

پیش بینی نرخ ارز با استفاده از شبکه‌های عصبی مصنوعی و مدل *ARIMA*

دکتر منصور زراء نژاد، علی فقه مجیدی و روح الله رضایی*

تاریخ وصول: 1387/8/15 تاریخ پذیرش: 1387/12/21

چکیده:

یکی از روش‌های سنتی پیش بینی، تجزیه و تحلیل سری زمانی است که بر دو فرض ایستایی و خطی بودن بنیان نهاده شده است. در مورد عملکرد این مدل‌های سنتی بعضاً تردیدهای ایجاد شده است. یکی از روش‌های جایگزین، شبکه‌های عصبی مصنوعی است که در برخی از موارد توانایی بالقوه‌ی خوبی برای پیش بینی سری‌های زمانی از خود نشان داده‌اند. در این مقاله، پس از مرور پژوهش‌های انجام شده در مورد توانایی پیش بینی مدل‌های خود توضیح جمعی میانگین متحرک¹ (*ARIMA*) و شبکه‌های عصبی مصنوعی² (*ANN*) به مقایسه‌ی این دو روش برای پیش بینی نرخ روزانه ارز در دوره‌ی مارس 2006 تا فوریه 2009 پرداخته شده است. نتایج تحقیق نشان داده است که روش شبکه‌های عصبی تخمین‌های بهتری نسبت به روش *ARIMA* ارائه می‌کند. در این پژوهش، از ابزارهای محاسباتی نرم افزار *MATLAB* و داده‌های اقتصادی ایران استفاده شده است.

طبقه بندی *JEL*: F_{31} , C_{45}

واژه‌های کلیدی: پیش بینی، شبکه‌های عصبی مصنوعی (*ANN*)، خود رگرسیون میانگین متحرک انباشته

* به ترتیب استاد، دانشجوی دکتری و کارشناس ارشد اقتصاد دانشگاه شهید چمران اهواز

(zarram@gmail.com)

¹ Autoregressive Integrated Moving Average Process

² Artificial Neural Network

1- مقدمه

امروزه پیش بینی روند متغیرهای اقتصادی از اهمیت ویژه‌ای برای سیاستگذاران دولتی و خصوصی در تنظیم روابط و مناسبات اقتصادی برخوردار است. به طوری که نیاز به ابزار و شیوه‌های پیش بینی متغیرها با کمترین خطا بسیار محسوس است. در اثر این نیاز، مدل‌های گوناگونی برای پیش بینی متغیرها توسعه یافته است. وجود برخی از مزیت‌های شبکه‌های عصبی مصنوعی (ANN) در امر پیش بینی برخی از متغیرها موجب شد که اقتصاددانان به این روش توجه کنند. در ابتدا، با توجه به نیاز این مدل‌ها به داده‌های زیاد، اکثر پژوهش‌ها در زمینه‌های بازارهای مالی انجام می‌گرفت. استفاده از شبکه‌های عصبی مصنوعی برای پیش بینی و مدل سازی در اقتصاد کلان در دهه‌ی 90 آغاز شد. با توجه به اهمیت پیش بینی نرخ‌های ارز در این مقاله پنج نرخ ارز JPY ³، GBP ⁴، USD ⁵، CAD ⁶ و EUR ⁷ پیش بینی شده است.

2- پیشینه‌ی پژوهش

در زمینه‌ی پیش بینی متغیرهای اقتصادی به وسیله‌ی شبکه‌های عصبی مصنوعی و مقایسه‌ی نتایج با روش‌های دیگر تحقیقات متفاوت و متعددی انجام شده است.

کونگ و وایت⁸ (1994) موضوعات موازی در شبکه‌های عصبی و اقتصاد سنجی را و هیل⁹ و دیگران (1994) نتایج پیش بینی توسط شبکه‌های عصبی و مدل‌های آماری مختلف را مورد بررسی و مقایسه قرار داده‌اند. نتایج حاصل بیانگر این بود که شبکه‌های عصبی مصنوعی در زمینه‌ی پیش بینی بهتر از سایر روش‌ها عمل می‌کنند. کهزادی¹⁰ و دیگران (1995) معاملات سلف ذرت را به روش شبکه‌های عصبی و مدل $ARIMA$ ، با استفاده از معیارهای مختلف عملکرد پیش بینی کرده‌اند. نتایج تحقیق نشان داد که خطای پیش بینی با شبکه‌ی عصبی

³ Japanese Yen

⁴ Pound Sterling

⁵ US Dollar

⁶ Canada Dollar

⁷ Euro

⁸ Kung and White

⁹ Hill

¹⁰ Kohzadi

مصنوعی بین 18 تا 40 درصد کمتر از خطای پیش بینی با *ARIMA* است. ¹¹ فو (1998) رشد تولید ناخالص داخلی واقعی ایالت متحده آمریکا، را با استفاده از شبکه‌های عصبی مصنوعی و رگرسیون خطی مورد بررسی قرار داده است. نتایج حاصل بیانگر این بود که شبکه‌های عصبی مصنوعی در پیش بینی بهتر عمل می‌کند. مشیری و کامرون ¹² (2000) عملکرد شبکه‌های عصبی مصنوعی با سایر روش‌های اقتصاد سنجی سنتی و سری زمانی را برای پیش بینی نرخ تورم کانادا مقایسه کرده‌اند. آنها مدل‌های شبکه‌های عصبی مصنوعی را با مدل‌های ساختاری، *VAR*، *BVAR* و *ARIMA* برای افق‌های زمانی مختلف (یک، سه و دوازده ماه بعد) مقایسه کرده‌اند. معیارهای به کارگرفته شده در این پژوهش، یعنی ریشه‌ی میانگین مربع خطاها (*RMSE*) و میانگین قدر مطلق خطاها (*MAE*) نشان داد که شبکه‌های عصبی برای پیش بینی نرخ تورم کانادا بهتر عمل می‌کنند.

اصغری اسکویی (1381) در پژوهشی به بررسی کاربرد شبکه‌ی عصبی مصنوعی در پیش بینی سری‌های زمانی داده‌های اقتصادی پرداخته است. در این تحقیق عوامل مختلف ساختاری، روش‌های مختلف یادگیری شبکه‌های عصبی و انتخاب و کاربرد مناسب داده‌ها در فرایند پیش بینی نیز مورد ارزیابی و بررسی قرار گرفته است. قدیمی و مشیری (1381) مدل سازی و پیش بینی رشد اقتصادی در ایران را با استفاده از شبکه‌های عصبی مصنوعی بررسی کرده‌اند. در این پژوهش، کارایی روش شبکه‌ی عصبی مصنوعی با کارایی یک مدل خطی رگرسیون برای پیش بینی نرخ رشد اقتصادی ایران در دوره‌ی 1373-1315 مقایسه شده است. نتایج حاصل بیانگر عملکرد بهتر شبکه‌ی عصبی نسبت به روش‌های دیگر است (زرانژاد و حمید، 1388).

3- شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی تکنیک‌هایی هستند که به تقلید سیستم عصبی بیولوژیکی انسان می‌پردازند. تا کنون از شبکه‌های عصبی در بسیاری از زمینه‌ها نظیر تجارت، صنعت و علوم تجربی استفاده شده است. سیستم عصبی انسان از

¹¹ Fu

¹² Moshiri and Cameron

یک سری عناصر پردازش ساده‌ای به نام نرون¹³ یا گره¹⁴ تشکیل یافته است. هر کدام از این نرون‌ها یک سیگنال اولیه را که اطلاعات کامل یک نرون دیگر و یا محرک خارجی است، دریافت می‌کند و آن را با استفاده از یک تابع فعال سازی¹⁵ یا تبدیل، پردازش و یک خروجی پردازش شده را تولید می‌کند. در مرحله‌ی بعد خروجی مربوط را به نرون‌های داخلی‌تر یا نرون‌های دیگر می‌فرستد. این ویژگی، یعنی پردازش اطلاعات، شبکه‌های عصبی مصنوعی را به یک روش محاسباتی قدرتمند برای یادگیری از مثال‌ها و تعمیم این یادگیری به مثال‌هایی که تاکنون مشاهده نشده است، تبدیل می‌کند.

شبکه‌های عصبی مختلفی تاکنون ارائه شده است که از جمله اینها می‌توان به شبکه‌ی پرسپترون چند لایه (MLP)¹⁶ یا پیشخور¹⁷، شبکه‌ی هاپفیلد¹⁸ و شبکه‌ی خود سازمان ده کوهونن¹⁹ اشاره کرد. از میان این شبکه‌ها، شبکه‌ی پرسپترون چند لایه به طور گسترده‌ای مورد استفاده قرار گرفته است. یک شبکه‌ی عصبی MLP معمولاً از چند لایه و نرون تشکیل می‌یابد. اولین و پایین‌ترین لایه، لایه‌ی ورودی²⁰ است که در آن اطلاعات خارجی دریافت می‌گردد. آخرین یا بالاترین لایه، لایه‌ی خروجی²¹ است که در آن حل مسئله انجام می‌گیرد. لایه‌ی ورودی و خروجی توسط یک یا چند لایه واسطه که لایه‌ی میانی²² یا پنهان نامیده می‌شود، جدا می‌شوند. نرون‌های موجود در لایه‌های همجوار معمولاً به طور کامل توسط کمان‌های غیرحلقوی²³ از لایه‌ی پایین به لایه‌ی بالا به هم مرتبط می‌شوند. در نمودار 1، یک شبکه‌ی پیشخور معمولی (MLP) نشان داده شده است.

¹³ Neuron

¹⁴ Node

¹⁵ Activation function

¹⁶ Multi layer perceptrons

¹⁷ Feedforwards

¹⁸ Hopfield network

¹⁹ Kohonens self organizing network

²⁰ Input layer

²¹ Output layer

²² Hidden layer

²³ Acyclic arcs

پیش از اینکه یک شبکه‌ی عصبی مصنوعی کاری انجام دهد، باید آموزش²⁴ داده شود. اساساً آموزش دادن شبکه، فرایند تعیین وزن‌های کمان²⁵ است که در واقع از عناصر کلیدی یک شبکه به شمار می‌رود. برای آموزش شبکه، معمولاً کل داده‌ها به دو مجموعه‌ی آموزش (داده‌های نمونه)²⁶ و آزمون (داده‌های خارج از نمونه)²⁷ تقسیم می‌شوند. مجموعه‌ی آموزش برای تخمین وزن‌های کمان به کار گرفته می‌شود، در حالی که مجموعه‌ی آزمون برای ارزیابی توانایی تعمیم مدل به کار می‌رود.

از آنجا که شبکه‌های عصبی کاربردهای متعدد و متفاوت دارد، الگوریتم آنها با توجه به نوع استفاده آنها متغیر است. صرف نظر از کاربردهای متفاوت شبکه، هر شبکه دارای شش مرحله‌ی مجزا برای طراحی، آموزش و آزمون است (شازلی، 1999).²⁸ این مراحل عبارتند از: (1) تعیین موضوع پیش بینی، (2) جمع آوری داده‌ها، (3) پردازش داده‌ها، (4) استخراج مجموعه‌ی آزمون، (5) طراحی ساختمان²⁹ شبکه، (6) آموزش دادن شبکه.

طراحی یک شبکه‌ی عصبی مصنوعی شامل فرایندهای مختلفی است. هر فرایند توسط یک پارامتر تبیین می‌شود. این پارامترها معیار قضاوت در مورد خوبی شبکه است و در ارزیابی مدل خوب³⁰ به کار می‌روند. در طراحی یک شبکه، باید مواردی همچون نوع توپولوژی (شیوه‌ی ارتباط نرون‌ها به هم)، تکنیک یادگیری، تابع فعال سازی، تعداد دوره‌های آموزش، مقیاس بندی و پردازش داده‌ها را تعیین کرد. مسأله‌ی انتخاب پارامترهای شبکه‌ی عصبی مصنوعی مسأله‌ی پارامترسازی³¹ انتخاب تکنیک بهینه یابی ثانویه³² است (کینگ دن و فیلدمن، 1995).³³

²⁴ Training

²⁵ Arc weights

²⁶ Training set (in sample data)

²⁷ Test set (out sample data)

²⁸ El Shazely


²⁹ Architecture

³⁰ Good model

³¹ Parameterization issue

³² Secondary optimization technique

³³ Kingdon and Feldman

نمودار 1: شبکه‌ی MLP ساده

4- انواع شبکه‌های عصبی

با توجه به ارتباطات بین لایه‌ها و نیز ارتباطات درون لایه‌ای، شبکه‌های عصبی مصنوعی به انواع مختلفی دسته بندی می‌شوند. در عمل، با توجه به مسأله‌ی خاص مورد بررسی باید ساختار شبکه به گونه‌ای طراحی شود که در آن تعداد لایه‌ها و تعداد نرون‌های هر لایه به اندازه‌ی کافی و مناسب برای حل مسأله باشد.

برخی از شبکه‌های عصبی مصنوعی عبارتند از: شبکه‌ی پرسپترون³⁴، پروسپترون‌های چند لایه³⁵ (MLP) یا شبکه‌ی پیشخور چند لایه³⁶ ($MLFN$)، شبکه‌ی آبخاری³⁷ ($CFNN$)، شبکه‌ی بازگشتی³⁸ (RNN) و شبکه‌ی تأخیر زمانی³⁹ ($TDNN$).

در این تحقیق از شبکه‌ی پیشخور چند لایه استفاده می‌شود؛ دلیل انتخاب پرسپترون چند لایه با روش یادگیری پس انتشار خطا، اثبات این است که یک شبکه‌ی عصبی پرسپترون چند لایه با الگوریتم یادگیری مزبور، یک تابع تقریب زنده‌ی عمومی است. یعنی هر مقدار از دقت که مورد نیاز باشد، یک پیکربندی از شبکه‌ی مزبور وجود دارد که قادر است دقت مزبور را تحصیل نماید (هرنیک،⁴⁰ 1991). به همین دلیل به بررسی ساختار این نوع شبکه می‌پردازیم.

³⁴ Perceptron

³⁵ Multi-Layer Perceptron

³⁶ Multi-Layer Feed Forward

³⁷ Cascade Forward Neural Network

³⁸ Recurrent Neural Network

³⁹ Time Delay Neural Network

⁴⁰ Hornik

5- ساختار شبکه‌ی پرسپترون چند لایه

یک شبکه معمولاً از تعدادی لایه تشکیل می‌شود. در یک شبکه‌ی پرسپترون چند لایه (MLP) تمامی نرون‌های ورودی در یک لایه‌ی ورودی و تمامی نرون‌های خروجی در یک لایه‌ی خروجی و تمامی نرون‌های پنهان در یک یا چند لایه‌ی پنهان توزیع می‌شوند. در طراحی این شبکه باید متغیرهای مانند تعداد نرون‌های ورودی، تعداد لایه‌های پنهان و نرون‌های پنهان و تعداد نرون‌های خروجی تعیین شود.

تعداد نرون‌های ورودی برابر با تعداد متغیرهای بردار ورودی مورد استفاده برای پیش‌بینی مقادیر آینده متغیر مورد بررسی است. برای پیش‌بینی عالی، تعداد ورودی‌ها مشخص و به راحتی قابل تعیین است. برای پیش‌بینی سری زمانی، تعداد نرون‌های ورودی برابر با تعداد مشاهدات باوقفه‌ای است که برای کشف الگوی موجود در داده‌ها و پیش‌بینی مقادیر آینده‌ی آن به کار می‌رود. وجود تعداد خیلی کم یا خیلی زیاد از نرون‌های ورودی می‌تواند قابلیت یادگیری و پیش‌بینی شبکه را تحت تأثیر قرار دهد. بنابراین، تعیین تعداد نرون‌های ورودی مهم‌ترین عامل در پیش‌بینی سری زمانی است؛ زیرا حاوی اطلاعات بسیار مهمی در خصوص ساختار خود همبستگی پیچیده (خطی یا غیرخطی) داده‌ها است.

نرون‌های لایه‌های پنهان نیز نقش بسیار مهمی در به کارگیری موفقیت‌آمیز یک شبکه دارند. در واقع این نرون‌های پنهان در لایه‌های پنهان هستند که به شبکه اجازه کشف ویژگی‌ها، شکار الگوی موجود در داده‌ها و طرح‌ریزی یک نقشه‌ی غیرخطی کاملاً پیچیده میان متغیرهای ورودی و خروجی را می‌دهند. باید توجه داشت که در صورت نبود نرون‌های پنهان، پرسپترون‌های ساده با نرون‌های خروجی خطی، کارکردی همانند کارکرد مدل‌های آماری خطی برای پیش‌بینی دارند. یک شبکه‌ی عصبی مصنوعی با یک لایه پنهان می‌تواند هر تابع غیرخطی پیچیده را با هر درجه از دقت تقریب بزند (هورنیک و دیگران، 1989). از این رو، بیشتر پژوهشگران از یک لایه‌ی مخفی برای پیش‌بینی استفاده می‌کنند. یک لایه‌ی پنهان به تعداد زیادی نرون پنهان احتیاج دارد و این امر زمان آموزش را بسیار طولانی می‌کند. معمول‌ترین روش برای تعیین تعداد نرون‌های پنهان و لایه‌های پنهان روش تجربی یا آزمون و خطا⁴¹ است.

⁴¹ Trial and Error

تعداد نرون‌های خروجی معمولاً به سادگی و با توجه به موضوع مورد مطالعه تعیین می‌شود. برای مسأله پیش‌بینی سری زمانی، تعداد نرون‌های خروجی به افق پیش‌بینی⁴² بستگی دارد.

دو نوع پیش‌بینی به صورت پیش‌بینی یک گام به جلو شامل یک نرون خروجی و پیش‌بینی چند گام به جلو شامل یک یا چند نرون خروجی وجود دارد. برای پیش‌بینی به صورت چندگام به جلو نیز دو روش وجود دارد. روش اول که در روش باکس - جنکینز نیز از آن استفاده می‌شود، عبارت از پیش‌بینی تکراری است. در این روش فقط به یک نرون خروجی نیاز است و در آن مقادیر پیش‌بینی به صورت تکراری به عنوان ورودی برای پیش‌بینی‌های آینده به کار می‌رود. روش دوم روش مستقیم است. در این روش به شبکه اجازه داده می‌شود که چندین نرون خروجی داشته باشد. به نظر می‌رسد که روش مستقیم روش بهتری باشد (ژانگ و ترلین،⁴³ 1994).

6- مجموعه‌ی آموزش⁴⁴ و مجموعه‌ی آزمون⁴⁵

در یک شبکه معمولاً داده‌ها به دو مجموعه‌ی آموزش و آزمون تقسیم می‌شود. مجموعه‌ی آموزش برای تخمین وزن‌های کمان شبکه و در واقع آموزش و گسترش شبکه به کار گرفته می‌شوند؛ ولی مجموعه‌ی آزمون برای ارزیابی توانایی تعمیم مدل به کار می‌رود. مسأله مهم، چگونگی تقسیم داده‌ها به این دو مجموعه است. در این زمینه باید به مسائلی همچون ویژگی‌های مسأله، نوع داده‌ها و داده‌های در دسترس توجه نمود. این دو مجموعه باید ویژگی‌های جامعه را داشته باشند. این امر در پیش‌بینی سری زمانی بسیار مهم است.

7- معیارهای عملکرد شبکه‌ی عصبی مصنوعی

اگرچه چندین معیار برای عملکرد شبکه‌ی عصبی مصنوعی وجود دارد که از جمله آنها می‌توان به زمان مدل‌بندی، زمان آموزش و دقت پیش‌بینی اشاره کرد. مهم‌ترین معیار برای ارزیابی عملکرد شبکه‌ی عصبی مصنوعی، معیار دقت

⁴² Forecasting Horizon

⁴³ Zhang and Thearling

⁴⁴ Training Set

⁴⁵ Test Set

پیش‌بینی است. دقت پیش‌بینی به صورت اختلاف میان مقادیر واقعی و مقادیر پیش‌بینی شده توسط شبکه تعریف می‌شود. برخی از روش‌های اندازه‌گیری دقت پیش‌بینی عبارتند از:

1- نرخ اغتشاش⁴⁶ که به صورت محاسبه نسبت پیش‌بینی‌های ناصحیح به تعداد کل پیش‌بینی‌ها تعریف و محاسبه می‌شود.

2- انحراف میانگین مطلق خطا که به صورت $MAD = \frac{\sum |e_t|}{N}$ تعریف و اندازه‌گیری می‌شود.

3- میانگین قدر مطلق درصد خطا که به صورت $MAPE = \frac{1}{N} \sum \left| \frac{e_t}{y_t} \right| (100)$ تعریف و اندازه‌گیری می‌شود.

4- میانگین مربعات خطا که به صورت $MSE = \frac{\sum e_t^2}{N}$ تعریف و اندازه‌گیری می‌شود.

5- ریشه‌ی میانگین مربعات خطا که به صورت $RMSE = \sqrt{MSE}$ تعریف و اندازه‌گیری می‌شود.

6- آماره‌ی U تایل⁴⁷ به صورت نسبت ریشه‌ی میانگین مربعات خطای مدل پیش‌بینی به ریشه‌ی میانگین مربعات خطای یک مدل ابتدایی که در آن ارزش متغیر مورد پیش‌بینی ثابت فرض می‌شود، تعریف و محاسبه می‌گردد.

$$U = \frac{\sqrt{\frac{\sum e_t^2}{N}}}{\sqrt{\frac{\sum (y_{t-1} - y_t)^2}{N}}} \quad (1)$$

7- بر اساس رابطه‌ی فوق، پیش‌بینی در دوره‌ی بعد به صورت ساده، ارزش واقعی دوره‌ی قبل را اختیار می‌کند. هر اندازه آماره‌ی U به صفر نزدیک‌تر باشد، نشانه‌ی دقت بیشتر است. معمولاً ارزش‌های کوچکتر از 0/55 مورد قبول است. مدل‌هایی که آماره‌ی U آنها بزرگتر از یک باشد، رد می‌شوند؛ زیرا در این حالت پیش‌بینی مدل از یک مدل ابتدایی نیز بدتر است.

⁴⁶ Confusion Rate

⁴⁷ Theil U Statistic

8- در روابط بالا e خطای پیش‌بینی y مقدار واقعی و N تعداد اجزاء خطا و t نشان دهنده‌ی زمان است.

8- پیش‌بینی سری‌های زمانی توسط شبکه‌های عصبی مصنوعی

در پیش‌بینی سری‌های زمانی، ورودی‌های شبکه‌ی عصبی مصنوعی مشاهدات با وقفه‌ی سری زمانی است و خروجی شبکه، مقادیر آتی آنها ورودی از n است. در این حالت، هر الگوی آموزشی⁴⁸ از تعداد ثابتی از مشاهدات با وقفه سری تشکیل می‌یابد. در واقع اگر مشاهدات گذشته به صورت سری باشد، آنگاه شبکه‌ی عصبی مصنوعی تابع زیر را تقریب و طرح ریزی می‌کند:

$$y_{t+1} = f(y_t, y_{t-1}, \dots, y_{t-n}) \quad (2)$$

که در آن y مشاهده‌ی زمان t ام است. همان طور که مشاهده می‌کنیم، در این حالت شبکه‌ی عصبی مصنوعی معادل با مدل خود رگرسیون در پیش‌بینی سری‌های زمانی است.

اگر N مشاهده‌ی y_1, y_2, \dots, y_N در مجموعه‌ی آموزشی داشته باشیم، برای پیش‌بینی یک گام به جلو، شبکه‌ی عصبی مصنوعی باید دارای n نرون ورودی و $N-n$ الگوی آموزشی باشد. اولین الگوی آموزشی از y_1, y_2, \dots, y_N به عنوان ورودی و y_{n+1} به عنوان خروجی مطلوب یا هدف تشکیل می‌یابد. دومین الگوی آموزشی از y_2, y_3, \dots, y_{n+1} به عنوان ورودی و y_{n+2} به عنوان خروجی مطلوب تشکیل می‌یابد. سرانجام آخرین الگوی آموزشی به صورت $y_{N-n}, y_{N-n+1}, \dots, y_{N-1}$ به عنوان ورودی و y_N به عنوان خروجی مطلوب تشکیل می‌یابد.

9- مزایای شبکه‌های عصبی مصنوعی

یکی از قابلیت‌های مهم شبکه‌های عصبی مصنوعی پیش‌بینی است. این قابلیت به خاطر ویژگی‌های منحصر به فرد شبکه‌ها است. ویژگی نخست این است که برخلاف روش‌های مبتنی بر مدل‌های سنتی، شبکه‌های عصبی مصنوعی روش‌های خود تطبیقی مستخرج از داده‌ها هستند⁴⁹ که در آنها پیش‌فرض‌های بسیار کمی در خصوص مدل‌های رفتاری مسأله مورد بررسی وجود دارد و به

⁴⁸ Training Pattern

⁴⁹ Data – Driven Self – Adaptive Methods

عبارتی دیگر به صورت مدل آزاد هستند.⁵⁰ این شبکه‌ها از مثال‌ها درس می‌آموزند و روابط تبعی میان داده‌ها را در صورت ناشناخته بودن روابط یا دشوار بودن توصیف آنها، کشف می‌کنند. از این رو، در صورتی که مسأله بسیار مشکل باشد یا داده‌های کافی وجود نداشته باشد، شبکه‌های عصبی ابزار بسیار مفیدی است؛ زیرا با توجه به آنچه که گفته شد، در واقع شبکه‌های عصبی مصنوعی یکی از روش‌های آماری ناپارامتریک غیرخطی چند متغیره⁵¹ است که توان یادگیری و تصحیح خطا دارد (آزوف،⁵² 1994).

این رویکرد مدل سازی که توانایی یادگیری از طریق تجربه دارند، ابزار مفیدی برای حل بسیاری از مسائل عملی است؛ زیرا جمع آوری داده‌ها برای مسائل عملی غالباً بسیار راحت‌تر از ارائه‌ی حدسیات تئوریک خوب در مورد قوانین مسلط بر مجموعه یا سیستمی است که داده‌ها از آن استخراج می‌شود (ال شازلی،⁵³ 1999).

ویژگی دوم شبکه‌های عصبی مصنوعی قابلیت تعمیم بسیار بالای آنهاست. پس از آن که شبکه توسط قسمتی از داده‌ها (یک نمونه) آموزش داده شد، غالباً می‌تواند، مقادیر آتی (مشاهده نشده) متغیر مورد بررسی را حتی زمانی که نمونه دارای اطلاعات نویزی یا نابهنجار است، به درستی حدس بزند. تخمین مقادیر آتی متغیر مورد بررسی با توجه به مثال‌هایی از رفتار گذشته، در واقع قدرت تعمیم آنهاست.

ویژگی سوم شبکه‌های عصبی مصنوعی تقریب‌زننده‌های قوی توابع کلی⁵⁴ مسائل مورد بررسی است. شبکه‌ها در مقایسه با روش‌های آماری سنتی، برای حل مسائل از توابع کلی و انعطاف‌پذیر بسیار بیشتری استفاده می‌کنند. به علت پیچیدگی‌های سیستم‌های حقیقی، روش‌های آماری سنتی با محدودیت‌های زیادی در شناخت این روابط مواجه هستند. شبکه‌های عصبی گزینه‌ای مناسبی برای مواجهه با این محدودیت هستند (ژانگ و دیگران، 1998).

⁵⁰ Model Tree

⁵¹ Multivariate Nonlinear Nonparametric Statical Methods

⁵² Azoff

⁵³ El Shazly

⁵⁴ Universal Functional Approximators

ویژگی دیگر شبکه‌های عصبی مصنوعی غیرخطی بودن آنهاست. در روش‌های سنتی مطالعه‌ی سری‌های زمانی نظیر روش باکس جنکینز و *ARIMA* فرض بر این است که سری‌های زمانی مورد مطالعه به وسیله‌ی یک فرآیند خطی تولید می‌شوند (هوشمند و دیگران، 1387). از مزایای این روش‌های سنتی می‌توان به قابلیت تحلیل آنها با جزئیات زیاد، قدرت توضیح دهنده‌ی بالا و به کارگیری آسان اشاره کرد. اما ضعف اساسی این روش‌ها خطی بودن آنهاست. در دو دهه‌ی گذشته، چندین مدل سری زمانی غیرخطی گسترش و توسعه یافته است که از آن جمله می‌توان به مدل خطی دو گانه،⁵⁵ مدل خودرگرسیون آستانه‌ای⁵⁶ (*TAR*) و مدل خود رگرسیون واریانس ناهمسان شرطی⁵⁷ (*ARCH*) اشاره کرد. اما این مدل‌ها هنوز با محدودیت بزرگی مواجهند. در این مدل‌ها، از قبل و بدون اطلاع از قوانین اساسی حاکم بر ورودی‌ها و خروجی‌ها، فرض می‌شود که یک رابطه‌ی صریح برای یک سری زمانی وجود دارد. در واقع، فرمول‌بندی یک مدل غیرخطی برای یک مجموعه‌ی معین از داده‌ها فرض محدود کننده‌ای است؛ زیرا مدل‌های غیرخطی بسیار متعدد و متنوعی وجود دارند که ممکن است منشاء تولید داده‌ها باشند. شبکه‌های عصبی مصنوعی برخلاف روش‌های غیرخطی یاد شده یکی از روش‌های پیش بینی غیر خطی است که نیاز به پیش فرض در خصوص روابط میان ورودی‌ها و خروجی‌ها نیست.

10- مدل سازی

از آنجا که هدف اصلی این تحقیق مشاهده‌ی کارایی شبکه‌ی عصبی مصنوعی در بالا بردن توان پیش بینی است، لذا در این مرحله برای بررسی بهتر عملکرد مدل مورد نظر نتایج آنرا با مدل خطی *ARIMA* مقایسه می‌کنیم. از آنجا که در برخی از موارد منظم کردن داده‌ها، توانایی شبکه‌ی عصبی مصنوعی را برای پیش بینی بالا می‌برد، ورودی‌های شبکه در بازه [1 و -1] نرمال سازی می‌شوند. متغیرهای ورودی مدل‌های شبکه‌ی عصبی مصنوعی برای هر کدام از سری‌های تجزیه شده، وقفه‌های سری‌های مربوطه هستند. برای لایه‌ی

⁵⁵ Bilin Model

⁵⁶ Threshold Autoregressive Model

⁵⁷ Auto Regressive Conditional Heteroscedastic

پنهان شبکه از تابع محرکه تانژانت هایپربولیک و برای لایه‌ی خروجی آن از تابع خطی استفاده می‌شود. برای آزمون عملکرد مدل شبکه‌ی عصبی از نسبت داده‌های آموزش و آزمون به صورت 20-80، 15-85، 10-90 و 5-90 درصد در نظر گرفته می‌شود. هر کدام از نسبت‌ها که عملکرد بهتری از خود نشان دهد، به عنوان نسبت نهایی انتخاب می‌شود.

الگوریتم مورد استفاده لونیبرگ-مارکوات است؛ زیرا این الگوریتم سرعت بیشتری در مقایسه با دیگر الگوریتم‌های پس انتشار خطا دارد. در طراحی شبکه از یک لایه پنهان می‌شود؛ با این توجیه که یک شبکه‌ی عصبی مصنوعی با یک لایه‌ی پنهان یک تقریب زننده‌ی کلی است. تعداد نرون‌های هر لایه نیز با استفاده از برنامه‌ی نوشته شده برای پیش بینی به صورت بهینه توسط شبکه تعیین می‌شود. برای اطمینان از کفایت فرایند یادگیری از توقف فرآیند یادگیری به روش توقف زود هنگام⁵⁸ استفاده می‌شود. برای آزمون عملکرد شبکه از معیار عملکرد شبکه‌ی $RMSE$ استفاده می‌شود. هر شبکه که کمترین مقدار $RMSE$ را داشته باشد، به عنوان مدل بهینه انتخاب می‌شود و بر اساس آن تعداد لایه‌ها و نرون‌های شبکه تعیین می‌گردد.

11- پیش بینی توسط مدل شبکه‌ی عصبی مصنوعی

به منظور اطمینان از توانایی بالای روش‌های پیش بینی، دو نوع پیش بینی به صورت پیش بینی یک گام به جلو و پیش بینی چند گام به جلو (دو گام به جلو تا ده گام به جلو) انجام می‌گیرد.

مراحل پیش بینی توسط شبکه‌ی طراحی شده به صورت زیر است:

۱- سری زمانی داده‌ها شامل 1588 داده به صورت جداگانه وارد نرم افزار مطلب می‌شود.

2- شبکه‌ی عصبی مصنوعی با یک لایه‌ی پنهان و حداکثر 5 نرون پنهان و حداکثر 5 وقفه با الگوریتم لونیبرگ-مارکوات، تابع محرکه لایه‌ی پنهان تانژانت هایپربولیک و تابع محرکه‌ی لایه‌ی خروجی خطی با معیار عملکردش $RMSE$ برای پیش بینی نرخ ارز اجرا می‌شود.

⁵⁸ Early Stopping

۳- نسبت داده‌های آموزش به آزمون 20-80، 15-85، 10-90 و 5-90 درصد و نرخ یادگیری به صورت 0/1، 0/2 و 0/3 تعیین می‌شود تا از این طریق بهترین نسبت آموزش به آزمون و نرخ یادگیری به دست آید.

4- تعداد وقفه‌ها و نرون‌های بهینه‌ی مدل محاسبه می‌گردد.

5- سری زمانی مربوطه پیش بینی می‌گردد.

ریشه‌ی مجموع مربعات خطای هر نوع پیش بینی به صورت زیر محاسبه می‌گردد:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}} \quad (3)$$

که در آن \hat{y}_t پیش بینی نرخ ارز در دوره‌ی t ام و y_t نرخ واقعی ارز در دوره‌ی t ام است. n نیز تعداد دفعات پیش بینی‌ها است؛ به طوری که برای یک گام به جلو $n=1$ و برای دو گام به جلو $n=2$ و ... تعیین می‌شود. نتایج پیش‌بینی‌های انجام گرفته در جداول نشان داده شده است.

در این تحقیق از معیار آکائیک⁵⁹ برای انتخاب مدل بهینه استفاده شده است؛ زیرا این معیار زمانی که تعداد داده‌ها زیاد باشد، درجه‌ی آزادی زیادی از دست نمی‌دهد.

12- پیش بینی توسط مدل خطی *ARIMA*

مراحل پیش بینی توسط مدل *ARIMA* به صورت زیر است:

سری زمانی اختلاف نرخ ارز دو روز متوالی محاسبه می‌گردد.

1- مدل با حداکثر *ARMA(10,10)* محاسبه می‌گردد.

2- ارزش معیار آکائیک مدل فوق با توجه به داده‌های پیش گفته، محاسبه و مقادیر آن با هم مقایسه می‌گردد و مدل دارای کمترین مقدار آکائیک، انتخاب می‌گردد.

3- پیش بینی‌های یک گام به جلو تا ده گام به جلو انجام می‌گردد.

4- اولین پیش بینی تفاضل نرخ ارز با آخرین مقدار واقعی نرخ ارز جمع می‌شود تا اولین پیش بینی یا همان پیش بینی یک گام به جلو محاسبه گردد.

5- برای پیش بینی نرخ ارز در ماه اول تا ماه دهم، پیش بینی اختلاف نرخ ارز با اولین پیش بینی نرخ ارز جمع می‌گردد.

⁵⁹ Akaick Information Criterion

6- ریشه‌ی مجموع مربعات خطای نرمال به صورت زیر محاسبه می‌گردد:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}} \quad (4)$$

7- که در آن \hat{y}_t نشانگر نرخ ارز در دوره‌ی t ام و y_t نرخ واقعی ارز در دوره‌ی t ام است.

13- تجزیه و تحلیل نتایج پژوهش

برای هر نرخ ارز 10 پیش بینی به صورت یک گام به جلو تا ده گام به جلو توسط مدل‌های ANN و ARIMA انجام شده است. در این پیش بینی‌ها مدل‌های به عنوان مدل بهینه انتخاب شده است که کمترین RMSE را داشته باشد. نتایج این پیش بینی‌ها در جدول‌های 1 تا 10 نشان داده شده است.

جدول 1: نتایج پیش‌بینی دلار کانادا توسط مدل ANN و ARIMA

پیش بینی به صورت گام به جلو به تفکیک گام‌ها به جلو										شرح
ده گام	نه گام	هشت گام	هفت گام	شش گام	پنج گام	چهار گام	سه گام	دو گام	یک گام	
۷۷۵۷	۷۷۵۷	۷۷۱۴	۷۷۰۷	۷۸۲۷	۷۸۲۵	۷۸۲۵	۷۷۶۶	۷۷۶۰	۷۷۳۸	داده اصلی
۷۵۶۹	۷۶۱۲/۰	۷۶۵۰/۵	۷۶۸۵/۴	۷۷۱۷/۰	۷۷۴۵/۵	۷۷۷۱/۳	۷۷۹۴/۵	۷۸۱۵/۳	۷۸۳۴/۱	NN
۸۴۰۴	۸۴۰۳/۷	۸۴۰۲/۴	۸۴۰۱/۰	۸۴۰۲/۶	۸۴۰۲/۲	۸۴۰۱/۸	۸۴۰۱/۴	۸۴۰۱/۱	۸۴۰۰/۷	ARIMA

مأخذ: نتایج تحقیق

جدول 2: نتایج پیش‌بینی دلار کانادا توسط مدل ANN

NN (lr ^{۶۰} =۰/۲, trset ^{۶۱} =۰/۸۰)										شرح
ده گام	نه گام	هشت گام	هفت گام	شش گام	پنج گام	چهار گام	سه گام	دو گام	یک گام	
۵	۵	۵	۵	۵	۵	۵	۵	۵	۵	وقفه بهینه
۵	۵	۵	۵	۵	۵	۵	۵	۵	۵	نرون پنهان بهینه
۴/۷۰	۳/۶۴	۱/۵۹	۰/۵۴	۲/۷۶	۱/۹۹	۱/۳۵	۰/۷۲	۱/۳۹	۲/۴۱	RMSE

مأخذ: نتایج تحقیق

^{۶۰} نرخ یاد گیری بهینه

^{۶۱} مجموعه‌ی آزمایش بهینه

جدول 3: نتایج پیش‌بینی دلار کانادا توسط مدل *ARIMA*

ARIMA										شرح
ده گام	نه گام	هشت گام	هفت گام	شش گام	پنج گام	چهار گام	سه گام	دو گام	یک گام	
4	4	4	4	4	4	4	4	4	4	درجه <i>AR</i>
3	3	3	3	3	3	3	3	3	3	درجه <i>MA</i>
۱۶/۱۹	۱۶/۱۸	۱۷/۲۴	۱۷/۴۱	۱۴/۴۰	۱۴/۴۴	۱۴/۴۳	۱۵/۹۰	۱۶/۰۴	۱۶/۵۸	<i>RMSE</i>

مأخذ: نتایج تحقیق

در مدل شبکه‌ی عصبی تعداد وقفه‌ی بهینه، تعداد نرون بهینه، نرخ یادگیری، نسبت داده‌های آموزش به آزمون به ترتیب 5، 5، 0/2 و 0/80 است. درجه‌ی *AR* و *MA* مدل بهینه *ARIMA* به ترتیب 4 و 3 است. همان‌طور که در جدول مشاهده می‌شود، در تمام پیش‌بینی‌ها برای دلار کانادا، مدل شبکه‌ی عصبی مدل بهینه (دارای کمترین مقدار *RMSE*) است.

جدول 4: نتایج پیش‌بینی یورو توسط مدل‌های *ANN* و *ARIMA*

پیش‌بینی به صورت گام به جلو به تفکیک گام‌ها به جلو										شرح
ده گام	نه گام	هشت گام	هفت گام	شش گام	پنج گام	چهار گام	سه گام	دو گام	یک گام	
۱۲۳۲۱	۱۲۳۲۱	۱۲۳۵۷	۱۲۳۴۷	۱۲۳۹۰	۱۲۳۸۶	۱۲۳۸۶	۱۲۲۸۷	۱۲۴۲۲	۱۲۳۶۹	داده اصلی
۱۱۲۸۵	۱۱۴۲۰	۱۱۵۵۰	۱۱۶۷۲	۱۱۷۸۴	۱۱۸۸۸	۱۱۹۸۳	۱۲۰۷۲	۱۲۱۵۵	۱۲۲۳۳	<i>NN</i>
۱۳۰۷۲	۱۳۰۷۱	۱۳۰۶۹	۱۳۰۶۸	۱۳۰۶۶	۱۳۰۶۵	۱۳۰۶۳	۱۳۰۶۲	۱۳۰۶۰	۱۳۰۵۹	<i>ARIMA</i>

مأخذ: نتایج تحقیق

جدول 5: نتایج پیش‌بینی یورو توسط مدل *ANN*

<i>NN</i> (<i>lr</i> = 0/3, <i>trset</i> = 0/80)										شرح
ده گام	نه گام	هشت گام	هفت گام	شش گام	پنج گام	چهار گام	سه گام	دو گام	یک گام	
5	5	5	5	5	5	5	5	5	5	وقفه بهینه
5	5	5	5	5	5	5	5	5	5	نرون پنهان بهینه
۲۵/۹۸	۲۲/۵۸	۲۰/۲۳	۱۶/۹۳	۱۵/۱۸	۱۲/۴۸	۱۰/۰۹	۵/۳۹	۶/۶۹	۳/۳۹	<i>RMSE</i>

مأخذ: نتایج تحقیق

جدول 6: نتایج پیش‌بینی یورو توسط مدل ARIMA

ARIMA										شرح
یک گام	دو گام	سه گام	چهار گام	پنج گام	شش گام	هفت گام	هشت گام	نه گام	ده گام	
1	1	1	1	1	1	1	1	1	1	درجه AR
0	0	0	0	0	0	0	0	0	0	درجه MA
17/27	15/98	19/40	16/96	16/99	16/93	18/04	17/83	18/77	18/80	RMSE

مأخذ: نتایج تحقیق

در مدل شبکه‌ی عصبی تعداد وقفه‌ی بهینه، تعداد نرون بهینه، نرخ یادگیری، نسبت داده‌های آموزش به آزمون به ترتیب 5، 5، 0/2 و 0/80 است. درجه‌ی AR و MA مدل بهینه ARIMA به ترتیب 1 و صفر است. با توجه به نتایج حاصل شده برای یورو، پیش‌بینی یک گام به جلو تا هشت گام به جلو مدل NN و در پیش‌بینی هشت گام به جلو تا ده گام به جلو مدل ARIMA عملکرد بهتری دارد.

جدول 7: نتایج پیش‌بینی پوند توسط مدل‌های ANN و ARIMA

پیش‌بینی به صورت گام به جلو به تفکیک گام‌ها به جلو										شرح
یک گام	دو گام	سه گام	چهار گام	پنج گام	شش گام	هفت گام	هشت گام	نه گام	ده گام	
13682	13749	13825	14153	14153	14125	13888	13758	13759	13759	داده اصلی
14660	15201	15403	15610	15730	15705	15688	15676	15623	15583	NN
17267	17356	17346	17336	17326	17315	17305	17295	17284	17274	ARIMA

مأخذ: نتایج تحقیق

جدول 8: نتایج پیش‌بینی پوند توسط مدل ANN

NN (lr = 0/2, trset = 0/80)										شرح
یک گام	دو گام	سه گام	چهار گام	پنج گام	شش گام	هفت گام	هشت گام	نه گام	ده گام	
5	5	5	5	5	5	5	5	5	5	وقفه بهینه
5	5	5	5	5	5	5	5	5	5	نرون پنهان بهینه
24/54	36/43	39/59	36/57	39/58	39/64	45/16	48/13	46/78	45/77	RMSE

مأخذ: نتایج تحقیق

جدول 9: نتایج پیش‌بینی پوند توسط مدل *ARIMA*

ARIMA										شرح
یک گام	دو گام	سه گام	چهار گام	پنج گام	شش گام	هفت گام	هشت گام	نه گام	ده گام	
4	4	4	4	4	4	4	4	4	4	درجه <i>AR</i>
3	3	3	3	3	3	3	3	3	3	درجه <i>MA</i>
۹۲/۱۸	۹۰/۲۵	۸۸/۰۹	۷۹/۶۳	۷۹/۳۸	۷۹/۸۲	۸۵/۴۹	۸۸/۴۸	۸۸/۲۰	۸۷/۹۳	<i>RMSE</i>

مأخذ: نتایج تحقیق

در مدل شبکه‌ی عصبی تعداد وقفه‌ی بهینه، تعداد نرون بهینه، نرخ یادگیری، نسبت داده‌های آموزش به آزمون به ترتیب 5، 5، 0/2 و 0/80 است. درجه‌ی *AR* و *MA* مدل بهینه *ARIMA* به ترتیب 4 و 3 است. همان‌طور که در جدول مشاهده می‌شود، در تمام پیش‌بینی‌ها برای پوند، مدل شبکه‌ی عصبی مدل بهینه است (دارای کمترین مقدار *RMSE* است).

جدول 10: نتایج پیش‌بینی بین ژاپن توسط مدل *ANN* و *ARIMA*

پیش‌بینی به صورت گام به جلو به تفکیک گام‌ها به جلو										شرح
یک گام	دو گام	سه گام	چهار گام	پنج گام	شش گام	هفت گام	هشت گام	نه گام	ده گام	
۱۰۷۱۳	۱۰۶۶۹	۱۰۷۱۲	۱۰۴۰۸	۱۰۴۰۸	۱۰۴۶۲	۱۰۵۹۹	۱۰۶۲۵	۱۰۴۲۰	۱۰۴۲۰	داده اصلی
۱۰۷۴۶	۱۰۷۲۹	۱۰۷۲۳	۱۰۷۲۳	۱۰۷۲۰	۱۰۷۲۰	۱۰۷۲۰	۱۰۷۲۰	۱۰۷۲۰	۱۰۷۲۰	<i>NN</i>
۱۲۹۲۹	۱۲۹۳۱	۱۲۹۳۳	۱۲۹۳۵	۱۲۹۳۶	۱۲۹۳۸	۱۲۹۴۰	۱۲۹۴۲	۱۲۹۴۴	۱۲۹۴۵	<i>ARIMA</i>

مأخذ: نتایج تحقیق

جدول 11: نتایج پیش‌بینی بین ژاپن توسط مدل *ANN*

<i>NN</i> (<i>lr</i> = 0/2, <i>trset</i> = 0/80)										شرح
یک گام	دو گام	سه گام	چهار گام	پنج گام	شش گام	هفت گام	هشت گام	نه گام	ده گام	
۵	۵	۵	۵	۵	۵	۵	۵	۵	۵	وقفه بهینه
۵	۵	۵	۵	۵	۵	۵	۵	۵	۵	نرون پنهان بهینه
۰/۸۴	۱/۵۲	۰/۲۹	۷/۸۷	۷/۸۵	۶/۴۹	۳/۰۵	۲/۳۹	۷/۵۴	۷/۵۴	<i>RMSE</i>

مأخذ: نتایج تحقیق

جدول 12: نتایج پیش‌بینی بین ژاپن توسط مدل *ARIMA*

ARIMA										شرح
ده گام	نه گام	هشت گام	هفت گام	شش گام	پنج گام	چهار گام	سه گام	دو گام	یک گام	
۵	۵	۵	۵	۵	۵	۵	۵	۵	۵	درجه <i>AR</i>
۵	۵	۵	۵	۵	۵	۵	۵	۵	۵	درجه <i>MA</i>
۸۶/۱۹	۸۸/۱۹	۰۲/۲۵	۳۹/۲۴	۹۸/۲۰	۶۴/۱۹	۶۶/۱۹	۲۸/۲۷	۲۲/۲۶	۳۳/۲۷	<i>RMSE</i>

مأخذ: نتایج تحقیق

در مدل شبکه‌ی عصبی تعداد وقفه‌ی بهینه، تعداد نرون بهینه، نرخ یادگیری، نسبت داده‌های آموزش به آزمون به ترتیب 5، 5، 0/2 و 0/80 است. درجه‌ی *AR* و *MA* مدل بهینه *ARIMA* به ترتیب 5 و 5 است. همان‌طور که در جدول مشاهده می‌شود، در تمام پیش‌بینی‌ها برای این مدل شبکه‌ی عصبی مدل بهینه است (دارای کمترین مقدار *RMSE* است).

جدول 13: نتایج پیش‌بینی دلار آمریکا توسط مدل‌های *ANN* و *ARIMA*

پیش‌بینی به صورت گام به جلو به تفکیک گام‌ها به جلو										شرح
ده گام	نه گام	هشت گام	هفت گام	شش گام	پنج گام	چهار گام	سه گام	دو گام	یک گام	
۹۵۷۸	۹۵۷۸	۹۵۶۸	۹۵۷۹	۹۵۶۸	۹۵۶۹	۹۵۶۹	۹۵۷۴	۹۵۶۰	۹۶۰۹	داده اصلی
۹۶۱۵	۹۶۱۶	۹۶۱۷	۹۶۱۸	۹۶۲۰	۹۶۲۳	۹۶۲۷	۹۶۳۲	۹۶۴۱	۹۶۵۳	<i>NN</i>
۹۶۲۵	۹۶۲۵	۹۶۲۴	۹۶۲۴	۹۶۲۳	۹۶۲۲	۹۶۲۳	۹۶۲۱	۹۶۲۱	۹۶۲۰	<i>ARIMA</i>

مأخذ: نتایج تحقیق

جدول 14: نتایج پیش‌بینی دلار آمریکا توسط مدل *NN*

<i>NN</i> ($lr = 0.2$, $trset = 0.8$)										شرح
ده گام	نه گام	هشت گام	هفت گام	شش گام	پنج گام	چهار گام	سه گام	دو گام	یک گام	
۵	۵	۵	۵	۵	۵	۵	۵	۵	۵	وقفه بهینه
۵	۵	۵	۵	۵	۵	۵	۵	۵	۵	نرون پنهان بهینه
۰/۹۴	۰/۹۶	۱/۲۳	۰/۹۹	۱/۳۱	۱/۳۶	۱/۴۶	۱/۴۸	۲/۰۵	۱/۱۳	<i>RMSE</i>

مأخذ: نتایج تحقیق

جدول 15: نتایج پیش‌بینی دلار توسط مدل *ARIMA*

ARIMA										شرح
یک گام	دو گام	سه گام	چهار گام	پنج گام	شش گام	هفت گام	هشت گام	نه گام	ده گام	
5	5	5	5	5	5	5	5	5	5	درجه AR
5	5	5	5	5	5	5	5	5	5	درجه MA
۲۹/۰	۵۳/۱	۱۹/۱	۳۴/۱	۳۵/۱	۳۹/۱	۱۳/۱	۴۲/۱	۱۹/۱	۲۰/۱	RMSE

مأخذ: نتایج تحقیق

در مدل شبکه‌ی عصبی تعداد وقفه‌ی بهینه، تعداد نرون بهینه، نرخ یادگیری، نسبت داده‌های آموزش به آزمون به ترتیب 5، 5، 0/2 و 0/80 است. درجه‌ی *AR* و *MA* مدل بهینه‌ی *ARIMA* به ترتیب 4 و 3 است. با توجه به نتایج حاصل شده برای یورو، پیش‌بینی یک گام به جلو تا پنج گام به جلو مدل *ARIMA* و در پیش‌بینی پنج گام به جلو تا ده گام به جلو مدل *NN* عملکرد بهتری دارد.

همان‌طور که در جدول زیر مشاهده می‌شود، در پیش‌بینی‌ها، عمدتاً مدل شبکه‌ی عصبی بهینه بوده است. نکته‌ی مهمی که باید به آن توجه شود آن است که مدل خطی *ARIMA* فقط در 8 مورد عملکرد مناسب‌تری از مدل شبکه‌ی عصبی داشته است. این موارد پیش‌بینی یک گام به جلو تا پنج گام به جلوی دلار آمریکا و هشت گام به جلو تا ده گام به جلوی یورو است. به نظر می‌رسد که عدم برتری پیش‌بینی‌های شبکه‌ی عصبی در مقایسه با مدل *ARIMA* در موارد مذکور ناشی از محدودیت‌های فراوانی است که بانک مرکزی بر روی دلار و یورو اعمال می‌کند. چون بیشتر مبادلات تجاری ایران بر اساس یورو و دلار انجام می‌شود، در نتیجه نوسانات این ارزها می‌تواند تاثیر منفی بر اقتصاد ایران بگذارد. برای جلوگیری از نوسانات دولت این ارزها مدیریت می‌کند. این کنترل باعث کم شدن دامنه‌ی نوسانات آنها می‌شود. اگر دامنه‌ی نوسانات دلار و یورو نیز همانند دیگر ارزها وسیع باشد، به احتمال زیاد مدل خطی *ARIMA* نمی‌تواند نرخ آنها را به خوبی پیش‌بینی کند. به طور کلی، نتایج تحقیق نشان می‌دهد که مدل غیر خطی شبکه‌ی عصبی برای پیش‌بینی نرخ‌های ارز در مقایسه با مدل خطی *ARIMA* عملکرد بهتری دارد. این نتایج از فرضیه رفتار غیر خطی سری‌های زمانی ارز حمایت می‌کند.

جدول 16: مدل‌های بهینه برای پیش بینی‌های مختلف

ARIMA		NN		مدل پیش بینی
ارز	فراوانی	ارز	فراوانی	
دلار آمریکا	1	پوند، یورو، ین، دلار کانادا، دلار آمریکا	4	یک گام به جلو
دلار آمریکا	1	پوند، یورو، ین، دلار کانادا	4	دو گام به جلو
دلار آمریکا	1	پوند، یورو، ین، دلار کانادا	4	سه گام به جلو
دلار آمریکا	1	پوند، یورو، ین، دلار کانادا	4	چهار گام به جلو
دلار آمریکا	1	پوند، یورو، ین، دلار کانادا	4	پنج گام به جلو
	0	پوند، یورو، ین، دلار کانادا، دلار آمریکا	5	شش گام به جلو
	0	پوند، یورو، ین، دلار کانادا، دلار آمریکا	5	هفت گام به جلو
یورو	1	پوند، ین، دلار کانادا، دلار آمریکا	4	هشت گام به جلو
یورو	1	پوند، یورو، ین، دلار کانادا، دلار آمریکا	4	نه گام به جلو
یورو	1	پوند، ین، دلار کانادا، دلار آمریکا	4	ده گام به جلو

مأخذ: نتایج تحقیق

14- جمع بندی و نتیجه گیری

در سال‌های اخیر روش شبکه‌ی عصبی مصنوعی به عنوان رقیبی برای روش‌های سنتی آماری ظهور کرده است. این شبکه‌ها مبتنی بر شبیه‌سازی‌های کامپیوتری از نرون‌های عصبی هستند و با استفاده از یک پایه‌ی ریاضیاتی عملیات خود را انجام می‌دهند. شبکه‌های عصبی مصنوعی به طور گسترده‌ای در زمینه‌های مختلف تجاری و صنعتی به کار گرفته می‌شوند و دارای قابلیت‌های زیادی هستند. در این مقاله پنج نرخ ارز را با استفاده از دو مدل شبکه‌های عصبی مصنوعی و *ARIMA* نرخ روزانه‌ی ارز در دوره‌ی مارس 2006 تا فوریه 2009 پیش بینی شده است. شبکه‌ی عصبی مصنوعی بهینه دارای یک لایه‌ی پنهان، حداکثر 5 نرون پنهان، حداکثر 5 وقفه با الگوریتم لورنبرگ - مارکوات است. همچنین، تابع محرکه‌ی لایه‌ی خروجی خطی و معیار آزمون عملکرد شبکه‌ی *RMSE* است. به طور کلی، نتایج تحقیق نشان می‌دهد که مدل غیر خطی شبکه‌ی عصبی برای پیش بینی نرخ‌های ارز در مقایسه با مدل خطی *ARIMA* عملکرد بهتری دارد و مدل خطی *ARIMA* فقط در 8 مورد عملکرد مناسب‌تری از مدل شبکه‌ی عصبی داشته است. به نظر می‌رسد که عدم برتری پیش بینی‌های شبکه‌ی عصبی در

مقایسه با مدل *ARIMA* در موارد مذکور ناشی از محدودیت‌های فراوانی است که بانک مرکزی بر روی دلار و یورو اعمال می‌کند. این نتایج از فرضیه‌ی رفتار غیر خطی سری‌های زمانی ارز حمایت می‌کند.

فهرست منابع:

- آلفرد، مرتینر. (1380). آنالیز سیگنال: ویولت، فیلتر بانک، تبدیل‌های زمان - فرکانس و کاربرد آنها. ترجمه‌ی دکتر محمد حسن مرادی. تهران: مرکز نشر دانشگاه صنعتی امیر کبیر.
- اصغری اسکویی، محمد رضا. (1381). کاربرد شبکه‌های عصبی در پیش بینی سری‌های زمانی. پژوهشنامه اقتصادی ایران، 12: 69-97.
- زراءنژاد، منصور و شهرام حمید. (1388). پیش بینی نرخ تورم در اقتصاد ایران با استفاده از شبکه‌های عصبی مصنوعی پویا (دیدگاه سری زمانی). اقتصاد مقداری، 6(1): 176-155.
- قدیمی، محمد رضا و سعید مشیری. (1381). پیش بینی رشد اقتصادی ایران با استفاده از شبکه‌های عصبی مصنوعی. پژوهشنامه اقتصادی ایران، 12: 96-123.
- منه‌اج، محمد باقر. (1377). هوش محاسبات، جلد اول، مبانی شبکه‌های عصبی. تهران: مرکز نشر پروفسور حسابی.
- هوشمند، محمود، محمد علی شعبانی و اعظم ذبیحی. (1387). نقش سرمایه انسانی در رشد اقتصادی ایران با استفاده از الگوی خود بازگشت با وقفه‌های توزیعی. اقتصاد مقداری (بررسی‌های اقتصادی سابق)، 5 (2): 84-63.

Azoff, M.E. (1994). Neural Network Time Series Forecasting of Financial Markets. John Wiley & Sons, 117-125.

Bosarge, W.E. (1999). Adaptive Process to Exploit the Nonlinear Structure of Financial Market, In R. R. Trippi and Troban(eds), Neural Networks in Finance and investing. Probus Publishing, 371-402.

El Shazly, M.R. & H. E. El Shazly. (1999). Forecasting Currency Prices using a Genetically Evolved Neural Network Architecture. International Review of Financial Analysis, 8(1): 67-72.

Fu, J. (1998). A Neural Network Forecast of Economic Growth and Recession. The Journal of Economics, XXIV(1): 51-66.

Hill, T., L. Marquez, M. O'Connor & W. Remus. (1994). Artificial Neural Network Models for Forecasting and Decision Making. International Journal of Forecasting, 10: 5-15.

Hornik, K. (1991). Approximation Capabilities of Multilayer Feedforward Networks. Neural Networks, 4: 251-257.

Kingdon, J. & K. Feldman. (1995). Genetic Algorithms and some Applications in Finance. Journal of Applied and Mathematical Finance, 1(1): 89-116.

- Kohzadi, N., M.S. Boy & I. kaastra. (1996). Neural Networks for Forecasting: An Introduction. *Canadian Journal of Agricultural economics*, 43: 463-474.
- Kung, C. M. & H. White. (1994). Artificial Neural Networks for Some Macroeconomic series: A First Repot. *Econometric Reviews*, 13: 105-122.
- Moshiri, S. & N.E. Cameron. (2000). Neural Network Versus Econometric Models in Forecasting Inflation. *Journal of Forecasting*, 19: 201-217.
- Moshiri, S., N. E. Cameron & D. Scuse. (1999). Static, Dynamic, and Hybrid Neural Network in Forecasting Inflation. *Computational Economics*, 14(3): 219-235.
- Ramsey, B.J. (2002) Wavelets in Economics and Finance: Past and Future. *Studies in Non-Linear Dynamics and Econometrics*, 6(3): 1-26 .
- Zhang, G., B.E. Patuwo & M. Y. Hu. (1998). Forecasting with Artificial Neural Networks: The State of the Art. *International Journal of Forecasting*, 14(1): 35-62.
- Zhang, X. & K. Thearling. (1994). Non-liner Time-series Prediction by Systematic Data Exploration on a Massively Parallel computer. Santa Fe Institute Technical Report, 94-107.