

## ارائه روش جدید در آموزش شبکه عصبی بازگشتی برای پیش‌بینی دو مرحله بعد سری‌های زمانی اقتصادی

نرگس طالبی مطلق<sup>۱\*</sup>، امیر ریخته‌گر غیائی<sup>۲</sup>، فرزاد هاشم‌زاده<sup>۳</sup>

۱- دانشکده مهندسی برق و کامپیوتر - دانشگاه تبریز - تبریز - ایران [n.talebi@tabrizu.ac.ir](mailto:n.talebi@tabrizu.ac.ir)

۲- دانشکده مهندسی برق و کامپیوتر - دانشگاه تبریز - تبریز - ایران [agiasi@tabrizu.ac.ir](mailto:agiasi@tabrizu.ac.ir)

۳- دانشکده مهندسی برق و کامپیوتر - دانشگاه تبریز - تبریز - ایران [hashemzadeh@tabrizu.ac.ir](mailto:hashemzadeh@tabrizu.ac.ir)

**چکیده:** پیش‌بینی دقیق رویدادهای آینده یکی از مهم‌ترین پایه‌های تصمیمات مهمی همچون خرید و فروش و توسعه فعالیت‌های اقتصادی معامله‌گران و شرکت‌های بزرگ اقتصادی می‌باشد. از سوی دیگر به دلیل رفتار دینامیکی عوامل اقتصادی، پیش‌بینی بلندمدت یکی از مسائل مشکل و پیچیده غیرخطی مورد علاقه اقتصاددانان می‌باشد. در این مقاله، به دلیل اهمیت پیش‌بینی جهت افزایش یا کاهش در قیمت، شبکه عصبی بازگشتی جدیدی برای پیش‌بینی دو مرحله بعد پیشنهاد شده است که در آن با استفاده از یک ترکیب خطی از تقارن جهت‌دار پیش‌بینی برای آموزش تقویتی شبکه عصبی و نرخ آموزش تطبیقی در الگوریتم یادگیری، شبکه عصبی بازگشتی، دقت و کارایی آن بهبود یافته است. همچنین، براساس شبکه پیشنهادی، الگوریتم‌های جداگانه‌ای برای آموزش آنلاین و آفلاین ارائه شده است. پس از اعمال این شبکه و پیش‌بینی قیمت با استفاده از این شبکه نتایج پیش‌بینی نشان دهنده دقت بالا و کارایی این شبکه در پیش‌بینی قیمت طلا می‌باشد.

**کلمات کلیدی:** شبکه عصبی بازگشتی، پیش‌بینی دو مرحله بعد (2SA)، آموزش تقویتی، تقارن جهت‌دار، پیش‌بینی بلندمدت قیمت

**طبقه بندی موضوعی:** sciences Game theory, economics, social and behavioral

### مقدمه

فرایند مدل‌سازی و پیش‌بینی سیستم‌های اقتصادی به دلیل ویژگی‌های غیرخطی آن‌ها بسیار پیچیده است. به همین دلیل تمام اطلاعاتی که ممکن است به مدل‌سازی آن‌ها کمک کند بسیار ارزشمند است.

\* سخنران

از طرفی، مدل‌سازی دقیق سیستم اقتصادی به دلیل دخیل بودن فاکتورهای مختلفی از جمله رخدادهای سیاسی، وضعیت اقتصادی و فاکتورهای محیطی، بسیار پیچیده است. علاوه بر این سری-های زمانی اقتصادی به طور عمده دینامیک و آمیخته با نویز و غیرخطی و پیچیده و آشوبگونه است [1]. در این مقاله هدف ارائه مدل مناسب برای پیش‌بینی قیمت طلا است. پیش‌بینی قیمت طلا به دلیل امکان کسب سود بالا در معاملات طلا در صورت پیش‌بینی دقیق از اهمیت بالایی برخوردار است شبکه‌های عصبی، سیستم‌های فازی و الگوریتم ژنتیک نتایج رضایت‌بخشی در مسائل اقتصادی به ویژه بازار طلا از خود نمایش داده‌اند. به طور مثال از آن‌ها برای مدل‌سازی عملکرد غیرخطی بازار بورس در شرایط ناآرام اقتصادی استفاده شده است و با دقت قابل قبول قادر به پیش‌بینی آن شده است [2]. از آنجایی که شبکه‌های عصبی ساختار موجود در محیط‌های متغیر را تشخیص می‌دهند، می‌توان از آن‌ها برای تشخیص الگوهای موجود در سری‌های زمانی سیستم‌های اقتصادی و پیش‌بینی قیمت آینده استفاده نمود. با فرض بر تکرارپذیری و حافظه‌دار بودن سیستم اقتصادی می‌توان از شبکه عصبی مصنوعی در تخمین ویژگی‌های غیرخطی در مسائلی چون مدل‌سازی و پیش‌بینی استفاده نمود [3-5]. الگوریتم آموزش بازگشتی بلادرنگ، یک الگوریتم مناسب و کارا برای آموزش سیستم‌های تکراری است که توسط ویلیام و زیپسر ارائه شده است و از حلقه‌های فیدبک داخلی برای بهبود عملکرد الگوریتم استفاده می‌کند [6].

### الگوریتم آموزش بازگشتی بلادرنگ تقویتی بهبود یافته

در این مقاله الگوریتم بهبود یافته IR - RTRL بر روی شبکه عصبی بازگشتی جهت پیش‌بینی دو مرحله بعد قیمت طلا اعمال شده است. شبکه عصبی بازگشتی تقویتی که توسط چنگ ارائه شده است. این شبکه از دو لایه تشکیل شده است و  $M$  ورودی خارجی و  $N$  خروجی دارد [7]. همان‌طور که در شکل ۱ نمایش داده شده است،  $x(t)$  نشان دهنده بردار ورودی گسسته زمان متغیر با زمان  $t$  و  $y(t+1)$  خروجی لایه میانی متناظر با ورودی مورد نظر است. ورودی شبکه از دو بردار  $x(t)$  و  $y(t+1)$  تشکیل شده است که در معادله ۱ نمایش داده شده است.

$$\mu(t) = [x(t); y(t)] \quad (1)$$

از طرفی  $y(t+1)$  ورودی لایه دوم و  $z(t+2)$  خروجی متناظر با آن در لایه خروجی است. خروجی نرون  $k$ م در لایه میانی با معادله ۲ مشخص می‌شود.

$$y_j(t+1) = f\left(\sum_{i \in AUB} w_{1ji}(t) \mu_i(t)\right) \quad (2)$$

که در آن  $f(\cdot)$  تابع فعال‌سازی غیرخطی نرون است. در لایه خروجی، خروجی نرون  $k$ م در لحظه  $t+2$  از معادله ۳ محاسبه می‌شود.

$$z_k(t+2) = f\left(\sum_j w_{2kj}(t+1) y_j(t+1)\right) \quad (3)$$

در معادله ۳ و ۲،  $w_{lji}(t)$  وزن شبکه است. حال می‌توانیم المان  $k$ ام بردار خطا متغیر با زمان  $e_k(t+2)$  را محاسبه کنیم.

$$e_k(t+2) = d_k(t+2) - z_k(t+2) \quad (4)$$

که در آن  $d_k(t+2)$  مقدار تابع هدف برای نرون  $k$ ام در لحظه  $t+2$  است. خطای لحظه‌ای شبکه از معادله ۵ محاسبه می‌شود.

$$E(t+2) = \frac{1}{2} \sum_{k=1}^K e_k^2(t+2) \quad (5)$$

همچنین نرخ آموزش وزن‌های شبکه با معادله ۶ محاسبه می‌شود.

$$\Delta w_{lmn}(t) = -\eta \frac{\partial E(t+2)}{\partial w_{lmn}(t)} \quad (6)$$

پروسه به‌روزرسانی تقویتی وزن‌های شبکه عصبی بازگشتی برای پیش‌بینی دو مرحله بعد به طور کامل در شکل ۲ نمایش داده شده است. در مرحله آموزش تقویتی خروجی لایه‌ها و خطاهای تخمین و قوانین به‌روزرسانی به صورت معادله ۷ جمع‌بندی می‌شوند.

$$\begin{aligned} \hat{y}_j(t+2) &= f\left(\sum_{i \in AUB} (w_{1ji}(t) + \Delta w_{1ji}(t)) \mu_i(t+1)\right) \\ \hat{z}_k(t+3) &= f\left(\sum_j (w_{2ji}(t+1) + \Delta w_{2ji}(t+1)) \hat{y}_j(t+2)\right) \\ \hat{e}_k(t+3) &= \hat{z}_k(t+3) - z_k(t+3) \\ \hat{E}(t+3) &= \frac{1}{2} \sum_{k=1}^K \hat{e}_k^2(t+3) \\ \Delta \hat{w}_{lmn} &= -\eta \frac{\partial \hat{E}(t+3)}{\partial w_{lmn}} \end{aligned} \quad (7)$$

و در نهایت می‌توان قوانین به‌روزرسانی وزن‌ها به فرم معادله ۸ جمع‌بندی نمود.

$$w_{lmn}^{new} = w_{lmn} + \Delta w_{lmn} + \Delta \hat{w}_{lmn} \quad (8)$$

که در آن  $w_{lji}(t)$  به ازای  $l=1$  درایه‌های ماتریس وزنی در لایه میانی و به ازای  $l=2$  درایه‌های ماتریس وزنی در لایه خروجی می‌باشند.

با وجود اینکه پیش‌بینی دقیق و کاهش خطای تخمین اهمیت زیادی دارد ولی در عین حال، پیش‌بینی جهت تغییرات قیمت یک سیستم اقتصادی اهمیت بیشتری دارد. چرا که با پیش‌بینی دقیق در مورد عملکرد سیستم، تصمیم درستی در زمینه خرید و یا فروش آن صورت می‌پذیرد که موجبات افزایش سود سرمایه‌گذار را فراهم می‌آورد. با این اوصاف روشی جدید برای بهبود آموزش شبکه عصبی ارائه شده است که در آن تابع مجازات بهبودیافته‌ای پیشنهاد شده است که شامل یک ترکیب خطی از تقارن جهت‌دار نمودار قیمت می‌باشد و در معادله ۹ آورده شده است.

$$\tilde{E}_1 = (\alpha + \beta \cdot DS) E(t+2) \quad \text{و} \quad \tilde{E}_2 = (\alpha + \beta \cdot DS) \hat{E}(t+3) \quad (9)$$

رابطه،  $\alpha$  و  $\beta$  مقادیر ثابت و  $DS$ ، تقارن جهت‌دار نمودار قیمت می‌باشد.

تقارن جهت‌دار ابزاری برای بررسی کارایی مدل در تشخیص جهت تغییرات مثبت یا منفی سری زمانی از یک لحظه به لحظه دیگر است [8] و در معادله ۱۰ تعریف شده است.

$$DS = \frac{1}{M} \sum_{t=1}^N a(t) \times 100\% \quad (10)$$

در این رابطه،  $M$  طول سیگنال ورودی و  $a(t)$  از معادله ۱۱ محاسبه می‌شود.

$$a(t) = \begin{cases} 1 & \text{if } (d(t+3) - d(t+2))(z(t+3) - z(t+2)) > 0 \\ 0 & \text{otherwise} \end{cases} \quad (11)$$

به بیان دیگر، تقارن جهت‌دار معیاری برای سنجش کارایی مدل پیش‌بین در تشخیص جهت تغییرات سری زمانی است.

### پیاده‌سازی

در این تحقیق، قیمت روزانه طلا از بانک اطلاعاتی بلومبرگ به عنوان ورودی به شبکه عصبی اعمال شده است. به طوری که داده‌های قیمت طلا از ۲۱ دسامبر ۲۰۱۲ تا ۱۲ جولای ۲۰۱۳ که در مجموع سری زمانی به طول ۷۹۲ می‌باشد، برای آموزش آفلاین شبکه و داده‌های قیمت طلا از ۱۳ جولای ۲۰۱۳ تا ۱۵ آگوست ۲۰۱۴ که در مجموع سری زمانی به طول ۳۳۹ می‌باشد، برای تست مرحله آفلاین شبکه اختصاص داده شده است. به منظور نمایش برتری روش پیشنهادی، نتایج حاصل از پیش‌بینی قیمت طلا با روش پیشنهادی را با نتایج حاصل از شبکه‌های عصبی R-RTNL و BPNN مقایسه می‌شود. نتایج جدول ۱ نشان می‌دهند که پیش‌بینی بر اساس الگوریتم پیشنهادی، منجر به مجموع مربعات خطا و مجموع مربعات خطای نرمالیزه شده پایین‌تری در پیش‌بینی آنلاین و آفلاین و در مقایسه با سایر روش‌ها می‌شود.

### نتیجه

پیش‌بینی کارآمد و دقیق قیمت می‌تواند بسیار ارزشمند باشد. سیستم RTRL قادر به طراحی مدلی پیچیده و قدرتمند برای پیش‌بینی دو مرحله بعد دقیق می‌باشد. در این مقاله الگوریتم جدید بهبود یافته IR - RTRL برای آموزش شبکه عصبی مصنوعی به منظور پیش‌بینی دو مرحله بعد قیمت طلا ارائه شده است و نتایج پیاده‌سازی برای اثبات توانایی روش پیشنهادی در آموزش کارآمد و پیش‌بینی دقیق آورده شده است که حاکی از مناسب بودن روش پیشنهادی نسبت به سایر روش‌های آموزش شبکه می‌باشد. الگوریتم پیشنهادی می‌تواند در الگوریتم‌های پیش‌بینی با افق طولانی‌تر تعمیم یابد.

### مراجع

- [1] Zhang, Yudong, and Lenan Wu, "Stock market prediction of s&p 500 via combination of improved bco approach and bp neural network," *Expert systems with applications*, vol. 36, no. 5, pp. 8849-8854, 2009.
- [2] Atsalakis GS, Valavanis KP, "Forecasting stock market short-term trends using a neuro-fuzzy based methodology," *Expert Systems with Applications*, vol. 36, no. 7, pp. 10,696-10,707, 2009.
- [3] Raval, Jabal, and Bhushan Jagyasi, "Distributed detection in Neural Network based multihop Wireless Sensor Network," in *Sensors Applications Symposium (SAS), 2014 IEEE. IEEE*, 2014.
- [4] Li, Shuai, and Yangming Li, "Nonlinearly activated neural network for solving time-varying complex sylvester equation," *Cybernetics, IEEE Transactions on*, vol. 44, no. 8, pp. 1397-1407, 2014.
- [5] Wen, T., Xu, A., Liu, C., & Li, N., "Application of RBF Neural Network Based on ENN2 Clustering in

- Fault Diagnosis," in *In Intelligent Human-Machine Systems and Cybernetics (IHMSC), 2014 Sixth International Conference on*.
- [6] Williams, Ronald J., and David Zipser, "A learning algorithm for continually running fully recurrent neural networks," *Neural computation*, vol. 1, no. 2, pp. 270-280, 1989.
- [7] Chang LC, Chen PA, Chang FJ, "Reinforced two-step-ahead weight adjustment technique for online training of recurrent neural networks," *Neural Networks and Learning Systems, IEEE Transactions on*, vol. 23, no. 8, p. 1269–1278, 2012.
- [8] Zhou, Shifei, Kin Keung Lai, and Jerome Yen, "A dynamic meta-learning rate-based model for gold market forecasting," *Expert Systems with Applications*, vol. 39, no. 6, pp. 6168-6173, 2012.

**جدول ۱:** مقایسه عملکرد شبکه برای پیش‌بینی سری زمانی قیمت طلا بر اساس روش‌های آموزش مختلف در آموزش آنلاین و آفلاین

آموزش آفلاین						آموزش آنلاین	
		مرحله تست شبکه عصبی		مرحله آموزش شبکه عصبی			
NMSE	MSE	NMSE	MSE	NMSE	MSE		
$1/26 \times 10^{-2}$	$2/64 \times 10^{-2}$	1/18	3324/8	0/004	52/89	شبکه IR-RTRL	
$1/44 \times 10^{-2}$	$4/58 \times 10^{-2}$	3/85	20650	0/009	140/92	شبکه R-RTRL	
$2/76 \times 10^{-2}$	$8/59 \times 10^{-2}$	4/83	22404	0/014	202/44	شبکه BPNN	