



پیش بینی روزانه نرخ جفت ارز پوند/دلار در بازار فارکس با استفاده از شبکه عصبی

پیمان بهرام پور، نیکبخش جوادیان*

چکیده:

کلمات کلیدی

در این مقاله به پیش بینی نرخ جفت ارز $\frac{\text{دلار}}{\text{پوند}}$ در بازار فارکس با استفاده از شبکه عصبی و مدل ARIMA می پردازیم. برای این منظور ابتدا یک مدل ARIMA برای نرخ جفت ارز $\frac{\text{دلار}}{\text{پوند}}$ که از بانک مرکزی تهیه شده ارائه می دهیم و با دو روش تجزیه و تحلیل باقیمانده ها و روش *overfit* به بررسی مناسبت مدل می پردازیم، سپس با استفاده از آزمون بعد همبستگی وجود اشوب را در سری زمانی جفت ارز تایید کرده و یک مدل شبکه عصبی برای پیش بینی نرخ جفت ارز ارائه می دهیم و نتایج حاصل از دو مدل را مقایسه می کنیم.

آشوب،
شبکه های عصبی مصنوعی،
نرخ جفت ارز $\frac{\text{دلار}}{\text{پوند}}$
مدل ARIMA،
مدل های غیر خطی

۱. مقدمه

بنابراین پیش بینی نرخ ارز تصمیم گیری بنگاه را به منظور کسب منفعت بیشتر تحت تاثیر قرار می دهد. دسته سوم سفته بازان بازار ارز (فارکس) هستند، این بازار بیست و چهار ساعت در شبانه روز و هفت روز در هفته فعال است. سفته بازان مشتاق ترین علاقه مندان به به پیش بینی نرخ ارز هستند. دو رویکرد نسبت به پیش بینی نرخ جفت ارز وجود دارد. اول رویکرد بنیادی است که پیش بینی نرخ ارز را بر اساس دیگر متغیرهای اقتصادی انجام می دهد. دوم رویکرد تکنیکال است که فقط از رفتار گذشته نرخ ارز برای پیش بینی روند آتی آن استفاده می کند و به دلیل عدم توجه به دیگر متغیرهای اقتصادی، به رویکرد تکنیکال شهرت یافته. علت توسعه مدل های تکنیکال، ناتوانی مدل های بنیادی در توضیح و پیش بینی نرخ ارز در کوتاه مدت است.

نرخ ارز یک متغیر اقتصادی است که پیش بینی آن مورد علاقه بسیاری از فعالان اقتصادی است. این علاقه مندان را می توان به سه دسته تقسیم کرد [۱] دسته اول سیاست گذاران اقتصادی و بانک های مرکزی هستند که تحت یک نظام ارزی شناور مدیریت شده بانک های مرکزی بر مبنایی مشخص به منظور هموار سازی تلاطمات بازار، در بازار ارز مداخله می کنند. دلایل آنها برای این مداخله می تواند شامل بیش از حد معمول بودن تلاطمات و نتیجه اثر منفی آن بر فعالیتهای اقتصادی باشد. بنابراین داشتن پیش بینی از نرخ ارز لازمه داشتن چنین مداخله ای است. دسته دوم، بنگاه های فعال در تجارت و سرمایه گذاری های بین المللی هستند. جهانی شدن اقتصاد موجب گسترش بازارها و متنوع تر شدن بوی تفولیوی سرمایه گذاری ها شده است. از مهمترین ریسک های مرتبط با این فعالیتهای، ریسک ارز است. تغییرات نرخ ارز، درآمد، هزینه و سود را دچار تغییر می کند.

از جمله روش های تکنیکال، روش شبکه عصبی مصنوعی است که در این مقاله برای پیش بینی روزانه نرخ جفت ارز $\frac{\text{دلار}}{\text{پوند}}$ استفاده شده است. در این مقاله ابتدا شرح مختصری در مورد سابقه تحقیق ارائه خواهد شد سپس ساختار سیستم مولد نرخ جفت ارز $\frac{\text{دلار}}{\text{پوند}}$ بررسی و مدلی برای پیش بینی آن ارائه می شود. در بخش چهارم آزمون اشوب و در بخش پنجم یک مدل شبکه عصبی و مقایسه آن با مدل

تاریخ وصول: ۹۰/۰۸/۲۶

تاریخ تصویب: ۹۲/۰۲/۰۴

پیمان بهرام پور، کارشناس ارشد مهندسی صنایع، دانشکده مهندسی صنایع، دانشگاه علوم و فنون مازندران،
Peyman.bahrampour@gmail.com

* نویسنده مسئول مقاله: نیکبخش جوادیان، استاد مهندسی صنایع، دانشکده مهندسی صنایع، دانشگاه علوم و فنون مازندران
Nijavadian@ustmb.ac.ir

پیش بینی نرخ‌های ارز دلار استرالیا، فرانک سوییس، مارک آلمان، پوند بریتانیا و ین ژاپن در مقابل دلار آمریکا عملکرد بهتری دارند. مطالعه دیویس و اپیسکوپوس [8] (۲۰۰۱)، نشان می‌دهند که شبکه‌های عصبی مشابه EGARCH هستند، اما عملکرد آن‌ها از مدل‌های گام تصادفی از نظر پیش بینی برون نمونه ای بهتر است. دنیس و ویلیامز [9] (۲۰۰۲)، نیز عملکرد بهتری نسبت به ARMA گزارش کرده اند. کی و وو [10] (۲۰۰۳)، گزارش کردند که شبکه به طور معناداری بهتر از گام تصادفی نیست. مطالعه وی و همکاران (۲۰۰۴) نشان می‌دهد که عملکرد شبکه‌های عصبی بهتر از الگوهای $AR(p)$, $ARIMA(p,d,q)$, $ARMA(p,q)$ اتک (۲۰۰۶) یک مدل شبکه عصبی برای پیش بینی شاخص‌های اقتصادی در ترکیه ارائه داد و آن را با روش‌های کلاسیک پیش بینی مقایسه کرد که برتری مدل تلفیق نسبت به مدل‌های ANN, ARIMA گزارش شد. محمد تقی صمدی [11] (۲۰۱۲) با استفاده از تحلیل غیر پارامتری، تغییر در برخی از بانک‌های خصوصی را مورد بررسی قرار داد. رعنا یاسر حسین و همکاران [12] (۲۰۱۲) وابستگی متقابل بین بورس اوراق بهادار آسیای شرقی در رابطه با بورس اوراق بهادار کراچی را مورد بررسی قرار دادند. محمد تقی عاملی و همکاران [13].

(۲۰۱۲) با رویکردی جدید در تلفیق مدل‌های HSA و PNN_S به حل مساله TNPE که خود یک مساله بهینه سازی است پرداختند.

۳. داده‌ها و ویژگی‌های سری زمانی

داده‌های مورد استفاده در این پژوهش قیمت روزانه جفت ارز $\frac{\text{دلار}}{\text{پوند}}$ از تیر ماه ۱۳۸۹ تا آخر بهمن ماه ۱۳۸۹ است که در مجموع ۲۴۳ مشاهده را در بر می‌گیرد نمودار (۱) روند و نمودار (۲) خود همبستگی نرخ جفت را در بر می‌گیرد.

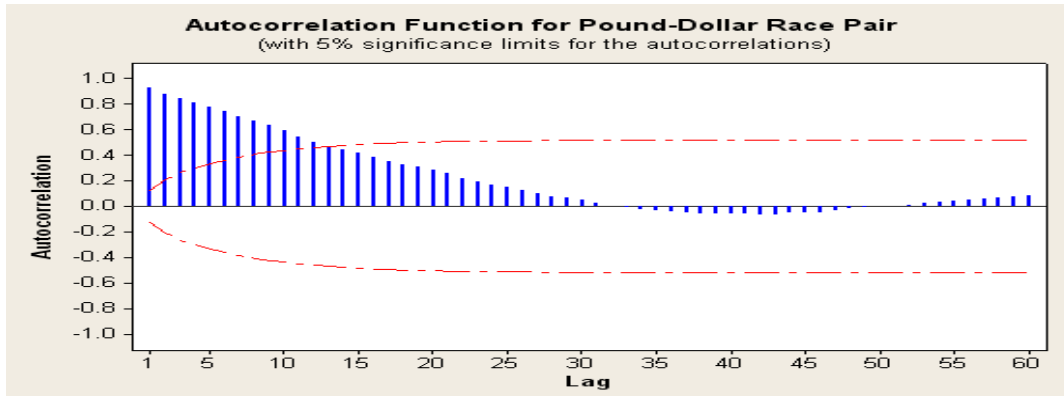
ARIMA ارائه می‌شود. نتیجه گیری بخش پایانی مقاله خواهد بود.

۲. سابقه علمی

درباره عملکردهای شبکه عصبی در پیش بینی نرخ ارز در مقایسه با روش‌های دیگر گزارش‌های متفاوتی ارائه شده است. ویچند و همکاران [1] (۱۹۹۲) دریافتند که شبکه عصبی در پیش بینی نرخ مبادله دلار آمریکا در مقابل مارک آلمان بهتر از گام‌های تصادفی عمل می‌کند. کو ان و لیو [2] (۱۹۹۵) قابلیت پیش بینی برون نمونه ای شبکه‌های عصبی برای نرخ برابری پنج ارز پوند، دلار کانادا، مارک آلمان، ین ژاپن و فرانک سوییس در مقابل دلار آمریکا را بررسی کردند. آن‌ها نشان دادند که برای پوند و ین شبکه‌های عصبی در مقابله با روش گام تصادفی دارای RSME کمتری برای پیش بینی برون نمونه ای هستند، ولی برای سه ارز دیگر شبکه‌های عصبی عملکرد بهتری برای پیش بینی ندارند. هان و استور [3] (۱۹۹۶) مدل‌های شبکه عصبی را با مدل‌های پولی خطی برای پیش بینی نرخ مبادله مارک آلمان در مقابل دلار آمریکا مقایسه کردند و نشان دادند که برای داده‌های هفتگی مدل‌های شبکه عصبی بهترند اما بر اساس داده‌های ماهانه، شبکه عصبی بهتر از مدل‌های خطی نیستند. لیسو و شیائو [4] (۱۹۹۹) شبکه عصبی را با مدل‌های آشوب مقایسه می‌کنند و نتیجه می‌گیرند که مدل‌های شبکه عصبی از نظر معیار $RMSE$ بهتر از مدل‌های آشوب هستند. هو و توکالاس [5] (۱۹۹۹)، عملکرد شبکه‌های عصبی را با روش‌های دیگر پیش بینی مقایسه کرده اند، در مطالعه آن‌ها استفاده از روش‌های ارزیابی متفاوت به نتایج مختلف منجر شده است. جنکی [6] (۱۹۹۹) نشان داده است که عملکرد شبکه بهتر از $GARCH(1,1)$ و گام تصادفی است. یاو و تان [7] (۲۰۰۰) نشان می‌دهند که صرف نظر از معیارهای ارزیابی (گرادین، سودآوری) مدل‌های شبکه عصبی از مدل‌های سنتی برای



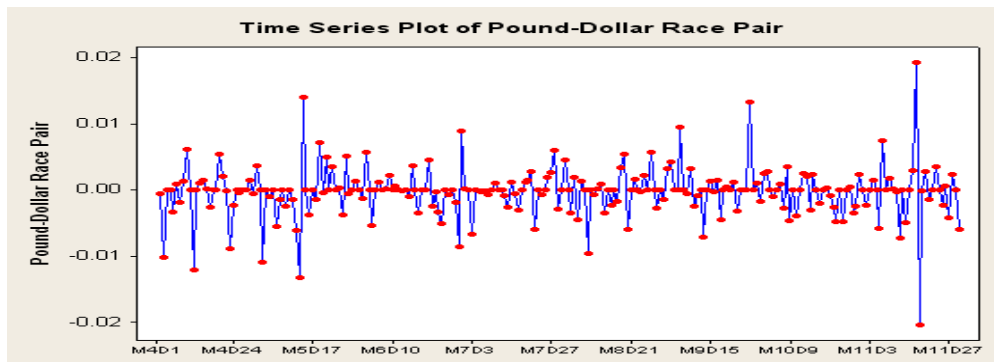
نمودار ۱. روند نرخ جفت ارز




نمودار ۲. خودهمبستگی نرخ جفت ارز

معرفی شده است می توان استفاده کرد که در ان λ را پارامتر تبدیل می نامند. برای پارامتر تبدیل λ برآورد حدود ۹۵ درصد و بهترین مقدار پیشنهاد شده ۳.۶۶ است. برای حصول ایستایی در میانگین ان را یکبار تفاضلی می کنیم. نمودار (۳) سری تفاضلی شده و نمودار (۴) خود همبستگی نرخ جفت ارز بعد از تفاضل گیری را نشان می دهند.

با توجه به نمودار سری زمانی و اینکه مقادیر خود همبستگی بسیار کند به سمت صفر میل می کنند، می توان نایستایی در میانگین را پذیرفت بنابراین برای حصول ایستایی در میانگین باید آن را یک بار تفاضلی کنیم. اما قبل از هر گونه تبدیلی به منظور پایا کردن میانگین باید از پایایی واریانس ان مطمئن شویم، به این منظور از تبدیل $T(X_t) = \frac{X_t^2 - 1}{\lambda}$ که به وسیله باکس - کاکس (۱۹۶۴)



نمودار ۳. سری تفاضلی شده



نمودار ۴. خود همبستگی نرخ جفت ارز بعد از تفاضل گیری

یک مدل $ARIMA(p, d, q)$ در حالت کلی به صورت زیر نشان داده می شود.

$$\phi(B) = (1 - B)^d X_t + \theta_0 + \theta_q(B)Z_t \quad (1)$$

نمودارهای فوق ایستایی در میانگین را نشان میدند.

۳-۱- برآورد مدل ARIMA

تشخیص اشوب در سری زمانی به دو دلیل دارای اهمیت است: اول اینکه سیستم اشوبناک به رفتار پیچیده می انجامد که به نظر تصادفی می رسد، حال آنکه تصادفی نیست. دیگر اینکه، چون اشوب از یک سیستم معین و غیر خطی پدید آمده، این خصوصیت آن را به طور کامل از سیستم‌های تصادفی متمایز می کند.

در ادامه به بررسی وجود فرایند اشوبناک در سیستم مولد نرخ جفت ارز خواهیم پرداخت، برای این منظور از آزمون بعد همبستگی استفاده خواهیم کرد.

۴-۱. تخمین بعد همبستگی [۳]

گراسبرگر و پرو کاچا (۱۹۸۳) الگوریتم بعد همبستگی را برای جستجوی رفتار اشوبناک پیشنهاد کردند. این الگوریتم، بعد سیستم مولد داده‌ها را تخمین می زند. کار تحلیل سری زمانی، با سری یک بعدی به صورت $\{X_t\}_{t=1}^T$ شروع می شود که می توان آن را با ابعاد $m \times T$ به شکل زیر تبدیل کرد.

$$X_t = (x_t, x_{t-1}, \dots, x_{t-m+1})^{Transpose}$$

m را embedding dimension می نامند. هر ردیف از ماتریس X_t یک بردار m تایی (یک نقطه در فضای m - بعدی) است. تعداد این نقاط در فضای فاز از رابطه $N = T - m + 1$ بدست می آید.

اگر $\{x_t : t = 1, \dots, T\}$ یک نمونه تصادفی از متغیرهایی باشد که مستقل از یکدیگر و دارای توزیع احتمال یکسان باشند، آنگاه به ازای مقادیر مشخص m و ε خواهیم داشت:

$$C_m(\varepsilon) = C_1(\varepsilon)^m \quad (4)$$

$$C_m = \frac{\lim_{T \rightarrow \infty} \{ \text{The number of } (i, j) \text{ for witch } |X_i^m - X_j^m| \leq \varepsilon \}}{T^2}$$

$C_m(\varepsilon)$ همبستگی جمعی یا تعداد نقاط موجود در فضای m است که فاصله ای کمتر از مقدار کوچک و معین ε از یکدیگر دارند. اگر سری زمانی از یک فرایند تصادفی نتیجه شده باشد، با افزایش embedding dimension نقاط موجود در فضای حالت m بعدی، در تمام جهات پراکنده خواهد شد ولی اگر سری از فرایند معین نتیجه شده باشد، نقاط به سمت زیر مجموعه از فضای حالت جذب می شوند. بعد همبستگی طبق رابطه زیر بدست می آید.

$$D^m = \lim_{\varepsilon \rightarrow \infty} \frac{\text{Log } C_m}{\text{Log } \varepsilon} \quad (5)$$

که در آن $\phi(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$ عملگر AR (مانا) و $\theta_q(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$ عملگر MA (وارون پذیر) ریشه مشترک ندارند. پارامتر θ_0 برای $d = 0$ و $d > 0$ نقش‌های بسیار متفاوتی را ایفا می کند. اگر $d = 0$ فرایند اولیه ماناست (پایا در میانگین و واریانس) و θ_0 به میانگین فرایند وابسته است، یعنی $\theta_0 = \mu(1 - \phi_1 - \dots - \phi_p)$ که در آن μ میانگین فرایند است. معهذاً وقتی $d \geq 1$ ، θ_0 جمله روند قطعی می نامند و اغلب آن را از الگو حذف می کنند مگر اینکه واقعاً لازم باشد [۱]. در این مطالعه با به کار گیری روش باکس - جنکینز، مدل $ARIMA(2,1,0)$ برای پیش بینی نرخ جفت ارز $\frac{\text{دلار}}{\text{پوند}}$ انتخاب شده است.

$$W_t = \frac{X_t^{3.66} - 1}{3.66} \quad (2)$$

جدول ۱. برآورد مدل $ARIMA(2,1,0)$ برای نرخ جفت ارز

پوند/دلار

$W_t = \alpha_1 W_{t-1} + \alpha_2 W_{t-2} + \alpha_3 W_{t-3} + \theta_0 + Z_t$			
Parameters	α_1	α_2	θ_0
Coef	-0.2087	-0.1535	-0.0003349
SE Coef	0.0642	0.0642	0.0002408
T	-3.25	-2.39	-1.39
P - Value	0.001	0.018	0.166

۴. آشوب [۲]

یک فرایند اشوبناک، فرایندی پویا، غیر خطی و معین است، در حالی که خروجی آن ظاهری کاملاً پیچیده و تصادفی دارد. با توجه به تعریف (Brock) سری زمانی $\{a_t\}$ یک سری معین اشوبناک خواهد بود، اگر سیستم مولدی به صورت (h, F, X) داشته باشد به طوری که h تابعی باشد که R^n را به R می نگارد ($h: R^n \rightarrow R$ که در آن n بعد سیستم اصلی، R مجموعه اعداد حقیقی است) و F تابعی باشد که R^n را به R^n می نگارد (به عبارت بهتر، F همان بیان ریاضی مدل مفروض است) و روابط زیر برقرارند.

$$a_t = h(X_t) \quad (3)$$

$$X_t = F(X_{t-1})$$

که در آن X_0 شرایط اولیه سیستم در $t = 0$ است.

ϵ ، مقادیر موجود در جدول (۲)، به سمت بی نهایت نمی رود (بزرگتر نمی شود)، و به ازای مقادیر مشخص ϵ ، با افزایش m از تعداد نقاطی که در فضای حالت فاصله ای کمتر از ϵ دارند، کاسته می شود (جدول (۳)) و همچنین با توجه به وجود ساختار غیر خطی در مشاهدات، می توان فرض وجود ساختار معین (غیر تصادفی) واشویی را در سری زمانی نرخ جفت ارز تایید کرد. از این رو انتظار داریم که الگوی پیش بینی شبکه عصبی جواب بهتری نسبت به الگوهای $ARIMA$ داشته باشد.

در یک سیستم اشوبناک به ازای مقادیر مشخص ϵ ، با افزایش m از تعداد نقاطی که در فضای حالت فاصله ای کمتر از ϵ کاسته شده، در حالی که در یک سیستم تصادفی، با افزایش m و کاهش ϵ ، D^m کاهش می یابد.

حال به بررسی بعد همبستگی نرخ جفت ارز خواهیم پرداخت. ابتدا برنامه آزمون بعد همبستگی توسط برنامه متلب نوشته شد و سپس با استفاده از آن، اماره آزمون به ازای m و ϵ های مختلف محاسبه گردید، با توجه به اینکه به ازای افزایش m و کاهش

جدول ۲. مقادیر D^m به ازای m و ϵ های مختلف

ϵ	m	10	15	20	25	30	35	40	45	50	55	60
10^{-2}		0.804	1.045	1.169	1.210	1.220	1.230	1.233	1.236	1.241	1.242	1.251
10^{-4}		0.600	0.602	0.603	0.605	0.607	0.610	0.612	0.618	0.620	0.623	0.626
10^{-6}		0.400	0.401	0.403	0.405	0.406	0.408	0.410	0.412	0.413	0.415	0.417
10^{-8}		0.300	0.301	0.302	0.303	0.305	0.306	0.307	0.309	0.310	0.311	0.313
10^{-10}		0.240	0.241	0.242	0.243	0.244	0.245	0.246	0.247	0.248	0.249	0.250
10^{-12}		0.200	0.200	0.201	0.202	0.203	0.204	0.205	0.206	0.206	0.207	0.208
10^{-14}		0.171	0.1722	0.1729	0.173	0.174	0.175	0.175	0.176	0.177	0.178	0.179
10^{-16}		0.150	0.150	0.1513	0.1519	0.152	0.1531	0.1538	0.1551	0.1552	0.1559	0.156
10^{-18}		0.1339	0.1339	0.134	0.1350	0.1356	0.1361	0.1367	0.1373	0.1379	0.138	0.139
10^{-20}		0.1201	0.1205	0.1210	0.1215	0.1220	0.1225	0.1230	0.1236	0.1241	0.1247	0.125
10^{-22}		0.1108	0.11091	0.1096	0.1100	0.1104	0.1109	0.1114	0.1118	0.1128	0.1133	0.1139

جدول ۳. تعداد نقاط موجود در فضای حالت به ازای m و ϵ های مختلف

ϵ	m	10	15	20	25	30	35	40	45	50	55	60	70	80	90	100
10^{-2}		1454	479	270	221	214	209	204	199	194	189	184	174	164	154	144
10^{-4}		234	229	224	219	214	209	204	199	194	189	184	174	164	154	144
10^{-8}		234	229	224	219	214	209	204	199	194	189	184	174	164	154	144
10^{-16}		234	229	224	219	214	209	204	199	194	189	184	174	164	154	144

را با استفاده از ابزارهای ریاضی درک کرده و تفسیر نمایند. ایشان شبکه‌های عصبی خود را به منظور مدل سازی عملگرها یا اپراتورهای منطقی به کار گرفتند. در اواخر قرن بیستم، روزنبلات مفهوم پرسپترون را معرفی نمود. اساسا پرسپترون به عنوان یک الگوی طبقه بندی کننده عمل می کند و یک مدل پیشرفته از سلول‌های عصبی است که توسط پیک و مک کولچ توسعه داده

۵. شبکه عصبی

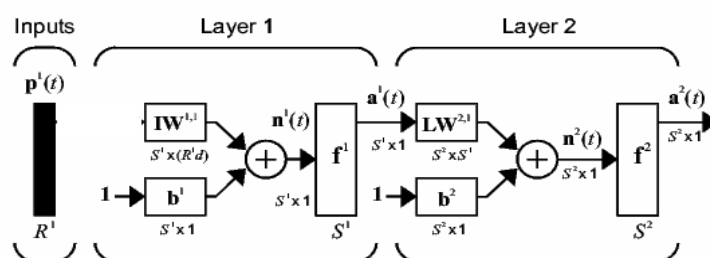
۵-۱. تاریخچه شبکه عصبی

پیک و مک کولچ بر روی شبکه‌های عصبی کار کرده اند و آن را در سال ۱۹۴۳ منتشر نمودند که هنوز هم پایه و اساس نظریه شبکه‌های عصبی است. آنها سعی نمودند تا کار کرد و وظیفه مغز

الگوریتم یادگیری به عنوان پر قدرت ترین الگوریتم یادگیری برای آموزش پرسپترون‌های چند لایه شناخته شده است.

۲-۵. ساختار شبکه‌های عصبی چند لایه پیش خور (MFNN)

ساختار MFNN که در شکل (۱) نشان داده شده است، متشکل از یک لایه ورودی، یک لایه خروجی عصب و حداقل یک لایه عصب‌های پنهان موجود بین ورودی‌ها و عصب‌های خروجی است. جریان اطلاعات از چپ به راست است، به طوری که ورودی‌ها از طریق اتصال وزن‌ها به لایه پنهان عصب‌ها و متعاقباً به لایه خروجی عبور می‌کنند. [۴]



شکل ۱. شبکه عصبی چند لایه

یک تابع پیچیده است که به میزان بزرگی ورودی شبکه بستگی دارد. به عنوان مثال، تابع پیچیده (فعال سازی) می‌تواند یک تابع لجستیک (سیگموئید) به صورت $f(net) = \frac{1}{1 + e^{-\lambda \cdot net}}$ باشد که در آن پارامتر مورد استفاده برای کنترل شیب تابع است. گام ۳: وزن‌ها را در لایه خروجی به روز کنید.

$$w_{ij} = w_{ij \text{ current}} + \Delta w_{ij}$$

$$\Delta w_{ij} = \delta_j (\text{output}_i) \quad (7)$$

$$\delta_j = \begin{cases} \text{output}_j (1 - \text{output}_j) (\text{actual}_j - \text{output}_j) & \text{for output layer nodes} \\ \sum_{\text{DownStream}} \text{output}_j (1 - \text{output}_j) w_{jk} \delta_k & \text{for hidden layer nodes} \end{cases} \quad (8)$$

۴-۵. محاسبه کارایی شبکه

برای مقایسه شبکه‌های عصبی مختلف با ویژگی‌های متفاوت لازم است از شاخصی استفاده شود. شاخص رایج در شبکه عصبی

شده است. با توجه به تعداد سلول‌های عصبی به هم پیوسته، پرسپترون، مسایل طبقه بندی را با دسته‌های متفاوتی حل می‌کند. در سال ۱۹۸۲ کوهونن یک طرح خود سازمان دهنده را معرفی نمود. SOM از یک الگوریتم یادگیری بدون نظارت برای کاربردهایی مانند استخراج داده‌ها و پردازش تصاویر استفاده می‌کند. در همان سال هاپفیلد، پلی بین محاسبات عصبی و فیزیک ایجاد نمود. یک شبکه هاپفیلد (که شامل نقاط اتصال رشته‌های عصبی به صورت متقارن و چندین حلقه باز خور می‌باشد) توسط مقادیر تصادفی، مقدار دهی می‌شود و سرانجام به حالت پایانی پایدار می‌رسد. با کشف الگوریتم پس انتشار در سال ۱۹۸۶، شبکه‌های عصبی، بسیار مهم جلوه نمود. در بوس در سال ۱۹۷۴، الگوریتم پس انتشار خطا را در پایان نامه دکترای خود ارائه نمود، این

۳-۵. الگوریتم یادگیرنده پس انتشار [۵]

گام ۱: یک الگوی ورودی تصادفی انتخاب کنید و از طریق لایه ورودی به MFNN ارائه دهید.
گام ۲: ورودی‌ها و خروجی‌های هر لایه را محاسبه کنید.

$$net_j^h = \sum_{i=1}^{N+1} w_j x_i \quad (6)$$

$$x_j = f(net_j^h)$$

$$\Delta w_{\text{current}} = -\eta \frac{\partial SSE}{\partial w_{\text{current}}} \quad (9)$$

گام ۴: گام‌های فوق را تا جایی ادامه دهید تا مقادیر خروجی لایه آخر شبکه با میزان واقعی تفاوت ناچیز داشته باشد.

اندازه‌گیری خطاست که در قالب روابط مختلف قابل محاسبه است که بعضی از آنها در زیر آمده‌اند.

قدر مطلق میانگین خطا (MAE)
 جذر میانگین مربع خطا ($RMSE$)
 نسبت قدر مطلق میانگین خطا ($MAPE$)

اگر مقدار واقعی (x_t) و خروجی مدل (x'_t) در دسترس باشد، داریم:

$$MAE = \frac{\sum_{t=1}^n |x_t - x'_t|}{n}$$

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (x_t - x'_t)^2}{n}} \quad (10)$$

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{x_t - x'_t}{x_t} \right|}{n}$$

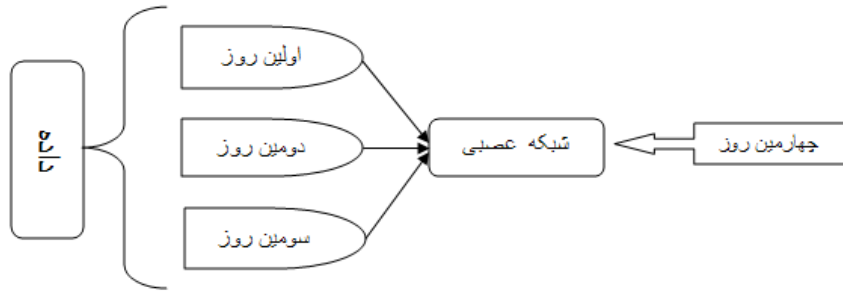
که معمولاً از خطای $MAPE$ برای محاسبه کارایی شبکه استفاده می‌شود. [11]

۵-۵. طراحی یک شبکه عصبی مصنوعی (ANN) جهت پیش‌بینی نرخ جفت ارز پوند/دلار

از آنجا که فرایند اَشوبی، یک پروسه غیر خطی معین و دارای پیچیدگی‌های زیادی است، بنابراین استفاده از مدل‌های خطی برای توصیف رفتار این گونه فرایندها مناسب نیستند.

جدول ۴. مقادیر شاخص‌ها برای داده‌های آموزشی

تعداد نرون	$MAPE$	MAE	$RMSE$
5	.008	.005	.008
6	.005	.004	.006
7	.012	.008	.011
8	.007	.004	.007
10	.013	.008	.012
15	.014	.009	.016
20	.017	.011	.016
25	.018	.012	.0163
30	.016	.011	.0162
35	.027	.07	.026
40	.026	.016	.025



شکل ۲. نحوه بکار بردن شبکه عصبی

جدول ۵. مقادیر شاخص‌ها برای داده‌های تست

مدل	MAPE	MAE	RMSE
ANN	0.004	0.002	0.003
ARIMA	0.009	0.005	0.007

جدول ۷. نتایج حاصل از آزمون دو نمونه‌ای t

Difference	μ (Time Serie) - μ (Real Data)
Estimate for difference	-0.005055
95% CI for difference	(-0.006519; -0.003591)
T-Value	-6.95
P-Value	0.000

همانطور که نتایج موجود در جدول شماره (۳) نشان می‌دهد مدل ANN نسبت به مدل ARIMA از قدرت پیش بینی بهتری برخوردار است. به منظور بررسی معنی داری اختلاف بین نتایج حاصل از پیش بینی مدل شبکه عصبی و مدل ARIMA از آزمون "دو نمونه‌ای t" استفاده می‌کنیم که نتایج حاصل در جدول (۶) آمده است.

جدول ۶. نتایج حاصل از آزمون دو نمونه‌ای t

Difference	μ (ANN) - μ (Real Data)
Estimate for difference	0.001355
95% CI for difference	(-0.000331; 0.003041)
T-Value	1.61
P-Value	0.113

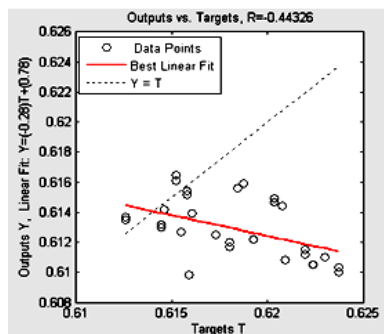
۵-۶. تحلیل پست رگرسیونی

کارایی مدل ARIMA و شبکه عصبی طراحی شده را در قسمت قبل با استفاده از آزمون‌های فرض آماری انجام دادیم. در این بخش جزئیات عکس العمل‌های مدل‌ها را با دقت بیشتر و با استفاده از تحلیل رگرسیونی انجام می‌دهیم.

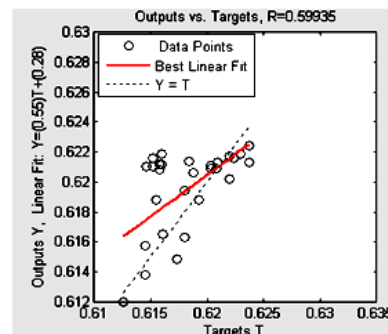
در نمودارهای زیر بهترین رگرسیون خطی مرتبط با خروجی مدل‌ها آمده است، اگر ما یک تنا سب کامل داشته، یعنی یعنی خروجی‌ها با هدف کاملاً برابر باشند، شیب برابر یک و برش λ برابر صفر خواهد بود. همانطور که شکل زیر نشان می‌دهد، بین خروجی شبکه عصبی و داده‌های واقعی تناسب بسیار بهتری وجود دارد.

همانطور که مشاهده می‌کنیم، بین داده‌های واقعی و نتایج حاصل از پیش بینی توسط شبکه عصبی در سطح خطای ۵٪ اختلاف معناداری وجود ندارد.

نتایج موجود در جدول (۷) نشان می‌دهند که در هر سطح معناداری، اختلاف معناداری بین داده‌های واقعی و نتایج حاصل از پیش بینی مدل ARIMA وجود دارد.



ب) تحلیل مربوط به ARIMA



الف) تحلیل مربوط به شبکه عصبی


نمودار ۵. نتایج حاصل از تحلیل پست رگرسیونی

۷. پیشنهادات

برای پیش بینی متغیرهای اصلی اقتصادی از جمله متغیرهای مالی (نرخ ارز) بهتر است از الگوهای چند معادله ای و اقتصاد - سنجی (الگوهای سیستم معادلات همزمان پویا) استفاده شود تا هم تأثیرات مقادیر گذشته و هم تأثیر متغیرهای کلان اقتصادی دیگر نیز مورد بررسی قرار گیرد که انتظار می رود نتایج قابل قبول تری در بر داشته باشد.

مراجع

- [۱] مشیری، سعید، و مروت، حبیب، پیش بینی شاخص کل بازدی سهام تهران با استفاده از مدل‌های خطی و غیرخطی، زمستان ۱۳۸۵، شماره ۴۱.
- [۲] هاشمی گلپایگانی، سید محمد رضا، آشوب و کاربردهای آن در مهندسی، انتشارات دانشگاه صنعتی امیرکبیر چاپ اول، ۱۳۸۸، فصول ۱، ۲، ۳، ۴.
- [۳] مشیری، سعید، و فروتن، فائزه، آزمون آشوب و پیش بینی قیمت‌های نفت خام، فصلنامه پژوهش‌های اقتصادی ایران، شماره ۲۱، ۱۳۸۳، صفحه ۹۰-۶۷.
- [۴] هاگان، مارتین تی، هاوارد بی، دیموث، مارک بیل، طراحی شبکه‌های عصبی، انتشارات کیان یارانه، چاپ اول، ۱۳۸۸، فصول ۱ تا ۱۲.
- [۵] منهاج، محمد باقر، مبانی شبکه‌های عصبی، انتشارات دانشگاه صنعتی امیرکبیر چاپ ششم، ۱۳۸۸ فصول ۱، ۲، ۳، ۴، ۷، ۸، ۱.
- [۶] نیرومند، حسینعلی، بزرگ نیا، ابوالقاسم، سری‌های زمانی، انتشارات دانشگاه پیام نور، چاپ، فصول ۱ و ۶.
- [7] Weigend, A.S., et al "Predicting sunspots and exchange rates with connectionist networks, in Nonlinear Modeling and Forecasting", eds. M. Casdagli and S. Eubank (Addison-Wesley, Redwood City, CA, pp. 39. (1992).
- [8] Kuan, C.M., & Liu, T., "Forecasting exchange rates using feedforward and recurrent neural networks", *Journal of Applied Econometrics* 10, 347-364. (1995).



شکل ۳. مقایسه نتایج حاصل از پیش بینی شبکه عصبی و مقدار واقعی

۶. نتیجه‌گیری

به دلیل وجود نوسانات بسیار زیاد و پیچیده، اغلب فرایند مولد سری زمانی نرخ ارز به صورت فرایندی تصادفی در نظر گرفته می شود. نظریه آشوب، در پی جستجوی نظم در رفتار به ظاهر تصادفی سیستم‌های دینامیکی غیر خطی معین است. نظریه آشوب در بازارهای مالی دلالت بر این دارد که قیمت در این بازارها به طور کامل از رابطه معین غیر خطی پیروی کرده و در صورت آگاهی دقیق از شرایط آغازین، قابل پیش بینی خواهد بود. در این پژوهش آزمون آشوب را برای سری زمانی روزانه نرخ جفت ارز $\frac{\text{دلار}}{\text{پوند}}$ در بازار فارکس، انجام دادیم. سوال اصلی این است که آیا دلیل نوسانات نرخ جفت ارز در این بازار، مکانیسم درونی سیستم مولد آن است و یا تکانه‌های خارجی و تصادفی به ایجاد چنین رفتارهای به ظاهر بی نظم منجر شده است. با توجه به نتایج آزمون بعد همبستگی، می توان نتیجه گرفت که به دلیل غیر خطی بودن سیستم مولد نرخ جفت ارز، استفاده از مدل‌های غیر خطی برای پیش بینی نرخ جفت ارز دقیق نخواهد بود و انتظار می رود که مدل‌های غیر خطی دقیق تر عمل نمایند. از سوی دیگر، مدل‌های شبکه عصبی مصنوعی با توجه به اینکه ساختاری غیر خطی و منعطف دارند، قادرند هر نوع الگوی حاکم بر داده‌ها را فرا گرفته، برآورد و پیش بینی دقیقی از آنها ارائه دهند. در این مطالعه با استفاده از شبکه عصبی پیشخور سه لایه و الگوریتم یادگیری پس انتشار خطا، مقادیر آتی نرخ جفت ارز $\frac{\text{دلار}}{\text{پوند}}$ طی یک دوره یک ماهه پیش بینی و نتیجه با مدل خطی *ARIMA* مقایسه شد. نتایج بدست آمده نشان داد که مدل شبکه عصبی از قدرت پیش بینی بهتری برخوردار است.

- [19] Samad, M.T., Measuring the performance of privatized banks in Irani. *Management Science Letters* 2, 1103–1108. 2012.
- [20] Lean, Yu, Shouyang, Wang., Kin Keung, Lai., A neural-network-based nonlinear metamodeling approach to financial time series forecasting *Applied Soft Computing*. Pages 563-574. Volume 9, Issue 2, March 2009.
- [21] Ping, Zou., Jingsong, Yang., Jianrong, Fu., Guangming, Liu., Dongshun, Li., Artificial neural network and time series models for predicting soil salt and water content *Original Research Article Agricultural Water Management*, Volume 97, Issue 12, 15 November 2010, Pages 2009-2019
- [22] Cryer, Jonathan D. *Times Series Analysis*. Publications of Duxbury Press, 19908. Brokwell P. J and Davis R.A. *Introduction to times Series and Forecasting*, 2nd edition Springer, New Yourk, 2002.
- [23] Olsan, Dennis., Mossaman, Charles., Neural network forecasts of Canadian stock returns using Accounting ratios, *Internatinal Journal of Forecasting*, 2003.
- [24] Robert, J., van, Eyden., *The Application of Neural Network in Forecasting of Share Price*, Finance and Technology Publishing, 2003.
- [25] Krzysztof, Michalak., Halina, Kwaśnicka., Influence of data dimensionality on the quality of forecasts given by a multilayer perceptron. *Theoretical Computer Science*, pp. 62-71. Volume 371, Issues 1-2, 22 February, 2007.
- [26] Ping, Zou., Jingsong, Yang., Jianrong, Fu., Guangming, Liu., Dongshun, Li., Artificial neural network and time series models for predicting soil salt and water content *Agricultural Water Management. Engineering Applications of Artificial Intelligence*. Pages 2009-2019, Volume 97, Issue 12, 15 November 2010.
- [27] Palmer, J.J., Montañó, F.J., Franconetti. Sensitivity Analysis Applied to Artificial Neural Networks for Forecasting Time Series Methodology. *European Journal of Research Methods for the Behavioral and Social Sciences*. Pages 80-86. Volume 4, Issue 2, 2008.
- [9] Hann, T.H., & Steurer, E., “Much ado about nothing? Exchangerate forecasting: Neural networks versus linear models using monthly and weekly data”, *Neurocomputing* 10, 323–339. (1996).
- [10] Lisi, F., & Schiavo, R.A., “A comparison between neural networks and chaotic models for exchange rate prediction”, *Computational Statistical and Data Analysis* 30, 87–102. (1999).
- [11] Hu, M.Y., & Tsoukalas, C., “Combining conditional volatility forecasts using neural networks: An application to the EMS exchangerates”, *Journal of International Financial Markets, Institutions and Money* 9, 407–422. (1999).
- [12] Gency, R., “Linear, Non-linear and essential foreign exchange rate with simple technical trading rules”, *Journal of International Economics*. (1999).
- [13] Yao, J.T., & Tan, C.L., “A case study on using neural networks to perform technical forecasting of forex”, *Neurocomputing* 34, 79–98. (2000).
- [14] Davis, J. T., et al “Predicting direction shifts on Canadian-US exchange rates with artificial neural networks”, *International Journal of Intelligent Systems in Accounting, Finance and Management* 10, 83–96. (2001).
- [15] Dunis, C.L., & Williams, M., “Modeling and Trading EUR/USD Exchange Rate: Do Neural Models Perform Better?”, *Trading and Regulation*. (2002).
- [16] Kamruzzaman, J., & Sarker, R., “Forecasting of currency Exchange Rates Using ANN: A Case Study”, *Proc. of IEEE Int. Conf. on Neural Networks & Signal Processing*, Vol. 1, pp: 793- 797. (2003).
- [17] Samad, M.T., Measuring the performance of privatized banks in Irani. *Management Science Letters* 2, 1103–1108. 2012.
- [18] Rana, Yasir Hussain., Haroon, Hussain., Bhatti, Ghulam Ali., and Arshad, Hassan., Long run Relationship among East Asian equity markets and KSE. *Management Science Letters* 2, 1167–1174. 2012.

- [28] Gao, D., Kinouchi, Y., Ito, K., Zhao, X., Neural networks for event extraction from time series: a back propagation algorithm approach. *Future Generation Computer Systems*. Pages 1096-1105. Volume 21, Issue 7, July 2005.
- [29] Balestrassi, P.P., Popova, E., Paiva, A.P., Marangon Lima, J.W., Design of experiments on neural network's training for nonlinear time series forecasting. *Neurocomputing*. Pages 1160-1178 Volume 72, Issues 4-6, January 2009.
- [30] González-Romera, Eva., Jaramillo-Morán, Miguel.Ángel., Diego Carmona-Fernández. Forecasting of the electric energy demand trend and monthly fluctuation with neural networks. *Computers & Industrial Engineering*. Pages 336-343. Volume 52, Issue 3, April 2007.