

## بهبود عملکرد پیش‌بینی‌های مالی با ترکیب مدل‌های خطی و غیرخطی خودرگرسیون میانگین متحرک انباشته و شبکه‌های عصبی مصنوعی

مهدی خاشعی<sup>۱</sup>  
دکتر مهدی بیجاری<sup>۲</sup>

تاریخ دریافت: ۸۵/۴/۱۴ تاریخ پذیرش: ۸۶/۱۰/۲۳

### چکیده

دقت پیش‌بینی از مهمترین عوامل مؤثر در انتخاب روش پیش‌بینی است. امروزه به‌رغم وجود روش‌های متعدد پیش‌بینی، هنوز پیش‌بینی دقیق مالی کار چندان ساده‌ای نیست و اکثر محققان درصدد به‌کارگیری ترکیب روش‌های متفاوت به منظور حصول نتایج دقیق‌تر می‌باشند. در حالت کلی، انتخاب مؤثرترین روش به منظور پیش‌بینی، کار بسیار دشواری است و بسیاری از محققان، روش‌های خطی و غیرخطی را به منظور حصول نتایج دقیق‌تر با یکدیگر ترکیب کرده‌اند؛ چرا که: اولاً در عمل تعیین خطی و غیرخطی بودن یک سری زمانی، کار دشواری است. ثانیاً سری‌های زمانی دنیای واقع، به‌ندرت کاملاً خطی و یا غیرخطی هستند. مدل‌های خودرگرسیون میانگین متحرک انباشته (ARIMA) و شبکه‌های عصبی مصنوعی (ANNs) به ترتیب از جمله دقیق‌ترین مدل‌های خطی و غیرخطی در پیش‌بینی سری‌های زمانی می‌باشند.

در این مقاله به منظور بهره‌گیری از مزایای منحصر به فرد هر یک از روش‌های مدل‌سازی خطی و غیرخطی و حصول نتایج دقیق‌تر، روش ترکیبی مدل‌های خودرگرسیون میانگین متحرک انباشته و شبکه‌های عصبی مصنوعی به منظور پیش‌بینی‌های مالی پیشنهاد شده‌اند. مقایسه نتایج حاصله بیانگر آنست که مدل تلفیقی نسبت به مدل‌های اریما (ARIMA) و شبکه‌های پرسپترون چندلایه (MLP) نتایج دقیق‌تری در پیش‌بینی نرخ ارز (یورو در مقابل ریال) ارائه نموده است.

طبقه بندی JEL : C53

**واژگان کلیدی:** مدل‌های خودرگرسیون میانگین متحرک انباشته (ARIMA)، شبکه‌های عصبی مصنوعی (ANNs)، مدل‌های ترکیبی، بازارهای مالی، پیش‌بینی نرخ ارز.

۱- کارشناس ارشد مهندسی سیستم‌های اقتصادی - اجتماعی  
۲- استادیار دانشکده مهندسی صنایع، دانشگاه صنعتی اصفهان

## ۱- مقدمه

به‌کارگیری روش‌های کمی به منظور پیش‌بینی بازارهای مالی، بهبود تصمیم‌گیری‌ها و سرمایه‌گذاری‌ها به ضرورتی انکارناپذیر در دنیای امروز تبدیل شده است. نرخ ارز یکی از مهمترین متغیرهای مؤثر در سیستم‌های مالی بوده و پیش‌بینی آن می‌تواند باعث بهبود قابل توجهی در عملکرد این‌گونه از سیستم‌ها گردد. تحقیقات بسیاری در زمینه پیش‌بینی نرخ ارز انجام شده است (خاشعی، ۱۳۸۵، Balkin, 2001) که تعداد انتشارات، بیانگر اهمیت مسأله مذکور می‌باشد. اینس از یک مدل دومرحله‌ای ترکیبی به منظور پیش‌بینی نرخ ارز استفاده نموده (Ince, 2005). و در این مقاله با ترکیب مدل‌های پارامتریک و غیر پارامتریک، روشی به منظور پیش‌بینی ارائه داده است. چنانچه در تحقیقی مشابه از یک روش ترکیبی به منظور پیش‌بینی در بازارهای مالی و پیش‌بینی و تعیین روند تغییرات نرخ ارز استفاده نموده است (Chen, 2004).

امروزه به‌رغم وجود روش‌های کمی متعدد جهت پیش‌بینی‌های مالی، هنوز پیش‌بینی دقیق نرخ ارز کار چندان ساده‌ای نیست و اکثر محققان درصدد به‌کارگیری و مقایسه روش‌های متفاوت به منظور حصول نتایج دقیق‌تر می‌باشند (chen, 2003). مید دقت مدل‌های کوتاه مدت خطی و غیرخطی پیش‌بینی را به منظور پیش‌بینی نرخ ارز بایکدیگر مقایسه نموده است (Meade, 2002). بالابان نیز عملکرد چهار روش متفاوت پیش‌بینی را به منظور پیش‌بینی نرخ ارز بایکدیگر مقایسه نموده است (Balaban, 2004). از سایر اقدامات انجام شده در این زمینه می‌توان به مقالات شین (Shin, 2000) و وانگ (wang, 2005) اشاره نمود.

پیش‌بینی سری‌های زمانی یکی از مهمترین زمینه‌های پیش‌بینی است که در آن مشاهدات گذشته یک متغیر جمع‌آوری و به منظور به‌دست آوردن روابط اساسی بین مشاهدات و تعیین یک مدل توصیفی، تجزیه و تحلیل می‌شود و سپس مدل حاصله به منظور 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. تلاش‌های زیادی در چند دهه اخیر به منظور توسعه و بهبود مدل‌های پیش‌بینی سری‌های زمانی انجام شده است. یکی از مهمترین و پرکاربردترین مدل‌های سری زمانی، مدل‌های اریما (ARIMA)<sup>۱</sup> می‌باشند. عمومیت این‌گونه مدل‌ها به دلیل خواص

---

1. Auto Regressive Integrated Moving Average

آماریشان و همچنین متدولوژی معروف باکس- جنکینز در فرایند مدل‌سازی این‌گونه از مدلها می‌باشد (Box & Jenkins, 1970). علاوه بر این مدل‌های هموارسازی نمایی متعددی می‌توانند توسط مدل‌های اریما به‌کار گرفته شوند.

این‌گونه مدلها همچنین کاملاً انعطاف‌پذیرند، چراکه می‌توانند مدل‌های بسیار متفاوتی از سری‌های زمانی همچون سری‌های اتورگرسیو (AR)<sup>۱</sup>، میانگین متحرک (MA)<sup>۲</sup> و ترکیب هر دو آنها (ARMA)<sup>۳</sup> را تشریح نمایند. مهمترین محدودیت این‌گونه مدلها پیش‌فرض خطی بودن آنها می‌باشد، یعنی در این‌گونه از مدلها فرض می‌شود بین مقادیر سری زمانی یک ساختار همبسته خطی وجود داشته باشد. لذا، الگوهای غیرخطی نمی‌توانند توسط مدل اریما محاسبه گردند، و به همین دلیل است که تخمین مدل‌های خطی، برای مسائل پیچیده دنیای واقعی که اغلب مدل‌های غیرخطی می‌باشند، همیشه رضایت‌بخش نخواهد بود.

اخیراً شبکه‌های عصبی مصنوعی (ANNs)<sup>۴</sup> به‌طور گسترده‌ای مورد مطالعه قرار گرفته و در پیش‌بینی سری‌های زمانی به‌کار گرفته شده‌اند. به‌طور مثال، زانگ در مقاله‌ای این‌گونه مدلها را به‌طور کامل مرور کرده است (Zhang, 1998). مزیت اصلی شبکه‌های عصبی، قابلیت مدل‌سازی غیرخطی انعطاف‌پذیرشان می‌باشد. در شبکه‌های عصبی مصنوعی، دیگر نیازی به تشخیص شکل خاص مدل نبوده و مدل براساس اطلاعات موجود در داده‌ها شکل می‌گیرد (Zhang, 2004). این رویکرد مبتنی بر داده برای بسیاری از مجموعه داده‌های تجربی بالاخص زمانی که هیچ اطلاعات تئوریک برای پیشنهاد یک فرایند تولید، داده مناسب در دسترس نباشد، بسیار مناسب است. حال با توجه به محدودیت‌های موجود در هر یک از روشهای فوق‌الذکر، در این مقاله به منظور پیش‌بینی، از یک رویکرد ترکیبی اریما و شبکه‌های عصبی مصنوعی استفاده شده است. مزایای استفاده از این روش ترکیبی را می‌توان به‌صورت زیر خلاصه نمود:

۱- معمولاً در عمل تعیین خطی یا غیرخطی بودن سری زمانی تحت مطالعه، همچنین تعیین اینکه آیا مدل خاص مؤثرتری در پیش‌بینی خارج از نمونه وجود دارد یا نه، کار بسیار مشکلی است. بنابراین، برای پیش‌بینی‌کنندگان انتخاب تکنیک مناسب در موقعیتهای خاص بسیار دشوار خواهد بود. لذا به علت عوامل تأثیرگذار بالقوه فراوانی همچون تغییرات نمونه‌گیری، عدم قطعیت مدل و تغییرساختار، با ترکیب مدل‌های متفاوت، مساله انتخاب مدل می‌تواند آسانتر گردد.

۲- پدیده‌های واقعی در دنیای واقع، اغلب غیرخطی بوده و به‌دلیل صعوبت برخورد با مسائل غیرخطی، سعی بر خطی‌سازی آنها به منظور مدل‌سازی می‌باشد. به همین دلیل، در حالت کلی، هیچ

1. Auto Regressive  
2. Moving Average  
3. Auto Regressive Moving Average  
4. Artificial Neural Networks

یک از مدل‌های اریما و شبکه‌های عصبی مصنوعی نمی‌توانند به منظور مدل‌سازی و پیش‌بینی سری‌های زمانی مناسب باشند، چراکه مدل‌های اریما نمی‌توانند برای مسائل غیرخطی استفاده شوند؛ در حالی که مدل‌های شبکه‌های عصبی نیز در مدل‌سازی الگوهای کاملاً خطی نتایج مطلوبی ارائه نمی‌نمایند. از این‌رو با ترکیب مدل‌های شبکه‌های عصبی مصنوعی با اریما می‌توان ساختارهای خودرگرسیون پیچیده در داده‌ها را به‌طور دقیق‌تری مدل‌سازی نمود.

۳- در ادبیات موضوع پیش‌بینی، هیچ اجماع کلی بر روش واحدی که در هر موقعیتی بهترین روش ممکن باشد وجود ندارد و این بدان دلیل است که مسائل دنیای واقعی ذاتاً پیچیده هستند و هیچ مدلی به تنهایی نمی‌تواند الگوهای گوناگون موجود را با دقت یکسان مدل‌سازی نماید. (Al-Saba, 1999, Elkateb, 1998, Hwang, 2001, Zhang, 2001 & Hwang, 2001)

بسیاری از مطالعات تجربی نیز که شامل چندین روش پیش‌بینی بوده‌اند، پیشنهاد کرده‌اند که با ترکیب چند مدل متفاوت، دقت پیش‌بینی را می‌توان نسبت به مدل‌های تکی بهبود داد، بدون آنکه نیاز به پیداکردن بهترین یا واقعی‌ترین مدل باشد (Makri dakis, 1993). بنابراین ترکیب مدل‌های مختلف می‌تواند شانس پوشش الگوهای متفاوت در داده‌ها را افزایش داده و عملکرد پیش‌بینی را بهبود بخشد. چندین مطالعه تجربی تاکنون پیشنهاد کرده‌اند که با ترکیب مدل‌های متفاوت با یکدیگر می‌توان دقت پیش‌بینی را نسبت به مدل‌های تکی بهبود بخشید؛ علاوه بر این مدل‌های ترکیبی در هنگام تغییر ساختار در داده‌ها قویتر هستند، لذا استفاده از مدل‌های ترکیبی یا ترکیب چندین مدل معمولاً برای بهبود دقت پیش‌بینی مناسب می‌باشند. اخیراً در این زمینه مطالعات فراوانی انجام گرفته است که از آن جمله می‌توان به موارد زیر اشاره کرد.

کلمن یک مرور کلی در این زمینه انجام داده است (Clemen, 1989). یافته‌های تجربی و نظری نشان می‌دهند که ترکیب مدل‌های متفاوت یک راه مؤثر و کارا برای بهبود دقت پیش‌بینی‌ها می‌باشد (Palm, 1992). در تحقیقات مربوط به پیش‌بینی با شبکه‌های عصبی نیز چندین مدل ترکیبی ارائه شده است. ودینگ و سیوس یک روش ترکیبی با استفاده از شبکه‌های عصبی پایه شعاعی و مدل‌های باکس-جنکینز ارائه داده‌اند (wedding & cios, 1996). لوکس هوج یک رویکرد ترکیبی شبکه‌های عصبی مصنوعی و روش‌های اقتصادسنجی برای پیش‌بینی فروش پیشنهاد کرده است (Luxhoj, 1996). همچنین پلیکان و همکارانش (plikan et al., 1992) و گینزنبورگ و هورن ترکیب چند شبکه عصبی پیشرو جهت بهبود دقت پیش‌بینی سری‌های زمانی را پیشنهاد داده‌اند (Ginzenburg & Horn, 1994).

در ادامه و در بخش بعد روشهای مدل سازی اریما و شبکه های عصبی مصنوعی جهت پیش بینی سریهای زمانی شرح داده شده اند. مدل ترکیبی در بخش سوم معرفی گردیده و نتایج مربوط به به کارگیری مدل ترکیبی برای پیش بینی در بخش چهارم و در نهایت نیز نتیجه گیری ارائه شده است.

## ۲- مدل های پیش بینی سریهای زمانی

چندین روش متفاوت به منظور مدل سازی سریهای زمانی وجود دارد. مدل های آماری شامل میانگین متحرک، هموارسازی نمایی و اریما خطی می باشند که در آنها پیش بینی مقادیر آینده به این موضوع محدود شده است که مقادیر آینده توابع خطی از مشاهدات گذشته باشند. این گونه روشها به دلیل سادگی نسبی در فهم و به کارگیری، در تحقیقات چند دهه اخیر بسیار مورد توجه بوده اند. برای غلبه بر محدودیت خطی بودن مدل و به حساب آوردن الگوهای غیرخطی مشخص در مسائل واقعی، چندین نوع مختلف از مدل های غیرخطی در ادبیات موضوع پیشنهاد شده است که از جمله مهمترین آنها می توان به اتورگرسیو شرطی (ARCH)<sup>۱</sup>، دوخطی<sup>۲</sup> و اتورگرسیو آستانه ای (TAR)<sup>۳</sup> اشاره نمود (خاشعی، ۱۳۸۴).

هر چند مدل های غیرخطی مذکور بهبودهایی در مسائل پیش بینی ایجاد نموده اند، اما به کارگیری آنها در حالت کلی محدود می باشد چراکه این گونه مدلها تنها برای الگوهای غیرخطی خاصی طراحی شده اند (Zhang, 2004) و قادر به مدل سازی انواع دیگر سریهای زمانی غیرخطی نمی باشند. اخیراً شبکه های عصبی مصنوعی به عنوان یک جایگزین مناسب جهت مدل سازی سریهای زمانی پیشنهاد شده اند. نقطه قوت اصلی شبکه های عصبی مصنوعی قابلیت مدلسازی غیرخطی انعطاف پذیر آنهاست. در ادامه این بخش به تشریح اصول اساسی فرایند مدل سازی توسط مدل های شبکه های عصبی مصنوعی و اریما پرداخته خواهد شد.

## ۲-۱- مدل خودرگرسیون میانگین متحرک انباشته (ARIMA)

آر مدل خودرگرسیون میانگین متحرک انباشته (ARIMA) مقادیر آینده متغیر به عنوان تابعی خطی، از مشاهدات گذشته و خطاهای تصادفی فرض می شوند، یعنی اینکه فرایند اساسی که سری زمانی را تولید می نماید بدین صورت می باشد:

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

به طوری که در آن  $\varepsilon_t, y_t$  به ترتیب مقادیر واقعی و خطاهای تصادفی در دوره  $t$  و  $\phi_i$  ( $i = 1, 2, \dots, p$ ) و  $\theta_j$  ( $j = 1, 2, \dots, q$ ) پارامترهای مدل و  $p$  و  $q$  اعداد صحیح و بیانگر

1. Auto Regressive Conditional Heteroscedastic  
2. Bilinear  
3. Threshold Auto Regressive

مرتبه مدل می‌باشند. خطای تصادفی  $\varepsilon_t$  نیز مستقل و دارای توزیع یکنواخت با میانگین صفر و واریانس ثابت  $\sigma^2$  فرض می‌شود. معادله (۱) چندین حالت خاص از خانواده مدل‌های اریما را شامل می‌گردد، اگر  $q=0$  باشد معادله (۱)، یک معادله اتورگرسیو از درجه  $p$  می‌باشد و وقتی  $p=0$  باشد مدل به یک مدل میانگین متحرک از درجه  $q$  تبدیل می‌شود.

یکی از مراحل اصلی مدل‌سازی اریما تعیین صحیح مرتبه مدل می‌باشد  $(p,q)$ . بر اساس کارهای انجام شده قبلی، یک روش عملی برای ساختن این‌گونه مدل‌ها به وجود آمده است که در تحلیل سریهای زمانی و کاربردهای مربوط به پیش‌بینی تأثیر بنیادی داشته است. متدولوژی باکس-جنکینز شامل سه مرحله تکراری، شناسایی مدل، تخمین پارامترها و کنترل تشخیصی می‌باشد. ایده اصلی شناسایی مدل نیز بر این اصل استوار است که اگر یک سری زمانی از یک فرایند اریما تولید شده باشد، باید برخی خواص خود همبستگی تئوریک را داشته باشد، لذا با تطبیق الگوهای خودهمبسته تجربی با الگوهای خودهمبسته تئوریک، غالباً شناسایی یک یا چند مدل بالقوه برای سریهای زمانی امکان‌پذیر خواهد بود. پیشنهاد باکس-جنکینز استفاده از تابع خودهمبستگی (ACF)<sup>۱</sup> و خودهمبستگی جزئی (PACF)<sup>۲</sup> داده‌های نمونه به عنوان ابزار پایه برای شناسایی مرتبه مدل اریما می‌باشد (Box & Jenkins, 1970). وقتی یک مدل آزمایشی شناسایی شد تخمین پارامترهای مدل کار ساده‌ای بوده و از طریق مینیمم‌سازی نرم خطا به دست می‌آید که بدین منظور می‌توان از روند بهینه‌سازی خطی استفاده نمود. آخرین گام مدل‌سازی کنترل تشخیصی مناسب بودن مدل است و اساساً به منظور آزمایش نمودن اینکه فرضیات مدل در مورد خطاها صدق می‌کند یا نه استفاده می‌شود.

جهت آزمایش خوبی برازش مدل آزمایشی پذیرفته شده، چندین آماره و نمودار تشخیصی از باقیمانده‌ها می‌توانند مورد استفاده قرار گیرند. اگر مدل انتخابی مناسب نباشد یک مدل آزمایشی جدید باید تشخیص داده شود و موارد فوق‌الذکر مجدداً تکرار گردد. این فرایند مدل‌سازی سه مرحله‌ای نوعاً چندین بار تکرار می‌گردد تا یک مدل رضایت‌بخش در انتها مشخص گردد. از مدل انتخاب شده نهایی می‌توان به منظور پیش‌بینی استفاده نمود.

## ۲-۲- روش شبکه‌های عصبی مصنوعی (ANNs) در مدل‌سازی سریهای زمانی


وقتی که محدودیت خطی بودن مدل برطرف نگردد، تعداد ساختارهای غیرخطی ممکن که می‌تواند برای تشریح و پیش‌بینی سریهای زمانی مورد استفاده قرار گیرند بسیار زیاد خواهد بود. یک مدل غیرخطی خوب باید به اندازه کافی کلی باشد تا بتواند پدیده‌های غیرخطی در داده‌ها را تشخیص دهد.

1. Autocorrelation Function  
2. Partial Autocorrelation Function

شبکه‌های عصبی مصنوعی یکی از این گونه مدلها می‌باشند که قادر به تخمین موارد غیرخطی متعدد در داده‌ها بوده و یک چارچوب محاسبه‌ای انعطاف‌پذیر برای دامنه وسیعی از مسائل غیرخطی می‌باشند (Zhang, 2004).

یکی از مزیت‌های بارز این گونه مدلها نسبت به مدل‌های دیگر غیرخطی، این است که شبکه‌های عصبی مصنوعی، یک تقریب‌زننده جهانی<sup>۱</sup> هستند که می‌توانند هر نوع تابعی را با دقت دلخواه تقریب بزنند. این گونه از شبکه‌ها نیاز به هیچ‌گونه پیش فرضی در مورد شکل مدل در فرایند مدلسازی نداشته و به‌طور کلی یک مدل مبتنی بر داده می‌باشند. شبکه عصبی پیشخور با یک لایه مخفی یکی از پرکاربردترین مدل‌های شبکه‌های عصبی به منظور پیش‌بینی سری‌های زمانی می‌باشند (Zhang, 2005). این گونه مدلها از سه لایه پردازش ساده اطلاعات متصل به هم تشکیل شده‌اند (شکل (۱)).

شکل (۱): ساختار شبکه‌های عصبی چندلایه پیشخور با یک لایه مخفی



مأخذ: یافته‌های تحقیق

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

$$y_t = \alpha_0 + \sum_{j=1}^q \alpha_j \cdot g \left[ \beta_{0,j} + \sum_{i=1}^p \beta_{i,j} \cdot y_{t-i} \right] + \varepsilon_t \quad (2)$$

به طوری که پارامترهای مدل بوده که غالباً وزنهای اتصالی نامیده می‌شوند،  $p$  تعداد گره‌های ورودی و  $q$  تعداد گره‌های مخفی می‌باشند. تابع سیگموئیدی اغلب به عنوان تابع فعال‌سازی لایه مخفی مورد استفاده قرار می‌گیرد.

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

از این رو مدل شبکه‌های عصبی مصنوعی رابطه (۲) در حقیقت به عنوان یک نگاشت غیرخطی از مشاهدات گذشته به مقدار آینده خواهد بود؛ یعنی:

$$y_t = f(y_{t-1}, \dots, y_{t-p}, w) + \varepsilon_t \quad (۴)$$

به طوری که  $w$  بردار همه پارامترها و  $f$  تابعی است که توسط ساختار شبکه عصبی و وزنهای اتصالی تعیین می‌گردد. از این رو شبکه‌های عصبی معادل مدل اتورگرسیو غیرخطی هستند. همچنین رابطه (۲) بیانگر این موضوع است که یک نرون (خروجی) در لایه خروجی برای پیش‌بینی یک مرحله‌ای مورد استفاده قرار می‌گیرد.

مدل ساده بیان شده توسط رابطه (۲) دارای قدرت تقریب بسیار زیادی می‌باشد، چرا که قادر است هر تابع دلخواه را به شرط آنکه تعداد گره‌های مخفی ( $q$ ) به اندازه کافی بزرگ باشد را تقریب بزند. در عمل ساختار شبکه عصبی ساده که تعداد نرون کمتری در لایه مخفی دارد غالباً در پیش‌بینی‌های خارج از نمونه بهتر عمل می‌کند و این به دلیل دوری جستن از مساله برازش بیش از حد است که عمدتاً در فرایند مدلسازی شبکه‌های عصبی رخ می‌دهد (Zhang, 2005).

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 (Demuth, 2004). انتخاب تعداد نرون‌های لایه مخفی وابسته به داده‌ها بوده و هیچ قانونی به منظور تعیین این پارامتر در طراحی شبکه‌های عصبی وجود ندارد. علاوه بر این، مرحله مهم دیگر مدلسازی شبکه‌های عصبی، تشخیص ساختارهای خودهمبسته غیرخطی موجود در مشاهدات به عنوان بردار ورودی شبکه می‌باشد که شاید مهمترین پارامتر در طراحی مدل‌های شبکه‌های عصبی مصنوعی باشد، چرا که این پارامتر در تعیین ساختار خودهمبسته غیرخطی سریهای زمانی نقش اساسی دارند. هیچ تئوری خاصی جهت انتخاب  $p$  وجود ندارد و از این رو تجربه و آزمایشات، مشخص‌کننده مقدار مناسب  $p$  و  $q$  خواهند بود. وقتی در یک ساختار شبکه‌ای  $p$  و  $q$  مشخص گردید، شبکه آماده آموزش فرایند تخمین پارامترهاست. همانند مدلسازی اریما پارامترها طوری تخمین زده می‌شوند که معیار دقت مانند



میانگین مربعات خطاها حداقل گردد. این فرایند توسط الگوریتم‌های بهینه‌سازی غیرخطی همچون پس انتشار خطا (BP)<sup>۱</sup> انجام می‌شود.

مدل برآورد شده معمولاً توسط یک نمونه جداگانه که در فرایند آموزش از آن استفاده نشده، مورد ارزیابی قرار می‌گیرد و این با فرایند مدل‌سازی اریما که از یک نمونه به منظور شناسایی، تخمین و ارزیابی مدل استفاده می‌کند، متفاوت است. دلیل این موضوع نیز شکل کلی مدل (خطی) برای مدل‌سازی اریما می‌باشد که از قبل مشخص شده است (Fildes, 1995)، در صورتی که در مدل‌سازی شبکه‌های عصبی این طور نیست. در مدل‌سازی با شبکه‌های عصبی مصنوعی مدل غیرخطی همانند مرتبه مدل باید تخمین زده شود و ممکن است شبکه دچار برازش بیش از حد شود. تشابهاتی نیز بین این دو روش وجود دارد که از آن جمله می‌توان به موارد ذیل اشاره نمود:

- ۱- هر دو این مدل‌ها شامل دسته‌ای از مدل‌های متفاوت با مرتبه‌های متفاوت می‌باشد.
- ۲- تبدیل داده غالباً برای به دست آوردن نتایج بهتر مورد استفاده قرار می‌گیرند.
- ۳- به منظور ساختن یک مدل موفق، یک نمونه نسبتاً بزرگ از داده‌ها مورد نیاز است.
- ۴- طبیعت آزمایشی، تکراری بودن و دخالت قضاوت‌های ذهنی در هر دو فرایند مدل‌سازی وجود دارد.

### ۳- روش ترکیبی

هر دو مدل اریما و شبکه‌های عصبی مصنوعی در دامنه‌های خطی و غیرخطی خودشان مدل‌های موفقی می‌باشند، هر چند هیچ‌کدام از آنها یک مدل کلی که برای همه موارد مناسب باشد، نیستند. تخمین مدل‌های اریما ممکن است برای مسائل غیرخطی پیچیده مناسب نباشد. از طرف دیگر، به کارگیری شبکه‌های عصبی مصنوعی برای مدل‌سازی مسائل خطی نتایج متفاوتی داشته است. به عنوان مثال با به کارگیری داده‌های شبیه سازی شده دنتون می‌توان نشان داد که وقتی همخطی چندگانه یا داده‌های پرت در داده‌ها وجود داشته باشد (Denton, 1995)، شبکه‌های عصبی می‌توانند به طور بارزی از مدل‌های رگرسیون خطی عملکرد بهتری داشته باشند.

مارک‌هام و مارکس نیز دریافته‌اند که عملکرد شبکه‌های عصبی مصنوعی برای مسائل رگرسیون خطی به اندازه نمونه و سطح خطا بستگی دارد (Markham, 1998). از این رو، مناسب نیست که شبکه‌های عصبی مصنوعی را برای هر داده‌ای به کارگیریم چراکه شناسایی خصوصیات داده‌ها به طور کامل در مشاهدات دنیای واقعی مشکل است. روش ترکیبی که قابلیت مدل‌سازی هر دوی مدل‌های

1. Back Propagation

خطی و غیرخطی را دارد، می‌تواند یک استراتژی مناسب برای استفاده‌های عملی باشد. با ترکیب مدل‌های مختلف، جنبه‌های مختلف الگوهای زیربنایی داده‌ها ممکن است به‌طور کاملتری به‌دست آید و شاید معقول باشد که یک سری زمانی به‌صورت ترکیب یک ساختار خودهمبسته خطی و یک جزء غیرخطی در نظر گرفته شود، یعنی:

$$y_t = N_t + L_t \quad (5)$$

به‌طوری که  $L_t$  جزء خطی و  $N_t$  جزء غیرخطی می‌باشد که باید توسط داده‌ها تخمین زده شوند. بدین منظور ابتدا با به‌کارگیری مدل اریما جزء خطی مدل، مدل‌سازی می‌گردد، لذا باقیمانده‌های مدل خطی فقط شامل روابط غیرخطی خواهند بود. حال اگر  $e_t$  باقیمانده مدل خطی در زمان  $t$  باشد لذا خواهیم داشت:

$$e_t = y_t - \hat{L}_t \quad (6)$$

به‌طوری که  $\hat{L}_t$  مقادیر پیش‌بینی شده‌ای هستند که توسط رابطه (۲) و در زمان  $t$  تخمین زده شده‌اند. باقیمانده‌ها در تشخیص مناسب بودن مدل‌های خطی بسیار مهم می‌باشند چرا که اگر یک مدل خطی هنوز ساختارهای همبسته خطی در باقیمانده‌های خود داشته باشد کامل نخواهد بود. در حالت کلی تحلیل باقیمانده‌ها نمی‌تواند هر مدل غیرخطی در داده‌ها را تشخیص دهد و در حقیقت، فعلاً هیچ آماره تشخیص‌دهنده کلی برای روابط خودهمبسته غیرخطی وجود ندارد (Zhang, 2004). بنابراین حتی اگر یک مدل مرحله کنترل تشخیصی را پشت سر گذاشته باشد، هنوز ممکن است که در آن روابط غیرخطی به‌طور مناسب، مدل نشده باشند.

الگوهای غیرخطی مشخص در باقیمانده‌ها نشانگر محدودیت‌های موجود در روش مدل‌سازی اریما می‌باشند. حال با مدل‌سازی باقیمانده‌ها توسط شبکه‌های عصبی مصنوعی می‌توان روابط غیرخطی موجود در باقیمانده‌ها را کشف کرد. با فرض  $n$  گره ورودی، مدل شبکه‌های عصبی مصنوعی برای باقیمانده‌ها به‌صورت زیر خواهد بود:

$$e_t = f(e_{t-1}, \dots, e_{t-n}) + \varepsilon_t \quad (7)$$

به طوری که  $f$  یک تابع غیرخطی مشخص شده توسط شبکه عصبی و  $e_t$  خطای تصادفی است. قابل توجه است که اگر مدل  $f$  مناسب نباشد جمله خطا ( $\varepsilon_t$ ) به اندازه کافی تصادفی نمی باشد. بنابراین، تشخیص صحیح مدل مساله‌ای بحرانی است. توجه کنید که با تخمین  $N_t$  از معادله شماره (۷)، پیش‌بینی ترکیبی به صورت زیر خواهد بود:

$$\hat{y}_t = \hat{L}_t + \hat{N}_t \quad (8)$$

به طور کلی روش ترکیبی را در دو گام زیر می‌توان خلاصه کرد:

در گام اول یک مدل اریما برای آنالیز جزء خطی مساله و در گام دوم یک مدل شبکه عصبی برای مدل کردن باقیمانده‌های حاصل از مدل اریما به کار گرفته می‌شود. از آنجا که مدل اریما نمی‌تواند ساختارهای غیرخطی داده‌ها را محاسبه کند، لذا باقیمانده‌های مدل خطی شامل اطلاعاتی غیرخطی خواهند بود.

نتایج شبکه‌های عصبی می‌تواند به صورت پیش‌بینی جمله‌های خطای مدل اریما در مدل ترکیبی استفاده شود. مدل ترکیبی از نقاط قوت منحصر به فرد مدل اریما و شبکه‌های عصبی مصنوعی در تعیین الگوهای متفاوت بهره‌مند می‌باشد، از این رو این مدل می‌تواند شامل مزیت‌های مدل سازی الگوهای خطی و غیرخطی به طور جداگانه با استفاده از مدل‌های متفاوت باشد و از ترکیب پیش‌بینی‌ها برای بهبود عملکرد پیش‌بینی در مدل سازی استفاده کند.

مدل‌های ترکیبی متعددی تاکنون ارائه شده است که بیشتر آنها با ترکیب مدل‌های مشابه طراحی شده‌اند (Pelikan, 1992). مدل‌های خطی برای پیش‌بینی‌های سنتی با یکدیگر ترکیب شده و در پیش‌بینی‌های اخیر نیز از ترکیب چندین مدل شبکه عصبی به منظور پیش‌بینی استفاده شده است (Ginzburg & Horn, 1994). اگر چه این نوع ترکیبات دقت پیش‌بینی‌ها را بهبود بخشیده است اما به نظر می‌رسد که ترکیب مدل‌های متفاوت راه مؤثرتری به منظور افزایش دقت پیش‌بینی‌ها باشد.

شواهد تجربی و تئوریک موجود در ادبیات موضوع نیز بیانگر آن است که استفاده از مدل‌های غیرمشابه یا مدلهایی که تفاوت بسیاری با یکدیگر دارند به منظور تشکیل مدل ترکیبی و به دست آوردن واریانس و خطای کمتر، مناسبتر می‌باشند. علاوه بر آن به دلیل وجود الگوهای متغیر و ناپایدار در داده‌ها، استفاده از مدل ترکیبی می‌تواند عدم اطمینان مدل را که نوعاً در استنباط آماری و پیش‌بینی سری زمانی رخ می‌نماید، را کاهش دهد. همچنین با برازش اولیه داده‌ها توسط مدل اریما می‌توان احتمال بروز مساله برازش بیش از حد را که در پیش‌بینی با شبکه‌های عصبی مشکلی عمده می‌باشد، کاهش داد.


#### ۴- فرموله کردن مساله

با توجه به مطالب بیان شده، در این بخش نرخ ارز (یورو در مقابل ریال) با استفاده از روش ترکیبی پیش‌بینی شده و نتایج حاصله با هر یک از روش‌های اریما و شبکه‌های عصبی مصنوعی از جهت دقت پیش‌بینی مقایسه شده است.

#### ۴-۱- 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<sup>۱</sup> بوده و جمعاً شامل ۱۲۰ داده می‌باشد. نمودار مربوط به نرخ ارز (یورو در مقابل ریال) بر اساس زمان در شکل (۲) آورده شده است.

شکل (۲): نرخ ارز مربوط به ۱۳ بهمن ماه ۱۳۸۴ تا ۱۸ خرداد ماه ۱۳۸۵



مأخذ: بانک مرکزی جمهوری اسلامی ایران

#### ۴-۲- نتایج حاصله:

در این قسمت نتایج سه مدل اریما، شبکه‌های عصبی مصنوعی و مدل ترکیبی آورده شده است. در این مطالعه تمامی مدل‌سازی‌های اریما توسط نرم‌افزار Eviews و مدل‌سازی‌های شبکه‌های عصبی توسط نرم‌افزار MATLAB7 انجام شده است. دو معیار میانگین مربعات خطا (MSE)<sup>۲</sup> و میانگین قدرمطلق خطا (MAE)<sup>۳</sup> به عنوان معیار سنجش عملکرد و تصمیم‌گیری در نظر گرفته شده‌اند (خاشعی، ۱۳۸۴). در این مقاله همچنین از سایر معیارهای متداول در سنجش عملکرد شبکه‌های عصبی همچون معیار اطلاعات آکائیک (AIC)<sup>۴</sup>، معیار اطلاعات بیزین (BIC)<sup>۵</sup>، معیار هانان-کوین (HQC)<sup>۶</sup>، مجموع مربعات

1. 2.Feb.2006-27Aug.2006  
 2. Mean Squared Error  
 3. Mean Absolute Error  
 4. Akaike Information Criterion  
 5. Bayesian Information Criterion  
 6. Hannan-Quinn criterion


خطا (SSE)<sup>۱</sup>، جذر میانگین مربعات خطا (RMSE)<sup>۲</sup>، میانگین خطا (ME)<sup>۳</sup> و میانگین مطلق درصد خطا (MAPE)<sup>۴</sup> نیز استفاده شده است.

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

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

با توجه به تعداد داده‌ها (اندازه نمونه) و مراحل اجرای روش ترکیبی، در مرحله اول یک مدل به منظور مدل‌سازی قسمت خطی داده‌ها مورد استفاده قرار گرفته و در مرحله دوم با توجه به اصول طراحی شبکه‌های عصبی و با انجام آزمایشات متعدد، شبکه‌ای تک لایه با ۳ نرون ورودی و ۳ نرون میانی و یک نرون خروجی  $N^{(3,3,1)}$  و توابع فعال‌سازی سیگموئیدی طراحی و به منظور مدل‌سازی ساختارهای غیرخطی موجود در باقیمانده‌های مدل اریما مورد استفاده قرار گرفته است. لازم به ذکر می‌باشد که شیوه آموزش شبکه، پس‌انتشار خطا بوده و به منظور اطمینان از صحت جوابهای حاصله و مسأله کمینه محلی شبکه با چندین نقطه تصادفی اولیه آموزش داده شده است. منحنی خطای یادگیری شبکه نهایی بر اساس زمان در شکل (۳) ملاحظه می‌شود. تقسیم‌بندی داده‌ها به داده‌های آزمون و آموزش نیز در جدول (۱) آورده شده است.

شکل (۳): منحنی خطای یادگیری شبکه نهایی بر اساس زمان.



مأخذ: یافته‌های تحقیق

1. Sum of Squared Error
2. Root Mean Squared Error
3. Mean Error
4. Mean Absolute Percentage Error

جدول (۱): تقسیم‌بندی داده‌ها به داده‌های آزمون و آموزش.

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

مأخذ: یافته‌های تحقیق

معیارهای عملکرد مدل ترکیبی در پیش‌بینی نرخ ارز (یورو در مقابل ریال) برای هر یک از مجموعه‌های آزمون و آموزش در جدول (۲) آورده شده است.


جدول (۲): معیارهای عملکرد مدل نهایی پیش‌بینی نرخ ارز.

آموزش					آزمون					
MSE	AIC	BIC	HQC	MAE	MSE	SSE	RMSE	ME	MAPE	MAE
۳۰۹۰	۳/۶۴	۳/۶۴	۳/۴۱	۳۰/۱۱	۲۷۱۸	۵۴۳۵۵	۵۲/۱۳	-۵/۴۲	۰/۳۲۸	۳۸/۵۰

مأخذ: یافته‌های تحقیق


اطلاعات مربوط به مقادیر حقیقی و پیش‌بینی شده هر یک از مدل‌های اریما، شبکه‌های عصبی و مدل ترکیبی نیز به ترتیب در شکل‌های (۴)، (۵)، (۶) آورده شده است.

شکل (۴): مقادیر واقعی و پیش‌بینی شده مدل اریما




مأخذ: یافته‌های تحقیق

شکل (۵): مقادیر واقعی و پیش‌بینی شده مدل شبکه‌های عصبی



مأخذ: یافته‌های تحقیق

شکل (۶): مقادیر واقعی و پیش‌بینی شده مدل ترکیبی



مأخذ: یافته‌های تحقیق

## ۳-۴- مقایسه روش ترکیبی با روش اریما و شبکه‌های عصبی

در این قسمت به منظور نشان دادن برتری مدل ترکیبی نسبت به مدل‌های تشکیل‌دهنده خطی و غیرخطی، نتایج سه مدل با یکدیگر مقایسه شده‌اند. معیارهای عملکرد به‌دست آمده از روش‌های اریما، شبکه‌های عصبی و مدل ترکیبی برای داده‌های آزمون در جدول (۳) آورده شده است.

جدول (۳): نتایج به‌دست آمده از مدلها.

داده‌های آزمون						معیار ارزیابی روش
MSE	SSE	RMSE	ME	MAPE	MAE	
۴۱۹۲	۸۳۸۵۲	۶۴/۷۵	-۹/۲۷	۰/۴۷۶	۵۵/۹۰	مدل اریما
۳۹۱۷	۷۸۳۴۹	۶۲/۵۹	-۴/۳۹	۰/۳۸۷	۴۳/۵۳	مدل شبکه عصبی
۲۷۱۸	۵۴۳۵۵	۵۲/۱۳	-۵/۴۲	۰/۳۲۸	۳۸/۵۰	مدل ترکیبی

مأخذ: یافته‌های تحقیق

نتایج به‌دست آمده از مقایسه روش ترکیبی با روش‌های اریما و شبکه‌های عصبی مصنوعی بیانگر برتری روش ترکیبی بر دو روش دیگر می‌باشد. به‌کارگیری روش ترکیبی به منظور پیش‌بینی نرخ ارز نتایج حاصله را به ترتیب به میزان ۳۵/۲ و ۳۰/۶ درصد در میانگین مربعات خطا و به میزان ۳۱/۱ و ۱۱/۶ درصد در میانگین قدرمطلق خطا بهبود داده است.

### ۵- نتیجه‌گیری

تحلیل سری‌های زمانی و پیش‌بینی، موضوع بسیاری از تحقیقات در چند دهه گذشته بوده است. پیش‌بینی از ابزارها و راهکارهای مؤثر به منظور برنامه‌ریزی و تدوین استراتژی‌های مالی می‌باشد. دقت پیش‌بینی سری‌های زمانی در بسیاری از فرایندهای تصمیم‌گیری نقش اساسی داشته و از این رو تحقیقات بسیاری به منظور بهبود دقت مدل‌های پیش‌بینی انجام شده است. روش‌های اریما و شبکه‌های عصبی مصنوعی از جمله مهمترین روش‌های پیش‌بینی در تحقیقات اخیر می‌باشند. اگر چه هر دو روش بیان شده، در مسائل متنوعی به کار گرفته شده‌اند، اما هیچ یک از آنها یک مدل کلی که بتوان از آن در هر موقعیت پیش‌بینی استفاده کرد، نیستند. امروزه با وجود روش‌های متعدد پیش‌بینی، هنوز پیش‌بینی‌های دقیق در بازارهای مالی کار چندان ساده‌ای نمی‌باشد.

در این مقاله به منظور بهبود عملکرد و حصول نتایج دقیق‌تر یک روش ترکیبی به منظور پیش‌بینی در محیط‌های مالی پیشنهاد شده است. نتایج حاصله از پیش‌بینی نرخ ارز (یورو در مقابل ریال) با روش ترکیبی بیانگر بهبود در دقت پیش‌بینی‌ها نسبت به مدل‌های اریما و شبکه‌های عصبی در معیارهای سنجش عملکرد انتخابی شده است. لذا می‌توان چنین نتیجه گرفت که در مواردی که خطی یا غیرخطی بودن الگوهای موجود در سیستم مشخص نبوده و یا سیستم مورد مطالعه شامل هر دو نوع الگو باشد، مدل ترکیبی مذکور می‌تواند نتایج مطلوب‌تری ارائه نماید.

### تشکر و قدردانی

در اینجا جا دارد از همکاریها و حمایت‌های جناب آقای مهندس مجید رفیعی به جهت ارائه اطلاعات و آمار مورد نیاز تشکر و قدردانی نماییم.

Archive



## فهرست منابع

خاشعی، مهدی (۱۳۸۴) 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.

خاشعی، مهدی و بیجاری، مهدی (۱۳۸۵) به‌کارگیری مدل‌های میانگین متحرک خودرگرسیون انباشته فازي به منظور پیش‌بینی نرخ ارز؛ مجموعه مقالات ششمین کنفرانس فازي، دانشگاه شیراز، صفحه ۲۶-۳۵.

- Al-Saba, T. & El-Amin, I. (1999) Artificial Neural Networks as Applied to Long-term Demand Forecasting; *Artif. Intell. Eng.* 13, pp. 189-197.
- Balaban, E. (2004) Comparative Forecasting performance of Symmetric and Asymmetric Conditional Volatility Models of an Exchange Rate; *Economics Letters*, Vol 83, Issue 1, April, pp. 99-105.
- 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, Issue 1, January-March, pp. 139-140.
- Box, G. E. P. & Jenkins, G. (1970) *Time Series Analysis, Forecasting and Control*; Holden-Day, San Francisco, CA.
- Chen, A., Leung, M. T. (2003) A Bayesian Vector Error Correction Model for Forecasting Exchange Rates", *Computers & Operations Research*, Volume 30, Issue 6, May, pp. 887-900.
- Chen, A., Leung, Mark T. (2004) Regression Neural Network for Error Correction in Foreign Exchange Forecasting and Trading; *Computers & Operations Research*, Volume 31, Issue 7, pp. 1049-1068, June.
- Clemen, R (1989) Combining Forecasts: A Review and Annotated Bibliography with discussion; *Int. J. Forecasting* 5, pp. 559-608.
- Demuth, H. and Beale, B. (2004) *Neural Network Toolbox User Guide*; The Mathworks Inc, Natick.
- Denton, J. W. (1995) How Good are Neural Networks for Causal Forecasting; *Journal Business Forecasting* 14, pp. 17- 20.
- Elkateb, M. M. , Solaiman, K. & Al-Turki, Y. (1998) A Comparative Study of Medium-Weather-Dependent Load Forecasting Using Enhanced Artificial Fuzzy Neural Network and Statistical Techniques", *Neurocomputing* 23, pp. 3-13.
- Fildes, R. & Makridakis, S. (1995) The Impact of Empirical Accuracy Studies on Time Series Analysis and Forecasting; *Int. Statist. Rev.* 63, pp. 289-308.
- Ginzburg, I. & Horn, D. (1994) Combined Neural Networks for Time Series Analysis; *Adv. Neural Inf. Process Systems* 6, pp. 224-231.
- Hwang, H. B. (2001) Insights into Neural-Network Forecasting Time Series Corresponding to ARMA (p; q) Structures; *Omega* 29, pp. 273-289.
- Hwang, H. & Brian, H. T. (2001) A Simple Neural Network for ARMA (p;q) Time Series; *Omega* 29, pp. 319- 333.
- Ince, H., and Trafalis Theodore, B. (2005) A Hybrid Model for Exchange Rate Prediction; *Decision Support Systems*, In Press, Corrected Proof, Available Online 20, October.
- Luxhoj, J. T., Riis, J. O. & Stensballe, B. (1996) A Hybrid Econometric-Neural Network Modeling Approach for Sales Forecasting; *Int. J. Prod. Econ.* 43, pp. 175-192.

- Makridakis, S., Chatfield, C., Hibon, M., Lawrence, M., Millers, T. Ord, K. & Simmons, L. F. (1993) The M-2 Competition: A Real-Life Judgmentally Based Forecasting Study; *Int. J. Forecasting* 9, pp. 5–29.
- Markham, I. S. & Rakes, T. R. (1998) The Effect of Sample Size and Variability of Data on the Comparative Performance of Artificial Neural Networks and Regression; *Comput. Oper. Res.* 25, pp. 251–263.
- Meade, N. (2002) A Comparison of the Accuracy of Short Term Foreign Exchange Forecasting Methods; *International Journal of Forecasting*, Volume 18, Issue 1, January–March, pp. 67–83.
- Palm, F. C. & Zellner, A. (1992) To Combine or not to Combine? Issues of combining forecasts; *J. Forecasting* 11, pp. 687–701.
- Pelikan, E., de Groot, C. & Wurtz, D. (1992) Power Consumption in West-Bohemia: Improved Forecasts with Decorrelating Connectionist Networks"; *Neural Network World* 2, pp. 701–712.
- Shin, T., and Han, I. (2000) Optimal Signal Multi-Resolution by Genetic Algorithms to Support Artificial Neural Networks for Exchange-Rate Forecasting; *Expert Systems with Applications*, Volume 18, Issue 4, May, pp. 257–269.
- Tang, Z. & Fishwick, P. A.; Feedforward Neural Nets as Models for Time Series Forecasting; *ORSA J. Comput.* 5, pp. 374–385.
- Wang, Sh., Yu, L. and Lai, K. K. (2005) A Novel Nonlinear ensemble forecasting model incorporating GLAR and ANN for foreign exchange rates"; *Computers & Operations Research*, Volume 32, Issue 10, October, pp. 2523–2541, 2005.
- Wedding, D. K. & Cios, K. J. (1996) Time Series Forecasting by Combining RBF Networks, Certainty Factors, and the Box–Jenkins Model; *Neurocomputing* 10, pp. 149–168.
- Zhang, G., Patuwo, B. E. & Hu, M. Y. (2004) Forecasting with Artificial Neural Networks: The State of the art; *Neurocomputing* 56, pp. 205 – 232.
- Zhang, G., Patuwo, B. E. & Hu, M. Y. (1998) Forecasting with Artificial Neural Networks: The State of the art; *Int.J. Forecasting* 14, pp. 35–62.
- Zhang, G., Patuwo, B. E. & Hu, M. Y. (2001) A Simulation Study of Artificial Neural Networks for Nonlinear Time-Series Forecasting"; *Comput. Oper. Res.* 28, pp. 381–396.
- Zhang, P. & Min, G. (2005) Neural Nnetwork Forecasting for Seasonal and Trend Time Series; *European Journal of Operational Research* 160, pp. 501–514.

Archiv SID