۳- به‌کارگیری روش پیشنهادی در پیش‌بینی نرخ ارز

با توجه به مطالب بیان‌شده، در این بخش با استفاده از روش پیشنهادی، نرخ ارز (یورو در مقابل ریال ایران) پیش‌بینی شده و نتایج حاصله با مدل‌های خودرگرسیون میانگین متحرک انباشته، خودرگرسیون میانگین متحرک انباشته فازی، همچنین پرسپترون‌های چندلایه و سیستم‌های عصبی-فازی تطبیقی از نظر دقت پیش‌بینی، مقایسه شده است.



شکل ۵- مقادیر واقعی و پیش‌بینی شده توسط پرسپترون چندلایه.



شکل ۶- ساختار شبکه عصبی احتمالی طراحی شده.

عملکرد پرسپترون چندلایه در پیش‌بینی نرخ ارز (یورو در مقابل ریال) برای هر یک از مجموعه‌های آزمون و آموزش در جدول (۲) آورده شده است. همچنین مقادیر حقیقی و پیش‌بینی شده توسط پرسپترون چندلایه در شکل (۵) آورده شده است.

پس از اجرای پرسپترون چندلایه، شبکه عصبی احتمالی به کار گرفته می‌شود. همچون مرحله قبل ۱۰۰ مشاهده به منظور آموزش شبکه و سپس ۲۰ مشاهده به منظور بررسی عملکرد شبکه مورد استفاده قرار گرفته است. طول گام در این مسئله خاص  $DLE = 8$  در نظر گرفته شده است، لذا با توجه به مطالب بیان شده در قسمت قبلی و انجام آزمایشات متعدد، شبکه بهینه، شبکه‌ای با هشت ورودی و دو خروجی است. ساختار شبکه مذکور در شکل (۶) آورده شده است. ورودی‌های شبکه با

توسط نرم‌افزار Eviews و مدل‌سازی‌های شبکه‌های عصبی توسط نرم‌افزار MATLAB 7 انجام شده است. همچنین دو معیار میانگین مربعات خطا (MSE) و میانگین قدرمطلق خطا (MAE) به عنوان معیار سنجش عملکرد و تصمیم‌گیری در نظر گرفته شده‌اند. تقسیم‌بندی داده‌ها به داده‌های آزمون و آموزش در جدول (۱) آورده شده است.

۱- میانگین مربعات خطا (MSE)

$$MSE = \frac{1}{N} \sum_{i=1}^N (e_i)^2$$

۲- میانگین مطلق خطا (MAE)

$$MAE = \frac{1}{N} \sum_{i=1}^N |e_i|$$

با توجه به تعداد داده‌ها (سایز نمونه) و مراحل اجرای روش پیشنهادی، در مرحله‌ی اول یک پرسپترون چندلایه به منظور مدل‌سازی داده‌ها مورد استفاده قرار گرفته شده است. معیارهای

جدول ۳- روند و مقادیر واقعی و پیش‌بینی شده برای داده‌های آزمون.

تاریخ	واقعی		تاریخ	تشخیص داده شده		واقعی		تاریخ
	مقدار	روند		مقدار	روند	مقدار	روند	
۲۵- اردیبهشت	۱۱۷۲۳	+	۶- خرداد	۱۱۷۳۲	۰	۱۱۷۵۰	-	۲۵- اردیبهشت
۲۶- اردیبهشت	۱۱۶۴۴	۰	۷- خرداد	۱۱۸۱۴	+	۱۱۷۲۹	+	۲۶- اردیبهشت
۲۷- اردیبهشت	۱۱۶۹۳	+	۸- خرداد	۱۱۸۳۲	+	۱۱۸۰۷	+	۲۷- اردیبهشت
۲۸- اردیبهشت	۱۱۷۶۷	۰	۹- خرداد	۱۱۷۵۰	+	۱۱۷۱۰	+	۲۸- اردیبهشت
۳۰- اردیبهشت	۱۱۷۸۲	+	۱۰- خرداد	۱۱۵۸۹	۰	۱۱۶۳۴	-	۳۰- اردیبهشت
۳۱- اردیبهشت	۱۱۷۵۶	+	۱۱- خرداد	۱۱۶۳۹	۰	۱۱۶۳۵	۰	۳۱- اردیبهشت
۱- خرداد	۱۱۷۵۰	-	۱۳- خرداد	۱۱۷۱۵	+	۱۱۶۸۴	+	۱- خرداد
۲- خرداد	۱۱۷۶۹	۰	۱۶- خرداد	۱۱۷۹۲	+	۱۱۷۵۸	+	۲- خرداد
۳- خرداد	۱۱۷۷۸	+	۱۷- خرداد	۱۱۵۶۹	-	۱۱۷۷۶	-	۳- خرداد
۴- خرداد	۱۱۶۶۹	-	۱۸- خرداد	۱۱۷۲۶	+	۱۱۷۰۴	+	۴- خرداد

به قسمی که

Var1: وقفه‌های اول سری زمانی در زمان  $t$  ( $y_{t-1}$ ).

Var2: وقفه‌های دوم سری زمانی در زمان  $t$  ( $y_{t-2}$ ).

Var3: وقفه‌های اول باقیمانده‌ها در زمان  $t$  ( $e_{t-1}$ ).


Var4: وقفه‌های دوم باقیمانده‌ها در زمان  $t$  ( $e_{t-2}$ ).

Var5: وقفه‌های سوم باقیمانده‌ها در زمان  $t$  ( $e_{t-3}$ ).

Var6: وقفه‌های چهارم باقیمانده‌ها در زمان  $t$  ( $e_{t-4}$ ).

Var7: مقدار پیش‌بینی شده‌ی سسری زمانی در زمان  $t$  ( $\hat{y}_t$ ).

Var8: وقفه‌های اول مقدار پیش‌بینی شده‌ی سری زمانی در زمان  $t$  ( $\hat{y}_{t-1}$ ).



شکل ۷- مقادیر واقعی و پیش‌بینی شده توسط روش ترکیبی پیشنهادی.

(+ و ۰ و -) هستند. همچنین داده‌های ورودی به بازه [۰°] نرمالیزه شده‌اند. در انتها نیز با توجه به شبکه عصبی احتمالی

توجه به مجموعه اولیه متغیرهای موجود و بر اساس شرایط مسئله مورد نظر انتخاب شده‌اند. خروجی شبکه نیز مقادیر

جدول ۴- معیارهای عملکرد مدل ترکیبی پیشنهادی در پیش‌بینی نرخ ارز.

آموزش		تست					
MSE	MAE	MSE	SSE	RMSE	ME	MAPE	MAE
۱۵۱۹	۲۷/۳۰	۲۹۳۸	۵۱۷۶۹	۵۴/۲۰	۱۰/۷۶	۰/۳۰۲	۳۵/۵۲

جدول ۵- نتایج به‌دست آمده از مدل‌ها.

داده‌های تست						معیار ارزیابی	روش
MSE	SSE	RMSE	ME	MAPE	MAE		
۴۱۹۲	۸۳۸۵۲	۶۴/۷۵	-۱/۲۷	۰/۴۷۶	۵۵/۹۰	خودرگرسیون میانگین متحرک انباشته (ARIMA)	
۴۰۷۲	۸۱۴۵۲	۶۳/۸۱	۳/۶۷	۰/۴۵۱	۵۱/۷۵	خودرگرسیون میانگین متحرک انباشته فازی (FARIMA)	
۳۹۱۷	۷۸۳۴۹	۶۲/۵۹	-۴/۳۹	۰/۳۸۷	۴۳/۵۳	پرسپترون‌های چندلایه (MLP)	
۳۳۱۲	۶۶۲۴۳	۵۷/۵۵	۵/۵۸	۰/۳۲۷	۳۷/۹۲	سیستم‌های عصبی- فازی تطبیقی (ANFIS)	
۲۹۳۸	۵۱۷۶۹	۵۴/۲۰	۱۰/۷۶	۰/۳۰۲	۳۵/۵۲	مدل ترکیبی پیشنهادی (PNN/MLP)	

با روش‌های خودرگرسیون میانگین متحرک انباشته، خودرگرسیون میانگین متحرک انباشته فازی، پرسپترون‌های چندلایه و سیستم‌های عصبی-فازی تطبیقی بیانگر برتری روش پیشنهادی بر روش‌های دیگر است. به‌کارگیری روش پیشنهادی به‌منظور پیش‌بینی نرخ ارز نتایج حاصله را به ترتیب به میزان ۲۹/۹۱٪، ۲۷/۸۵٪، ۲۴/۹۹٪، ۱۱/۲۹٪ در میانگین مربعات خطا و به میزان ۳۶/۴۶٪، ۳۱/۳۶٪، ۱۸/۴۰٪ و ۶/۳۳٪ در میانگین قدرمطلق خطا نسبت به مدل‌های خودرگرسیون میانگین متحرک انباشته، خودرگرسیون میانگین متحرک انباشته فازی، پرسپترون‌های چندلایه و سیستم‌های عصبی-فازی تطبیقی بهبود داده است.

### ۶- نتیجه‌گیری

دقت پیش‌بینی سری‌های زمانی در بسیاری از فرایندهای تصمیم‌گیری نقش اساسی داشته و با وجود روش‌های متعدد پیش‌بینی هنوز پیش‌بینی‌های دقیق در بازارهای مالی کار چندان ساده‌ای نیست. از اینرو تحقیقات بسیاری به‌منظور بهبود دقت مدل‌های پیش‌بینی انجام شده است. در این مقاله، به‌منظور بهبود

طراحی‌شده در مرحله قبلی، روند موجود در داده‌ها تشخیص داده شده‌اند. نتایج حاصله مطابق جدول (۳) است.

همان طوری که در جدول فوق مشاهده می‌شود، شبکه عصبی احتمالی قادر است ۶۵٪ از نقاط شکست را به درستی تشخیص دهد، لذا تغییرات فوق‌الذکر بر روی داده‌ها اعمال می‌شود. حال با توجه به روندهای به‌دست آمده از شبکه عصبی احتمالی و مقادیر پیش‌بینی‌شده توسط پرسپترون چندلایه، نتایج روش پیشنهادی برای داده‌های آزمون و آموزش در شکل (۷) آورده شده‌اند. همچنین با توجه به تغییرات اعمال‌شده بر روی داده‌ها معیارهای عملکردی روش ترکیبی پیشنهادی در جدول (۴) آورده شده است.

### ۵-۳- مقایسه روش ترکیبی با سایر روش‌ها

در این قسمت به‌منظور نشان‌دادن برتری مدل پیشنهادی نسبت به مدل‌های تشکیل‌دهنده، نتایج سه مدل با یکدیگر مقایسه شده‌اند. معیارهای عملکرد به‌دست آمده از روش‌های خودرگرسیون میانگین متحرک انباشته، پرسپترون‌های چندلایه و مدل ترکیبی پیشنهادی برای داده‌های آزمون در جدول (۵) آورده شده است. نتایج به‌دست آمده از مقایسه روش پیشنهادی

مربعات خطا و به میزان  $15/84\%$  و  $18/40\%$  در میانگین قدرمطلق خطا به ترتیب در داده‌های آموزش و آزمون نسبت به پرسپترون‌های چندلایه بهبود داده است.

### قدردانی

در اینجا جا دارد از داوران محترم این مقاله و همچنین جناب آقای دکتر غلامعلی رئیسی اردلی، استادیار دانشکده مهندسی صنایع دانشگاه صنعتی اصفهان، به سبب راهنمایی‌های سازنده این عزیزان در تألیف این مقاله کمال تشکر و قدردانی را داشته باشیم.

عملکرد و حصول نتایج دقیق‌تر یک روش جدید به منظور پیش‌بینی در محیط‌های مالی پیشنهاد شده است. روش پیشنهادی از قدرت تشخیص شبکه‌های عصبی احتمالی به منظور تشخیص روند موجود در باقیمانده‌های پرسپترون‌های چندلایه استفاده می‌کند و بدین ترتیب نتایج حاصله را بهبود می‌بخشد. نتایج حاصله از پیش‌بینی نرخ ارز (یورو در مقابل ریال) با روش ترکیبی پیشنهادی بیانگر بهبود در دقت پیش‌بینی‌ها نسبت به مدل‌های خودرگرسیون میانگین متحرک انباشته و پرسپترون‌های چندلایه در معیارهای سنجش عملکرد انتخابی شده است. به کارگیری روش پیشنهادی به منظور پیش‌بینی نرخ ارز نتایج حاصله را به ترتیب به میزان  $29/15\%$  و  $24/99\%$  در میانگین

### مراجع

1. خاشعی، م.، "پیش‌بینی و تحلیل قیمت محصولات عرضه‌شده شرکت ذوب آهن اصفهان در بورس فلزات تهران با به‌کارگیری شبکه‌های عصبی مصنوعی پایان‌نامه کارشناسی ارشد، دانشکده صنایع و سیستم‌ها، دانشگاه صنعتی اصفهان، ۱۳۸۴.
2. خاشعی، م. و بیجاری، م.، بهبود عملکرد پیش‌بینی‌های مالی با ترکیب مدل‌های خطی و غیر خطی خودرگرسیون میانگین متحرک انباشته و شبکه‌های عصبی مصنوعی، فصلنامه پژوهش‌های اقتصادی، دانشگاه تربیت مدرس، سال هشتم، شماره ۲، ص ۱۰۰-۸۳، تابستان ۱۳۸۷.
3. Khashei, M., and Bijari, M., "A Novel Hybridization of Artificial Neural Networks and ARIMA Models for Time Series Forecasting," *Applied Soft Computing*, Vol. 11, pp. 2664–2675, 2011.
4. Reid, M.J., "Combining three Estimates of Gross Domestic Product," *Economica*, Vol. 35, pp. 431–444, 1968.
5. Bates, J.M., and Granger, W.J., "The Combination of Forecasts," *Operation Research*, Vol. 20, pp. 451–468, 1969.
6. خاشعی، م. و بیجاری، م.، به‌کارگیری مدل‌های میانگین متحرک خودرگرسیون انباشته فازی به منظور پیش‌بینی نرخ ارز، مجله علمی و پژوهشی استقلال ویژه‌نامه روش‌های عددی در مهندسی، دانشگاه صنعتی اصفهان، سال ۲۶، شماره ۲، ص ۷۵-۶۷، اسفند ۱۳۸۶.
7. Khashei, M., Hejazi, S.R., and Bijari, M., "A New Hybrid Artificial Neural Networks and Fuzzy Regression Model for Time Series Forecasting," *Fuzzy Sets and Systems*, Vol. 159, pp. 769–786, 2008.
8. Amin-Naseri, M.R. and Soroush, A.R., "Combined Use of Unsupervised and Supervised Learning for Daily Peak Load Forecasting," *Energy Conversion and Management*, Vol. 49, pp. 1302–1308, 2008.
9. Lin, G., and Wu, M., A., "Hybrid Neural Network Model for Typhoon-Rainfall Forecasting," *Journal of Hydrology*, Vol. 375, pp. 450–458, 2009.
10. Khashei, M., and Bijari, M., "An Artificial Neural Network (p,d,q) Model for Time Series Forecasting," *Expert Systems with Applications*, Vol. 37, pp. 479–489, 2010.
11. Tsaih, R., Hsu, Y., and Lai, C., "Forecasting S&P 500 Stock Index Futures with a Hybrid AI System," *Decision Support Systems*, Vol. 23, pp. 161–174, 1998.
12. Yu, L., Wang, S., and Lai, K.K., "A Novel Nonlinear Ensemble Forecasting Model Incorporating GLAR and ANN for Foreign Exchange Rates," *Computers and Operations Research*, Vol. 32, pp. 2523–2541, 2005.
13. Leigh, W., Paz, M., and Purvis, R., "An Analysis

- of a Hybrid Neural Network and Pattern Recognition Technique for Predicting Short-Term Increases in the NYSE Composite Index," *Omega*, Vol. 30, pp. 69–76, 2002.
14. Tseng, F.M., Yu, H.C., and Tzeng, G.H., "Combining Neural Network Model with Seasonal Time Series ARIMA Model, *Technological Forecasting & Social Change*, Vol. 69, pp. 71–87, 2002.
۱۵. بیجاری، م.، خاشعی، م و صالحی، ع.، "پیش‌بینی و تحلیل قیمت جهانی فولاد خام با به‌کارگیری مدل ترکیبی میانگین متحرک خودرگرسیون انباشته و شبکه‌های عصبی مصنوعی"، مجموعه مقالات سمپوزیوم فولاد ۸۴، ص ۱۰۰۵–۹۹۲، اسفند ۱۳۸۴.
۱۶. خاشعی، م.، به‌کارگیری شبکه‌های عصبی رگرسیون عمومی (GRNN) به‌منظور پیش‌بینی، فصلنامه بهبود، دانشکده صنایع و سیستم‌ها، دانشگاه صنعتی اصفهان، شماره ۲۲، ص ۴۵–۴۲، بهار ۱۳۸۵.
17. Zhang, G., Patuwo, B.E., and Hu, M.Y., "Forecasting with Artificial Neural Networks: The State of the Art," *International Journal of Forecasting*, Vol. 14, pp. 35–62, 1998.
18. Khashei, M., Bijari, M., and Raissi, G.H. A., "Improvement of Auto-Regressive Integrated Moving Average Models Using Fuzzy Logic and Artificial Neural Networks (ANNs)," *Neurocomputing*, Vol. 72, pp. 956–967, 2009.
19. Specht, D., "Probabilistic Neural Networks," *Neural Networks*, Vol. 3, pp. 109–118, 1990.
20. Masters, T., "Advanced Algorithms for Neural Networks," Wiley, New York, 1995.
21. Hajmeer, M., and Basheer, I., Comparison of logistic Regression and Neural Network-based Classifiers for Bacterial Growth," *Food Microbiology*, Vol. 20, pp. 43–55, 2003.
22. Hajmeer, M., and Basheer, I., "A Probabilistic Neural Network Approach for Modeling and Classification of Bacterial Growth/no-Growth Data," *Journal of Microbiological Methods*, Vol. 51, pp. 217–226, 2002.
23. Parzen, E., "On Estimation of a Probability Density Function and Mode," *Annals of Mathematical Statistics*, Vol. 36, pp. 1065–1076, 1962.
24. Wasserman, P., *Advanced Methods in Neural Computing*, New York: Van Nostrand Reinhold, 1993.
25. Tsai, C., "On Detecting Nonlinear Patterns in Discriminant Problems," *Information Sciences*, Vol. 176, pp. 772–798, 2006.
26. Cacoullos, T., "Estimation of Multivariate Density," *Annals of the Institute of Statistical Mathematics*, Vol. 18, pp. 179–189, 1966.
27. Ge, S.S., Yang, Y., and Lee, T.H., "Hand Gesture Recognition and Tracking Based on Distributed Locally Linear Embedding," *Image and Vision Computing*, Vol. 26, pp. 1607–1620, 2008.
28. Chen, A., Leung, M., and Daouk, H., "Application of Neural Networks to an Emerging Financial Market: Forecasting and Trading the Taiwan Stock Index," *Computers & Operations Research*, Vol. 30, pp. 901–923, 2003.
29. Xue, X.Y., Zhang, M.C., Liu, Z.D., Hu, B.T., and Fan, C.X., "Study of Probabilistic Neural Networks to Classify the Active Compounds in Medicinal Plants," *Journal of Pharmaceutical and Biomedical Analysis*, Vol. 38, pp. 497–507, 2005.
30. Khashei, M., and Bijari, M., A New Hybrid Methodology for Nonlinear Time Series Forecasting, Modelling and Simulation in Engineering, Article ID 379121, 2011.
31. Yuan, S., and Chu, F., "Support Vector Machines-Based Fault Diagnosis for Turbo-Pump Rotor," *Mechanical Systems and Signal Processing*, Vol. 20, pp. 939–952, 2006.