

## کاربرد شبکه‌های عصبی مصنوعی در پیش بینی داده‌های سری زمانی: مطالعه موردی بورس تهران

مهیا کریمزاده خسروشاهی<sup>a</sup>، آرمان مالک<sup>b</sup>

<sup>a</sup> دانشجوی کارشناسی ارشد مدیریت مالی (دانشکده علوم مالی، دانشگاه خوارزمی، تهران)

<sup>b</sup> دانشجوی کارشناسی ارشد مدیریت مالی (دانشکده علوم مالی، دانشگاه خوارزمی، تهران)

نویسنده مسئول: مهیا کریمزاده خسروشاهی (mkarimzadeh1375@gmail.com-09052722795)

### چکیده:

**هدف:** در این پژوهش ضمن اشاره به کاربرد شبکه‌های عصبی مصنوعی در بازارهای مالی، به مقایسه مدل حافظه کوتاه مدت ماندگار و مدل تکرارشونده درگاهی از دسته مدل‌های داده کاوی و هوش مصنوعی، در دقت پیش‌بینی آنها بر روی داده‌های ده سهم بزرگ بازار بورس تهران در بازه زمانی ده ساله، از ابتدای ۱۳۸۸ تا ابتدای سال ۱۳۹۸ پرداخته شده است. هدف از این پژوهش معرفی مدل بهتر برای پیش‌بینی قیمت پایانی این ده سهم است.

**روش:** از آن جایی که این تحقیق بر روی داده‌های بازار بورس تهران انجام شده، هر یک از سهم‌های مورد مطالعه با مشکل داده‌های گم شده روبه‌روست که این مشکل در نهایت تأثیر بسزایی بر عملکرد مدل می‌گذارد. به منظور حل این مشکل از روش رگرسیون خطی برای پیدا کردن این داده‌ها و در ادامه برای توضیح قیمت پایانی هر سهم از اندیکاتورها و اسپلاتورها تکنیکال استفاده شده است. در گام بعد از الگوریتم جنگل تصادفی از دسته مدل‌های یادگیری ماشین‌ها به منظور انتخاب مؤثرترین این متغیرها استفاده شده است. در نهایت از آزمون دیابولد ماریانو برای بررسی معنی‌دار بودن اختلاف در دقت پیش‌بینی این دو مدل استفاده شده است. شایان ذکر است که در این مطالعه برای اولین بار در ایران عملکرد این ۲ شبکه عصبی مصنوعی با این ساختار در بازار سهام مقایسه شده است.

**یافته‌ها:** یافته‌های این پژوهش حاکی از آن است که هر دو مدل مورد بررسی قدرت بالایی در جهت استخراج اطلاعات از داده‌های سری زمانی را دارند اما مدل حافظه کوتاه مدت ماندگار به دقت بالاتری در شش سهم از ده سهم مورد مطالعه و مدل تکرارشونده درگاهی در چهار سهم باقی، دست یافته‌اند.

**نتایج:** در نهایت نتایج آزمون دیابولد ماریانو نشان داد که به جز اختلاف دقت دو مدل در یکی از سهم‌های مورد مطالعه، در باقی آن‌ها از حیث آماری معنی‌دار است. نتایج این تحقیق می‌توان راهنمایی برای افرادی که مدیریت سبد سهام انجام می‌دهند و همچنین گسترش دهندگان ابزارهای تحلیل و معامله قرار گیرد.

**کلمات کلیدی:** مدل حافظه کوتاه مدت ماندگار؛ مدل تکرارشونده درگاهی؛ الگوریتم جنگل تصادفی؛ بازار بورس تهران.

## ۱. مقدمه

در سال‌های اخیر با پیشرفت‌های رخ داده در حوزه آبر داده‌ها<sup>۱</sup> و هوش مصنوعی<sup>۲</sup>، پژوهشگران بیشتری اقدام به استفاده از این تکنولوژی برای حل مسائل خود کرده‌اند. آن‌ها ثابت کرده‌اند که این تکنولوژی می‌تواند مسائل غیرخطی و داده‌های نا مانا<sup>۳</sup> را بهتر از مدل‌های کلاسیک آماری حل کند (وانگ لی ژانگ و لیو، ۲۰۲۰). مدل‌های شبکه عصبی مصنوعی<sup>۴</sup> امروزه بسیار مورد توجه پژوهشگران مالی و اقتصادی قرار گرفته است و دلیل آن را می‌توان از یک سو توانایی این مدل‌ها در تقلید انعطاف پذیر روابط غیرخطی (کو و لین، ۲۰۰۶ و ۲۰۰۸) و از سوی دیگر ارزش بازرگانی این مدل‌ها به دلیل ریسک‌ها و سودهای جذابی که در این عرصه وجود دارد، دانست (ماژی، پاندا، ساهو، داش و داس، ۲۰۰۷). در این پژوهش به مقایسه قدرت پیش‌بینی دو نوع از به‌روزترین مدل‌های شبکه عصبی مصنوعی (۱) حافظه کوتاه مدت ماندگار<sup>۵</sup> (۲) تکرار شونده درگاهی<sup>۶</sup> پرداخته شده است. بررسی قدرت پیش‌بینی این دو مدل بر روی ده سهم بزرگ بازار بورس تهران انجام شده و هدف این پژوهش معرفی مدل برتر برای پیش‌بینی قیمت پایانی هر یک از این ده سهم با استفاده از کتابخانه‌های تانسورفلو<sup>۷</sup> و کراس<sup>۸</sup> است. با شایان ذکر است که در این مطالعه برای اولین بار در ایران عملکرد این ۲ شبکه عصبی مصنوعی با این ساختار در بازار سهام مقایسه شده است.

## ۲. پیشینه پژوهش

### - پیشینه نظری

شبکه‌های عصبی مصنوعی یک دسته از مدل‌های محاسباتی از مدل‌های آموزش ماشین‌ها<sup>۹</sup> هستند. این مدل‌ها بیشتر از هفتاد سال است که به وجود آمده‌اند (مک کولو و پیتس، ۱۹۴۳). یک شبکه عصبی مصنوعی را می‌توان یک الگوریتم تعریف کرد برای حل مسائل غیرخطی. این الگوریتم با تنظیم وزن‌ها موجود بین لایه‌های برهم مرتبط که با ورود پروپاگاندا<sup>۱۱</sup> گونه داده‌ها و استفاده از توابع نسبتاً ساده این کار را انجام می‌دهد. این لایه‌ها از واحدهای کوچکی به اسم نورون<sup>۱۱</sup> ساخته شده‌اند که این نام از واحدها ساده سازنده سیستم محاسباتی انسان (مغز) الهام گرفته است. شبکه‌های عصبی مصنوعی ثابت کرده‌اند که در امر تشخیص متغیرهای موثر نسبت به سایر مدل‌ها بهتر عمل کرده‌اند. دلیل این امر تشخیص دشوار این متغیرها و بخصوص استخراج روابط انتظالی از بین متغیرها توسط سایر الگوریتم‌هاست. شبکه‌های عصبی امروزه کاربرد زیادی در مالی پیدا کرده‌اند (تریپی و توربان، ۱۹۹۲) از مدل‌هایی برای پیش‌بینی قیمت سهام گرفته (نیکولاس رنفس، زپرانیس و فرانسیس، ۱۹۹۴) تا تشخیص احتمال ورشکستگی شرکت‌ها (آدوم و شردا، ۱۹۹۰). اثربخشی مدل‌های شبکه عصبی مصنوعی در پیش‌بینی قیمت سهام همواره مورد مقایسه با سایر مدل‌های سنتی توسط پژوهشگران بوده است (فرناندز رُد ریگز، گُنزالس مارتل و سُسویلا ریورو، ۲۰۰۰)، و بدیهی است که مقایسه‌ها، متأثر از شرایط بازارها و سهم‌های مورد نظر است. اما به صورت کلی یک توجه به خصوصی به مدل شبکه‌های عصبی مصنوعی وجود داشته که دلیل آن را می‌توان به شکل زیر ذکر کرد:

(۱) نتایج بسیار خوب شرکت گوگل<sup>۱۲</sup> در پیاده‌سازی شبکه‌های عصبی بازگشتی<sup>۱۳</sup> بر روی عکس‌ها و تشخیص گفتار<sup>۱۴</sup>.

(۲) دردسترس بودن کتابخانه‌های متعدد برای پیاده‌سازی انواع شبکه‌های عصبی همچون تانسورفلو از شرکت گوگل.

1. Big data  
 2. Artificial Intelligence (AI)  
 3. Non stationary  
 4. Artificial neural network  
 5. Long Short-Term Memory (LSTM)  
 6. Gated Recurrent Unit (GRU)  
 7. Tensorflow  
 8. Keras  
 9. Machine learning  
 10. Backpropagation  
 11. Neuron  
 12. Google  
 13. Recurrent Neural Network (RNN)  
 14. Speech recognition

۳) افزایش قدرت پردازش گره‌های چندهسته‌ای گرافیکی<sup>۱۵</sup> که امکان انجام محاسبات را با سرعت بالاتر و هزینه کمتر فراهم می‌کنند. همچون پردازشگرهای شرکت انویدیا<sup>۱۶</sup> (سانگ و دی پیرو، ۲۰۱۹).

### ۳. شبکه‌های عصبی مصنوعی

شبکه‌های حافظه کوتاه‌مدت ماندگار:

شبکه‌های حافظه کوتاه‌مدت ماندگار توسط هوخیدر<sup>۱۷</sup> و شمیت هوپر<sup>۱۸</sup> به‌عنوان جایگزینی بر روش‌های پیشین خود برای آموزش داده‌های دارای ترتیب وقوعی معرفی شدند (هوخیدر و شمیت هوپر، ۱۹۹۷). شبکه‌های حافظه کوتاه‌مدت ماندگار از دسته شبکه‌های بازگشتی هستند، اما با این تفاوت که شبکه‌های حافظه کوتاه‌مدت ماندگار قدرت بازیابی اطلاعات طولانی‌مدت را بیشتر از شبکه‌های عصبی بازگشتی ساده دارند (فیشر و کراوس ۲۰۱۸، لی کان، بنجیو و هینتون، ۲۰۱۵). ساختار سلول حافظه کوتاه‌مدت ماندگار در شکل ۱ نشان داده شده است.

توابع سلول حافظه کوتاه‌مدت ماندگار به شرح زیر است:

$$f_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) \quad \text{رابطه (۱)}$$

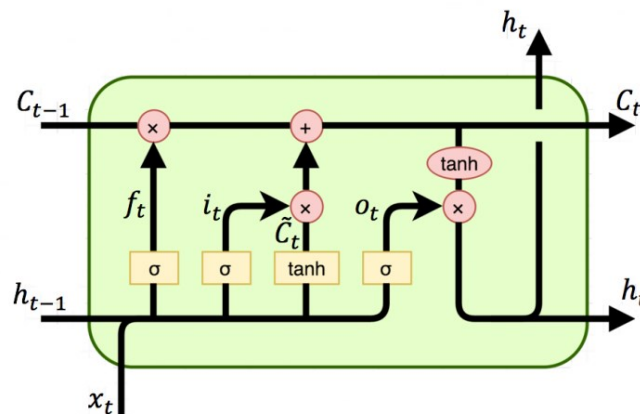
$$i_t = \sigma(w_i \cdot [h_{t-1}, x_t] + b_i) \quad \text{رابطه (۲)}$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad \text{رابطه (۳)}$$

$$c_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad \text{رابطه (۴)}$$

$$g_t = \tanh(x_t U^g + h_{t-1} W^g) \quad \text{رابطه (۵)}$$

$$h_t = \tanh(c_t) \cdot o_t \quad \text{رابطه (۶)}$$



شکل ۱. ساختار سلول حافظه کوتاه مدت ماندگار

<sup>15</sup>. Multi-core graphic processing units  
<sup>16</sup>. Nvidia  
<sup>17</sup>. Hochreiter  
<sup>18</sup>. Schmidhuber

### شبکه‌های تکرارشونده درگاهی

شبکه‌های تکرارشونده درگاهی نسل جدیدی از دسته شبکه‌های بازگشتی هستند و شباهت زیادی به شبکه‌های حافظه کوتاه‌مدت ماندگار دارند. این شبکه‌ها بر خلاف شبکه‌های حافظه کوتاه‌مدت ماندگار درگاه ورود و خروج<sup>۱۹</sup> ندارند و این کار را بر عهده منطقه مخفی<sup>۲۰</sup> سلول تکرارشونده درگاهی گذاشته‌اند. سلول‌های تکرارشونده درگاهی فقط دو واحد دارند یک واحد باز آغازی<sup>۲۱</sup> و یک واحد بروز رسانی<sup>۲۲</sup>. در این سلول‌ها واحد به‌روزرسانی همچون درگاه ورودی<sup>۲۳</sup> و درگاه خروجی<sup>۲۴</sup> سلول‌های حافظه کوتاه‌مدت ماندگار عمل می‌کند و تصمیم این که چه داده‌هایی اضافه یا حذف شوند بر عهده آن است. واحد باز آغازی واحدی است که تصمیم می‌گیرد چه اطلاعاتی از گذشته را باید فراموش کند. ساختار سلول تکرارشونده درگاهی در شکل ۲ نشان داده شده است.


توابع سلول تکرارشونده درگاهی به شرح زیر است:

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad \text{رابطه (۷)}$$

$$z_t = \sigma(w_z \cdot [h_{t-1}, x_t] + b_z) \quad \text{رابطه (۸)}$$

$$k = \tanh(x_t U^k + (h_t - 1 \cdot r) W^k) \quad \text{رابطه (۹)}$$

$$h_t = (1 - z) \cdot k + z h_{t-1} \quad \text{رابطه (۱۰)}$$



شکل ۲ - ساختار سلول تکرار شونده درگاهی

19. Cell state  
 20. Hidden state  
 21. Restart  
 22. Update  
 23. Input gate  
 24. Output gate

- پیشینه تجربی

کارا اِتا<sup>۲۵</sup> با انتخاب ده اندیکاتور تکنیکال<sup>۲۶</sup> پژوهش خود را انجام داد (کارا، آکار بویاژو و بایکان ۲۰۱۱). اندیکاتورهایی همچون RSI<sup>۲۷</sup>، EMA<sup>۲۸</sup> و MOM<sup>۲۹</sup> همبستگی زیادی بر تغییرات بازار دارند (چن و هاوو، ۲۰۱۸). همچنین سری‌های زمانی مربوط به قیمت سهم همیشه با استفاده از وقفه خود متغیر نیز توضیح داده شده است (وانگ اِتا، ۲۰۲۰). به طور مثال پایوا اِتا<sup>۳۰</sup> از تعداد زیادی وقفه بازده برای توضیح بازده آینده سهم استفاده کرد (پایوا، کاردوسو، هاناآکا و دوارت، ۲۰۱۹). و در نهایت فیشا<sup>۳۱</sup> و کراوس<sup>۳۲</sup> از یک سری بازده با طول ۲۴۰ برای آموزش داده‌های خود استفاده کردند (فیشر و کراوس ۲۰۱۸).

۴. روش‌شناسی پژوهش

داده‌ها

نکته مهم آن است که مدل‌های حافظه کوتاه‌مدت ماندگار و تکرارشونده درگاهی نیاز به داده‌های طولانی‌مدت برای عملکرد هرچه بهتر دارند، به همین منظور داده‌های روزانه ۱۰ سال اخیر از سایت TSETMC استخراج شده است. داده‌های استخراج شده از ابتدای سال ۱۳۸۸ تا ابتدای سال ۱۳۹۸ را شامل می‌شود. جدول شماره ۱ خلاصه‌ای از قیمت پایانی ده سهم مورد مطالعه را ارائه می‌دهد.

جدول ۱ - خلاصه قیمت پایانی سهام (تمام قیمت‌ها به ریال است)

نماد	کمترین	بیشترین	انحراف استاندارد	میانگین
اخابر	۴۵۱.۶۵	۲۴۶۸.۶۸	۳۴۸.۶۵	۱۰۸۳.۴۶
فملی	۶۲.۳۱	۲۸۶۹.۰۴	۵۲۳.۷۶	۷۳۷.۹۴
فولاد	۴۵.۳۰	۲۱۸۰.۵۰	۴۱۷.۵۱	۴۴۶.۹۰
حکشتی	۴۰۴.۶۴	۶۱۷۶.۹۳	۱۶۹۷.۶۹	۲۴۶۸.۲۹
کگل	۷۶.۱۷	۵۹۷۴.۶۸	۱۱۶۲.۱۰	۱۱۶۱.۰۹
رمینا	۲۰۲.۳۴	۴۷۲۳.۸۸	۱۱۵۶.۰۹	۱۸۱۲.۸۱
شیراز	۴۲۱.۸۷	۴۸۰۹.۷۹	۹۹۵.۲۷	۱۳۰۲.۲۳
شپنا	۱۱۵.۷۲	۷۶۵۸.۰۰	۱۴۹۳.۹۷	۲۲۱۵.۲۹
وغدیر	۳۴۷.۳۸	۲۲۹۷.۰۵	۳۹۴.۱۲	۱۱۰۰.۵۹
ومعادن	۴۸.۸۸	۴۵۵۶.۲۷	۸۱۵.۵۸	۸۵۲.۳۸

25. Kara et al

26. Technical indicator

27. Relative Strength Index

28. Exponential Moving Average

29. Momentum

30. Paiva et al

31. Fisher

32. Krauss

## پیش‌پردازش داده‌ها

یکی از محدودیت‌های پژوهشگران در مدل‌های شبکه‌های عصبی مصنوعی، داده‌های گم شده<sup>۳۳</sup> است که در اثر بسته‌شدن نماد پیرو قانون‌های سازمان بورس تهران مبنی بر نوسانات ۲۰ درصد یا ۵۰ درصد یا سایر قوانینی که موجب بسته‌شدن نماد به مدت طولانی‌تر می‌شود، به وجود می‌آید. این محدودیت می‌تواند تأثیر بسزایی در کارایی مدل ایجاد کند. بدین منظور پژوهشگران می‌توانند از روش‌های متفاوتی از جمله صرف‌نظر کردن از آن داده‌ها یا جای‌گذاری داده‌های گم شده با میانگین قیمت قبل و بعد از بسته‌شدن نماد و همچنین از روش‌های داده‌کاوی<sup>۳۴</sup> استفاده کنند. در این پژوهش رگرسیون خطی<sup>۳۵</sup> به‌منظور پرکردن داده‌های گم شده استفاده شده تا بتوان حداقل میزان داده را برای اجرای مدل را فراهم کرد.

## متغیر ورودی

انتخاب متغیر ورودی مناسب از میان سایر متغیرها همواره یک چالش برای پژوهشگران بوده است. در این پژوهش با توجه به ادبیات‌های موضوع پیشین اندیکاتورهای تکنیکال<sup>۳۶</sup> نشان داده‌اند که گزینه مناسبی هستند. این اندیکاتورها توانسته‌اند به شکل مؤثر در توضیح و بازتاب شرایط بازار عمل کنند. اندیکاتورهای استفاده شده در این تحقیق در جدول شماره ۲ اشاره شده‌اند.

از سوی دیگر روش‌های متعددی برای انتخاب متغیر مؤثر وجود دارد تا بتواند محققان را یاری کند تا از میان تعداد زیادی از متغیرها، آنهایی را که در رتبه بالاتر از حیث تأثیرگذاری بر متغیر وابسته قرار دارند را ارائه دهند. این تکنیک‌ها به محققان کمک می‌کند تا بتوانند در زمان اجرای مدل خود صرفه‌جویی کرده، کارایی مدل برای ارائه پیش‌بینی را بالاتر برند و نهایتاً یک تحلیل بهتری از داده را با استفاده از نرم‌افزارها بتوانند ارائه دهند. از دیگر مزایای این تکنیک‌ها می‌توان (۱) افزایش عملکرد استاندارد کردن داده‌ها و متغیرها (۲) استاندارد کردن قوی‌تر داده‌ها که در برابر داده‌های جدید بهتر عمل کنند (۳) افزایش توانایی فهم بهتر از فرایندی که در آن داده‌ها ساخته می‌شوند (چاندرا شکار و ساهین، ۲۰۱۴). در نهایت تکنیک جنگل تصادفی<sup>۳۷</sup> برای انتخاب مؤثرترین متغیرها در این تحقیق استفاده شده است. جنگل تصادفی یکی از الگوریتم‌های معروف و پرکاربرد در میان تکنیک‌های یادگیری ماشین‌ها است. علت موفقیت این الگوریتم قدرت پیش‌بینی بالا، احتمال کم بیش مقید<sup>۳۸</sup> شدن الگو و توان فهم و درک آسان این الگوریتم‌ها است. توانایی درک آسان این الگوریتم به این دلیل است که میزان اهمیت هر متغیر با استفاده از درخت تصمیم<sup>۳۹</sup> به راحتی قابل استخراج است. الگوریتم جنگل تصادفی تشکیل شده از چهارصد تا هزار و دویست درخت تصمیم که هر کدام از این درخت‌های تصمیم مسئولیت بررسی یک انتخاب تصادفی از مشاهدات و همچنین یک انتخاب تصادفی از متغیرهای مستقل را دارد. به بیانی دیگر هر یک درخت تصمیم توانایی دسترسی به تمام مشاهدات و یا تمام متغیرهای مستقل را ندارد و این امر ضامن عدم همبستگی بین درخت‌ها و در نتیجه ضامن عدم بیش مقید شدن الگوریتم انتخاب متغیرهای توضیح‌دهنده است. هر درخت تصمیم به کار برده شده تشکیل شده از توالی از سؤالات بلی یا خیر از یک متغیر یا تلفیقی از چند متغیر. بعد از جواب به هر سؤال درخت تصمیم داده‌ها را به دو خوشه تقسیم می‌کند، هر خوشه محل جمع‌آوری مشاهدات با بیشترین تشابه و با بیشترین تفاوت نسبت به خوشه مقابل است. در نتیجه متغیرهای مستقل انتخابی برای ورود به الگوریتم‌های مورد مطالعه از میان خوشه‌هایی انتخاب می‌شود که بالاترین درصد خلوص (درصد تشابه) را داشته باشند. نکته مهم در این الگوریتم جنگل تصادفی رفتار پویا در مقابل داده‌های متفاوت است، بنابراین در این پژوهش تعداد متغیرهای انتخاب شده برای هر سهم نسبت به سایر سهم‌ها متفاوت بوده است. جدول شماره ۲ تمام متغیرهای ورودی به الگوریتم جنگل تصادفی را نشان می‌دهد.

33. Missing data

34. Data mining

35. Linear regression

36. Technical indicators

37. Random forest

38. Over fitting

39. Decision tree

جدول ۲ - متغیرهای ورودی

متغیرهای دخیل در اندیکاتور	نام اندیکاتور یا اسیلاتور	ردیف
High - Low - Close	Average Directional Movement Index	۱
High - Low - Close	Average Directional Movement Index Rating	۲
Close	Absolute Price Oscillator	۳
High - Low	Aroon	۴
High - Low	Aroon Oscillator	۵
Open - High - Low - Close	Balance Of Power	۶
High - Low - Close	Commodity Channel Index	۷
Close	Chande Momentum Oscillator	۸
High - Low - Close	Directional Movement Index	۹
Close	Moving Average Convergence/Divergence	۱۰
High - Low - Close - Volume	Money Flow Index	۱۱
High - Low - Close	Minus Directional Indicator	۱۲
High - Low	Minus Directional Movement	۱۳
Close	Momentum	۱۴
High - Low - Close	Plus Directional Indicator	۱۵
High - Low	Plus Directional Movement	۱۶
Close	Percentage Price Oscillator	۱۷
Close	Rate of change	۱۸
Close	Rate of change Percentage	۱۹
Close	Rate of change ratio	۲۰
Close	Rate of change ratio 100 scale	۲۱
Close	Relative Strength Index	۲۲
High - Low - Close	Stochastic	۲۳
High - Low - Close	Stochastic Fast	۲۴
Close	Stochastic Relative Strength Index	۲۵
Close	1-day Rate-Of-Change (ROC) of a Triple Smooth EMA	۲۶
High - Low - Close	Ultimate Oscillator	۲۷
High - Low - Close	Williams' %R	۲۸
Close	First lag Close price(target)	۲۹
Close	Second lag Close price(target)	۳۰
Close	Third lag Close price(target)	۳۱

### تقسیم‌بندی داده‌های آموزشی<sup>۴۰</sup> و آزمایشی<sup>۴۱</sup>

در این پژوهش از ده سال داده سری زمانی روزانه استفاده شده است که باتوجه به تلاش بر جای‌گذاری داده‌های مربوط به روزهای بسته هر سهم، تمام سهم‌های مورد مطالعه دارای تعداد داده برابر شدند. از بین تمام داده‌ها ۹۰ درصد آن که متناظر با ۹ سال اول می‌شود به داده‌های آموزش و ۱۰ درصد باقی برای پیش‌بینی و آزمایش مدل اختصاص داده شده است.

### یافته‌های پژوهش

در پیاده‌سازی مدل‌ها سرعت‌های<sup>۴۲</sup> متفاوت برای آموزش شبکه‌ها امتحان گردید. سرعت‌ها بالا در روند آموزش موجب اصطلاحاً انفجار در تابع گرادیانت<sup>۴۳</sup> و سرعت‌های پایین موجب به دام افتادن تابع گرادیانت در مینیموم موضعی<sup>۴۴</sup> و مانع از به دست آوردن مینیموم کلی<sup>۴۵</sup> می‌شود. همچنین با آزمون و خطاهای انجام شده، بهترین اندازه دستة اطلاعاتی<sup>۴۶</sup> برای ورود به مدل، اندازه ۴۰ به دست آمد. جدول شماره ۳ میزان خطا هر مدل بر روی هر یک از ده سهم مورد مطالعه طبق توابع مختلف سنجش خطا را گزارش می‌دهد.

جدول ۳- خطای مدل‌ها

نماد	تابع سنجش خطا	حافظه کوتاه‌مدت ماندگار	تکرار شونده در گاهی
اخبار	MSE	۰.۰۰۳۳۶۴۰۷۸	۰.۰۰۹۷۳
	MAE	۰.۰۴۳۴۳۱۳۱۲	۰.۰۷۱۴۳
	RMSE	۰.۰۵۸	۰.۰۹۹
فملی	MSE	۰.۰۰۱۵۴۵۷۱۲	۰.۰۰۱۷۴
	MAE	۰.۰۳۱۳۲۳۵۱۱	۰.۰۳۱۵۴
	RMSE	۰.۰۳۹	۰.۰۴۲
فولاد	MSE	۰.۰۰۴۳۰۸۴۰۱	۰.۰۵۹۹۱
	MAE	۰.۰۵۱۹۴۴۱۸۵	۰.۱۹۷۰۳
	RMSE	۰.۰۶۶	۰.۲۴۵
حکشتی	MSE	۰.۰۰۱۷۰۳۶۱۶	۰.۰۰۰۷۹
	MAE	۰.۰۲۹۹۲۱۱۱۳	۰.۰۲۰۹
	RMSE	۰.۰۴۱	۰.۰۲۸
کگل	MSE	۰.۱۶۷۰۶۲۳۵۸	۰.۱۳۲۱۱
	MAE	۰.۳۲۲۴۵۲۲۰۸	۰.۲۸۹۵۹
	RMSE	۰.۴۰۹	۰.۳۶۳
رمپنا	MSE	۰.۰۰۰۴۱۵۴۰۱	۰.۰۰۱۹۲
	MAE	۰.۰۱۵۵۰۲۲۷۳	۰.۰۳۵۹۴
	RMSE	۰.۰۲	۰.۰۴۴

40. Training data

41. Test data

42. Learning rate

43. Gradient explosion

44. Local minimum

45. Global minimum

46. Batch size



شیراز	MSE	۰.۰۰۱۳۰۰۶۱۹	۰.۰۰۳۶۵
	MAE	۰.۰۲۴۲۴۳۷۳۹	۰.۰۴۵۶۷
	RMSE	۰.۰۳۶	۰.۰۶
شپنا	MSE	۰.۰۰۰۸۳۳۴۶۳	۰.۰۰۰۵۷
	MAE	۰.۰۲۳۷۰۳۴۱۵	۰.۰۱۸۵۶
	RMSE	۰.۰۲۹	۰.۰۲۴
وغدیر	MSE	۰.۰۰۰۲۰۵۵۵۷	۰.۰۰۰۱۳
	MAE	۰.۰۱۰۹۱۴۶۴۸	۰.۰۰۸۲۹
	RMSE	۰.۰۱۴	۰.۰۱۲
ومعادن	MSE	۰.۱۰۴۰۶۰۳۹۳	۰.۱۵۸۷۶
	MAE	۰.۲۲۶۴۳۴۱۷۱	۰.۲۹۷۶۳
	RMSE	۰.۳۲۳	۰.۳۹۸

نتایج جدول نشان می‌دهد در سهم‌های اخبار، فملی، فولاد، رمپنا، شیراز و ومعادن مدل حافظه کوتاه مدت ماندگار عملکرد بهتری نشان می‌دهد. در مقابل مدل تکرار شونده درگاهی در سهم‌های حکشتی، کگل، شپنا و وغدیر عملکرد بهتری را نشان می‌دهد. در ادامه به منظور بررسی معنی‌دار بودن اختلاف عملکرد این دو مدل از آزمون دیابولد ماریانو<sup>۴۷</sup> استفاده شده است. جدول شماره ۴ نتایج آزمون دیابولد ماریانو را نشان می‌دهد، نتایج حاکی از آن است که تمام تفاوت‌های دو مدل حافظه کوتاه‌مدت ماندگار و تکرار شونده درگاهی در پیش‌بینی معنی‌دار و غیر صفر بوده است و آماره آزمون‌ها همان‌طور که در جدول شماره ۳ نیز مشخص بود، برتری مدل حافظه کوتاه‌مدت ماندگار در سهم‌های اخبار، فملی، فولاد، رمپنا، شیراز و ومعادن و برتری عملکرد مدل تکرار شونده درگاهی در سایر سهم‌های مطالعه شده را نشان می‌دهد.

جدول ۴ نتایج آزمون دیابولد ماریانو

نماد	احتمال	آماره آزمون
اخبار	E-15۱.۷۶	-۸.۵۱۹۷۵۰۱۴۴
فملی	۰.۳۶۴۷۰۶۸۶۳	-۰.۹۰۸۱۴۱۶۲۶
فولاد	E-30۱.۷۹	-۱۳.۲۴۳۱۱۰۶۶
حکشتی	E-07۱.۱۴	-۵.۴۶۶۱۲۰۹۰۳
کگل	E-16۳.۷۷	۸.۷۴۷۳۰۲۵۲۷
رمپنا	E-27۲.۱۶	-۱۲.۳۱۸۵۳۷۴
شیراز	E-27۸.۱۶	-۱۲.۱۵۰۳۰۱۲۱
شپنا	E-07۱.۳۷	۵.۴۲۹۷۷۰۸۷۹
وغدیر	E-13۵.۹۰	۷.۶۱۷۰۰۴۹۱۱
ومعادن	E-38۹.۶۲	-۱۵.۳۹۴۲۸۸۶

<sup>47</sup>. Diebold Mariano test

## بحث

در سال‌های اخیر به دلیل پیشرفت‌های زیادی که در حوزه هوش مصنوعی، داده‌کاوی و نوین‌ترین الگوریتم‌هایی که در آنها استفاده می‌شود رخ داده است، پژوهشگران توانسته‌اند به شکلی بسیار متمایز به استخراج اطلاعات از میان داده‌های خام بپردازند. به شکلی که هیچ یک از مدل‌های آماری کلاسیک از جمله آریما<sup>۴۸</sup>، آرفیما<sup>۴۹</sup>، فاریما<sup>۵۰</sup>، آرچ<sup>۵۱</sup> و گارچ<sup>۵۲</sup> نتوانسته‌اند بدین شکل مطلوب عمل کنند. اما در این پژوهش فارغ از مدل‌های کلاسیک آماری، این دو مدل برتری‌هایی در هر سهم بخصوص نسبت به دیگری داشته‌اند که به تفصیل توضیح داده شد.

## نتیجه‌گیری و پیشنهادها

به‌طور کلی در ۱۰ سهم مورد مطالعه و در بازه زمانی مشخص شده، عملکرد مدل حافظه کوتاه‌مدت ماندگار در ۶ سهم بهتر از تکرارشونده درگاهی و در ۴ سهم باقی عملکرد مدل تکرارشونده درگاهی بهتر بوده است، از این رو افرادی که قصد پیش‌بینی بازده سالانه برای سهم‌های مورد مطالعه این پژوهش را دارند بهتر است نتایج این پژوهش را در نظر داشته باشند. نتایج این پژوهش می‌تواند زمینه‌ای برای پژوهشگرانی که قصد انجام بهینه‌سازی سبد سهام با استفاده از تئوری‌هایی که بازده در آن دخیل است، فراهم کند، تا بتوانند برای ارزیابی بازده یک‌ساله هر یک از این ده سهم از مدل مناسب استفاده کنند. همچنین زمینه‌ای برای ارائه مدل‌های پویا<sup>۵۳</sup> جهت انجام معاملات الگوریتمی در بازار عملیاتی را فراهم می‌کند.

## References

- Chandrashekar, G., & Sahin, F. (2014). A survey on feature selection methods. *Computers & Electrical Engineering*, 40(1), 16-28. doi:<https://doi.org/10.1016/j.compeleceng.2013.11.024>
- Chen, Y., & Hao, Y. (2018). Integrating principle component analysis and weighted support vector machine for stock trading signals prediction. *Neurocomputing*, 321, 381-402. doi:<https://doi.org/10.1016/j.neucom.2018.08.077>
- Fernández-Rodríguez, F., González-Martel, C., & Sosvilla-Rivero, S. (2000). On the profitability of technical trading rules based on artificial neural networks: Evidence from the Madrid stock market. *Economics Letters*, 69(1), 89-94. doi:[https://doi.org/10.1016/S0165-1765\(00\)00270-6](https://doi.org/10.1016/S0165-1765(00)00270-6)
- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654-669. doi:<https://doi.org/10.1016/j.ejor.2017.11.054>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780. doi:<https://doi.org/10.1162/neco.1997.9.8.1735>
- Kara, Y., Acar Boyacioglu, M., & Baykan, Ö. K. (2011). Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. *Expert Systems with Applications*, 38(5), 5311-5319. doi:<https://doi.org/10.1016/j.eswa.2010.10.027>
- Ko, P.-C., & Lin, P.-C. (2006). An evolution-based approach with modularized evaluations to forecast financial distress. *Knowledge-Based Systems*, 19(1), 84-91. doi:<https://doi.org/10.1016/j.knosys.2005.11.006>
- Ko, P.-C., & Lin, P.-C. (2008). Resource allocation neural network in portfolio selection. *Expert Systems with Applications*, 35(1), 330-337. doi:<https://doi.org/10.1016/j.eswa.2007.07.031>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. doi:[10.1038/nature14539](https://doi.org/10.1038/nature14539)

48. ARIMA

49. ARFIMA

50. FARIMA

51. ARCH

52. GARCH

53. Dynamic models

- Majhi, R., Panda, G., Sahoo, G., Dash, P. K., & Das, D. P. (2007, 25-28 Sept. 2007). *Stock market prediction of S&P 500 and DJIA using Bacterial Foraging Optimization Technique*. Paper presented at the 2007 IEEE Congress on Evolutionary Computation.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133. doi:10.1007/BF02478259
- Nicholas Refenes, A., Zapranis, A., & Francis, G. (1994). Stock performance modeling using neural networks: A comparative study with regression models. *Neural Networks*, 7(2), 375-388. doi:https://doi.org/10.1016/0893-6080(94)90030-2
- Odom, M. D., & Sharda, R. (1990, 17-21 June 1990). *A neural network model for bankruptcy prediction*. Paper presented at the 1990 IJCNN International Joint Conference on Neural Networks.
- Paiva, F. D., Cardoso, R. T. N., Hanaoka, G. P., & Duarte, W. M. (2019). Decision-making for financial trading: A fusion approach of machine learning and portfolio selection. *Expert Systems with Applications*, 115, 635-655. doi:https://doi.org/10.1016/j.eswa.2018.08.003
- Sang, C., & Di Pierro, M. (2019). Improving trading technical analysis with TensorFlow Long Short-Term Memory (LSTM) Neural Network. *The Journal of Finance and Data Science*, 5(1), 1-11. doi:https://doi.org/10.1016/j.jfds.2018.10.003
- Trippi, R. R., & Turban, E. (1992). *Neural Networks in Finance and Investing: Using Artificial Intelligence to Improve Real World Performance*: McGraw-Hill, Inc.
- Wang, W., Li, W., Zhang, N., & Liu, K. (2020). Portfolio formation with preselection using deep learning from long-term financial data. *Expert Systems with Applications*, 143, 113042. doi:https://doi.org/10.1016/j.eswa.2019.113042