

## LSTM پیش‌بینی بازار سهام با استفاده از مدل ترکیبی شبکه عصبی

طاهره رامه<sup>۱</sup>، رضوان عباسی<sup>۲</sup>، محمدرضا ثنایی<sup>۳</sup>

### چکیده

پیش‌بینی قیمت و بازده سهام یکی از پیچیده‌ترین و بحث‌برانگیزترین موضوعات در بازارهای مالی است که همواره مورد توجه سرمایه‌گذاران و سهامداران می‌باشد. بازار سهام در برابر عوامل مختلفی آسیب‌پذیر است که بر نوسانات قیمت در بازار بورس تأثیر می‌گذارد. توسعه یک الگوریتم قوی بازار سهام که بتواند رفتار سهام را به دقت پیش‌بینی کند، برای به حداکثر رساندن سود و به حداقل رساندن ضرر سرمایه‌گذار، مورد نیاز است. با توجه به اینکه علاوه بر تاریخچه هر سهم، عوامل روانی بازار نیز بر ارزش هر سهم تأثیر می‌گذارد، در این تحقیق یک مدل ترکیبی هوش مصنوعی بر اساس LSTM و تعبیه متن پیشنهاد می‌شود که هم بر سابقه بازار سهام در قالب داده‌های سری زمانی توجه دارد، و هم ویژگی‌های روانی بازار را از سایت‌های خبری استخراج می‌کند و آینده بازار سهام را پیش‌بینی می‌کند. نتایج ارزیابی‌ها نشان می‌دهد مدل پیشنهادی می‌تواند به خوبی آینده بازار را پیش‌بینی نماید و نسبت به روش‌های پروفت و آریما دارای میانگین مربعات خطای کمتری است.

کلیدواژه‌ها: LSTM، تعبیه متن، بازار بورس

طبقه بندی JEL: G17, G12, G41

<sup>۱</sup> گروه فناوری اطلاعات، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران. [maharameh17@gmail.com](mailto:maharameh17@gmail.com)

<sup>۲</sup> گروه مهندسی برق، پزشکی و مکاترونیک، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران. (نویسنده مسئول):

[Rezvanabbasi@yahoo.com](mailto:Rezvanabbasi@yahoo.com)

<sup>۳</sup> گروه فناوری اطلاعات، واحد قزوین، دانشگاه آزاد اسلامی، قزوین، ایران. [Mohamadrezasanaei@gmail.com](mailto:Mohamadrezasanaei@gmail.com)

# Forecasting the stock market using LSTM neural network hybrid model

## Tahereh Rameh<sup>1</sup>, Rizvan Abbasi<sup>2</sup>, Mohammad Reza Sanai<sup>3</sup>

### Abstract

Forecasting stock prices and returns is one of the most complex and controversial issues in financial markets, which is always the concern of investors and shareholders. The stock market is vulnerable to various factors that affect the price fluctuations in the stock market. The development of a robust stock market algorithm that can accurately predict stock behavior is needed to maximize profits and minimize investor losses. Considering that in addition to the history of each share, the psychological factors of the market also affect the value of each share, in this research, a hybrid model of artificial intelligence based on LSTM and text embedding is proposed, which is based on the history of the stock market in the form of data. It pays attention to time series, and it extracts psychological characteristics of the market from news sites and predicts the future of the stock market. The results of the evaluations show that the proposed model can predict the future of the market well and has a lower mean square error than the PROFET and ARIMA methods.

**Keywords:** LSTM, text embedding, stock market

**JEL Classification:** G17, G12, G41

### ۱. مقدمه و بیان مسئله

پیش بینی قیمت و بازده سهام یکی از پیچیده ترین و بحث برانگیزترین موضوعات در بازارهای مالی است (رمضانیان و همکاران، ۲۰۱۹) که همواره مورد توجه سرمایه گذاران و سهامداران است (پولاموری<sup>۴</sup> و همکاران، ۲۰۲۱). بورس اوراق بهادار یکی از منابع جمع آوری پس اندازها و تامین سرمایه گذاریها می باشد (حسینی ابراهیم آباد و همکاران، ۲۰۱۹)؛ پیش بینی بازار سهام، به دلیل عدم قطعیت های متفاوت تاثیرگذار بر قیمت بازار، کار بسیار دشواری است که شامل رویدادهای سیاسی، اقتصادی و احساسات سرمایه گذاران است (قندمال و کومار<sup>۵</sup>، ۲۰۱۹). بازار سهام بطور طبیعی، پویا و پراشوب است (گورموزیادیس و گاتزولگلو<sup>۶</sup>، ۲۰۱۶) و نوسانات قیمت بازار سهام دارای نوسانات تصادفی است (اویوالا<sup>۷</sup> و همکاران، ۲۰۲۱). برای پیش بینی بازار سهام، داشتن دانش پیشرفته سهام الزامی است. سرمایه گذاران ترجیح می دهند سهامی بخرند که قیمت آن در آینده افزایش یابد و از خرید سهامی که ارزش آن در طول زمان کاهش می یابد خودداری کنند. با این حال، توسعه یک الگوریتم قوی بازار سهام که بتواند رفتار سهام را به دقت پیش بینی کند، برای به حداکثر رساندن سود و به حداقل رساندن ضرر سرمایه گذار مهم است (اویوالا<sup>۸</sup> و

---

<sup>1</sup>Department of Information Technology, Qazvin Branch, Islamic Azad University, Qazvin, Iran.  
maharameh17@gmail.com

<sup>2</sup> Department of Electrical, Medical and Mechatronic Engineering, Qazvin Branch, Islamic Azad University, Qazvin, Iran. (author and responsible): Rezvanabbasi@yahoo.com

<sup>3</sup> Department of Information Technology, Qazvin Branch, Islamic Azad University, Qazvin, Iran.  
Mohamadrezasanai@gmail.com

<sup>4</sup> Polamuri

<sup>5</sup> Gandhmal, Kumar

<sup>6</sup> Chourmouziadis, Chatzoglou

<sup>7</sup> Oyewola

<sup>8</sup> Oyewola

همکاران، ۲۰۲۱). سرمایه گذاران در خرید سهام به شاخص های فنی مختلف برای پیش بینی حرکت قیمت سهام تکیه می کنند. اگرچه از این شاخص ها برای ارزیابی سهام استفاده می شود، اما پیش بینی روند بازار دشوار است چرا که عوامل اقتصادی و غیراقتصادی بر رفتار روند سهام تأثیر می گذارد (آوجی<sup>۱</sup>، ۲۰۰۷). بنابراین پیش بینی بازار سهام به عنوان یک چالش مهم برای رشد تولید تلقی می شود.

طراحی سیستم های معاملاتی با بازده مناسب همواره یکی از حوزه های پر طرفدار و پر کاربرد در حوزه مهندسی مالی بوده و نیز یکی از ضروریات سرمایه گذاران بازار سرمایه است (داودی و همکاران، ۱۴۰۱). یک سیستم پشتیبانی تصمیم مالی می تواند تصمیم گیری سرمایه گذاران را پس از افشای صورت های مالی تا حد زیادی تسهیل کند (فریگال و پرنديگر<sup>۲</sup>، ۲۰۲۱). چنین سیستم هایی، می توانند به شناسایی سهام سودمند مالی و اعمال مالکیت کمک کنند. هر چقدر الگوریتم مورد استفاده برای پیش بینی آینده سهام قدرتمند و کامل باشد، پیش گویی ها درست تر خواهد بود پس لازم است از الگوریتم های کارا برای این امر استفاده شود. برای این منظور، الگوریتم های مختلفی در طی سالهای مختلف پیشنهاد شده است. بسیاری از الگوریتم های کلاسیک مانند مدل میانگین متحرک یکپارچه رگرسیون خودکار آریماس<sup>۳</sup> (ناثو<sup>۴</sup>، ۲۰۱۴) به وجود آمدند. به طور کلی مراحل پیش بینی آریماس شامل فرآیندهای تعریف مسئله، جمع آوری و تجزیه و تحلیل مجموعه داده ها، طراحی و بهینه سازی مدل، و پیش بینی و ارزیابی است. با این حال، آنها مدل های خطی هستند و از مشکلات عملکردی رنج می برند، زیرا داده های بازار سهام دارای ماهیت سری های زمانی هستند که بعد زمانی را آشکار می کنند. مدل های خطی با روش های یادگیری ماشین سنتی مانند ماشین بردار پشتیبان<sup>۵</sup> برای پیش بینی استفاده می شوند (پولاموری و همکاران، ۲۰۱۹).

ثابت شده است که مدل های یادگیری عمیق جایگزین های امیدوار کننده ای در تحقیقات پیش بینی قیمت سهام هستند زیرا به موفقیت های بزرگی دست یافتند (ژانگ<sup>۶</sup> و همکاران، ۲۰۱۹). وارگاس<sup>۷</sup> و همکاران (وارگاس و همکاران، ۲۰۱۷)، لیو<sup>۸</sup> و همکاران (لیو و همکاران، ۲۰۱۸) و کاتایاما<sup>۹</sup> و همکاران (کاتایاما و همکاران، ۲۰۱۹) نشان دادند که مدل یادگیری عمیق، از مدل های یادگیری ماشین سنتی بهتر عمل می کند. این الگوریتم ها به سبب ذات پیچیده خود، توانستند نتایج امیدوار کننده ای در پیش بینی قیمت سهام داشته باشند. با اینکه مدل های یادگیری عمیق منجر به دقت بالا در پیش بینی سهام می شوند اما عموماً از ضعف تعمیم پذیری رنج می برند. مدل های اقتصادسنجی به دلیل ضریب تعیین نسبتاً پایین، از جمله رگرسیون خودکار و میانگین متحرک در رابطه با بازارهای پر نوسان نمی توانند رابطه دقیقی برای بازده سهام ارائه کنند (لیو<sup>۱۰</sup>، ۲۰۱۶). معمولاً در چنین شرایطی، استفاده از مدل های ترکیبی که بتواند در حالت های مختلف، خروجی ها را جرح و تعدیل کند، در دستور کار قرار می گیرد. بهره گیری از مدل های ترکیبی داده کاوی منجر به افزایش دقت و نیز قدرت تعمیم پذیری به نسبت تک تک مدل های پیش بینی کننده می شود (سوتکاتی و تورس<sup>۱۱</sup>، ۲۰۰۸).

تحقیقات گذشته عموماً توجه خود را به داده های سری زمانی مربوط به قیمت سهام معطوف کرده اند. با توجه به اینکه گستردگی داده های مورد استفاده، عملاً دستیابی به رویکردی متقن و کارا در پیش بینی قیمت اکثریت سهام ها در بازارهای سرمایه مختلف را مشکل می سازد، ارائه مدل ترکیبی برای پیش بینی بازار سهام هدف این تحقیق است. در این تحقیق یک مدل مبتنی بر یادگیری عمیق برای پیش بینی قیمت سهام پیشنهاد می شود. مدل پیشنهادی، با استفاده از نیروهای روانی بازار سرمایه و تاریخچه هر سهم آینده آن را پیش بینی می کند. مدل ترکیبی پیشنهادی بر

<sup>1</sup> Avci

<sup>2</sup> Feuerriegel, Prendinger

<sup>3</sup> Autoregressive Integrated Moving Average

<sup>4</sup> Nau

<sup>5</sup> Support Vector Machine

<sup>6</sup> Zhang

<sup>7</sup> Vargas

<sup>8</sup> Liu

<sup>9</sup> Katayama

<sup>10</sup> Libo

<sup>11</sup> Sutkatti and Torse

اساس LSTM<sup>1</sup> و تعبیه متن<sup>۲</sup> می‌باشد که علاوه بر داده‌های سری زمانی، ویژگی‌هایی را نیز از سایت‌های خبری استخراج کرده و به منظور بررسی نیروی روانی بازار، آینده سهام را پیش‌بینی می‌کند.

ساختار مقاله به شرح زیر است: در بخش ۲ ادبیات موضوع و راهکارهای مورد استفاده را شرح می‌دهد، همچنین مروری بر روش‌ها بوده و مقالات اخیر در رابطه با پیش‌بینی بازار سهام بررسی می‌شود. بخش ۳ سوالات و فرضیه‌های پژوهش و بخش ۴ معماری مدل پیشنهادی را نشان می‌دهد. بخش ۵ نتایج عملی استفاده از مدل پیشنهادی را ارائه می‌کند. بخش ۶ ضمن جمع‌بندی و نتیجه‌گیری، مقاله را به پایان می‌رساند و دستورالعمل‌هایی را برای دامنه تحقیقات آینده ارائه می‌کند.

## ۲. مبانی نظری و پیشینه پژوهش

در این بخش در مورد روش‌های مورد استفاده در مدل پیشنهادی، از جمله LSTM و تبدیل داده‌های متنی به بردار شرح مختصری داده می‌شود.

### ۱.۲ LSTM

LSTM یکی از انواع بسیاری از شبکه‌های عصبی بازگشتی است که می‌تواند داده‌ها را از مراحل گذشته بگیرد و از آن برای پیش‌بینی‌های آینده استفاده کند. به طور کلی، یک شبکه عصبی مصنوعی از سه لایه تشکیل شده است: لایه ورودی، لایه‌های پنهان، لایه خروجی.

شبکه‌های عصبی عمیق LSTM یک معماری خاص شبکه عصبی بازگشتی است که می‌تواند الگوهای زمانی را از داده‌های متوالی بیاموزد و بر مشکل نا پدید شدن گرادینان<sup>۳</sup> در RNN استاندارد (هوچریترو اشمیتروبر<sup>۴</sup>، ۱۹۹۷) غلبه کند.

علاوه بر این، شبکه‌های عصبی عمیق LSTM مکانیزم‌های گیتی<sup>۵</sup> برای تنظیم جریان اطلاعات دارند. مقدار اطلاعاتی که حفظ می‌شود به صورت سیستمی در هر مرحله زمانی تعیین می‌شود. بنابراین، شبکه‌های عصبی عمیق LSTM می‌توانند الگوهای زمانی را در طول یک سری زمانی طولانی به خاطر بسپارد. معماری یک سلول شبکه‌های عصبی عمیق حافظه LSTM در شکل ۱ نشان داده شده است که در آن  $ht$  و  $ct$  به ترتیب به عنوان ورودی، حالت پنهان و حالت سلول در زمان  $t$  تعریف شده‌اند. شبکه‌های عصبی عمیق LSTM مکانیزم‌های داخلی به نام گیت<sup>۶</sup> دارد. این گیت‌ها جریان اطلاعات را کنترل می‌کنند. این گیت‌ها مشخص می‌کنند که چه داده‌هایی از توالی مهم هستند و باید هم‌چنان حفظ شوند و چه داده‌هایی باید حذف شوند. به این شکل، شبکه اطلاعات مهم را در طول زنجیره توالی عبور می‌دهد تا خروجی مدنظر را داشته باشیم. یک سلول شبکه‌های عصبی عمیق LSTM دارای سه گیت  $it$ ،  $ft$  و  $ot$  است که به ترتیب به آنها گیت فراموشی، گیت ورودی و گیت خروجی می‌گویند. توجه داشته باشید که  $\otimes$  ضرب نقطه‌ای است. توابع فعال سازی سیگموئید و  $\tanh$  به ترتیب به عنوان sigmoid و  $\tanh$  مشخص می‌شوند. در اینجا، تابع فعال سازی  $\tanh$  طبق فرمول ۱ تعریف می‌شود.

$$\tanh(z) = \frac{z}{1 + e^{-2z}} - 1 \quad (۱)$$

تابع  $\tanh$  به منظور به روز رسانی وضعیت پنهان استفاده می‌شود.

تابع فعال‌سازی sigmoid طبق فرمول ۲ تعریف می‌شود. تابع سیگموئید به شکل گیری مقدار خروجی در محدوده  $[0, 1]$  کمک می‌کند. اگر خروجی نزدیک به ۰ باشد، بیشتر اطلاعات از بین می‌رود. اگر مقدار خروجی نزدیک به ۱ باشد، به این معنی است که اطلاعات بیشتری مجاز است.

<sup>1</sup> Long Short-Term Memory (LSTM)

<sup>2</sup> Text embedding

<sup>3</sup> the vanishing gradient problem

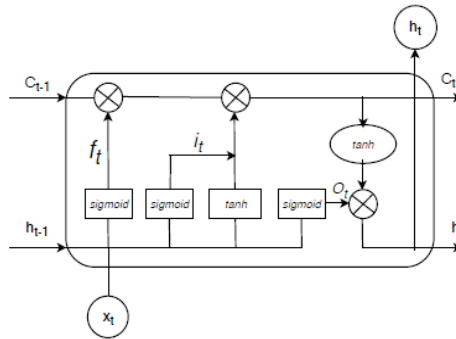
<sup>4</sup> Hochreiter, Schmidhuber

<sup>5</sup> Gated mechanism

<sup>6</sup> Gate

$$\sigma(z) = (1 + e^{-z})^{-1}$$

(۲)



شکل ۱- معماری داخلی یک LSTM (نگوین و یون، ۲۰۱۹)

محاسبات برای گیت فراموشی ( $f_t$ )، گیت ورودی ( $i_t$ )، گیت خروجی ( $o_t$ )، حالت سلول ( $c_t$ ) و حالت پنهان ( $h_t$ ) با استفاده از فرمول های زیر

انجام می شود:

$$f_t = \sigma(W_f \times x_t + U_f \times h_{t-1} + b_f) \quad (۳)$$

$$i_t = \sigma(W_i \times x_t + U_i \times h_{t-1} + b_i) \quad (۴)$$

$$o_t = \sigma(W_o \times x_t + U_o \times h_{t-1} + b_o) \quad (۵)$$

$$c_t = f_t \times c_{t-1} + i_t \times \tanh(W_c \times x_t + U_c \times h_{t-1} + b_c) \quad (۶)$$

$$h_t = o_t \times \tanh(c_t) \quad (۷)$$

که در آن  $U_c, U_o, U_i, U_f, W_c, W_o, W_i, W_f, b_c, b_o, b_i, b_f$  بردارهای بایاس هستند (مغار و هامیچه<sup>۲</sup>، ۲۰۲۰).

## ۲.۲. تبدیل داده های متنی به بردار

برای تبدیل متن به بردار عددی قابل فهم برای شبکه عصبی، در این تحقیق از FastText استفاده شد. FastText یک کتابخانه منبع باز، رایگان و سبک است که به کاربران اجازه می دهد تا بازنمایی متن و طبقه بندی متن را بیاموزند. روی سخت افزار استاندارد و عمومی کار می کند. FastText یک برنامه افزودنی برای Word2Vec است که توسط فیس بوک در سال ۲۰۱۶ برای یادگیری کارآمد بازنمایی کلمات و طبقه بندی جملات ایجاد شده است. FastText به جای قرار دادن کلمات جداگانه در شبکه عصبی، کلمات را به چند زیر کلمه<sup>۳</sup> تقسیم می کند. پس از آموزش شبکه عصبی، با توجه به مجموعه داده آموزش، تعبیه کلمه برای همه زیر کلمه ها را خواهیم داشت که می توان کلمات کمیاب را به درستی نشان داد، زیرا به احتمال زیاد برخی از زیر کلمه ها در کلمات دیگر نیز وجود دارد. FastText امکان می دهد تا کلمات و جملات را تحت نظارت و بدون نظارت آموزش داد. این تعبیه ها<sup>۴</sup> می تواند برای برنامه های کاربردی متعدد از فشرده سازی داده ها، به عنوان ویژگی هایی در مدل های اضافی، برای انتخاب نامزد، یا به عنوان تنظیم کننده برای انتقال یادگیری استفاده شود.

## ۳.۲. مروری بر مطالعات پیشین

در این بخش مرور مختصری بر تحقیقات پیشین در زمینه پیش بینی بازار سهام در دو بخش تحقیقات خارجی و تحقیقات داخلی ذکر می شود.

<sup>11</sup> Nguyen and Yoon

<sup>2</sup> Moghar, Hamiche

<sup>3</sup> n-gram

<sup>4</sup> Embedding

## الف) تحقیقات خارجی

با بررسی مقالات مرتبط با پیش بینی بازار بورس درمی یابیم که در اکثر مقالات از سری زمانی استفاده شده است. روش سری زمانی یک مدل رابطه آماری است که شاخص قیمت سهام را با چارچوب سری زمانی ترکیب می کند. مدل های کلاسیک شامل مدل RW (مدل تصادفی کامل) و مدل میانگین متحرک رگرسیون خودکار است. در (خاشعی و حاجی رحیمی، ۲۰۱۹) نویسندگان از مدل آرما برای پیش بینی بازار بورس استفاده کردند. در روش سری های زمانی (مدل ناپایداری یکنواخت)، با توجه به متغیرهای موجود در مدل، برای تشخیص تک متغیره و چند متغیره روش اندازه گیری برای تصمیم گیری مدل چند متغیره و انتخاب پارامترها، تجزیه و تحلیل داده های پیچیده زیادی مورد نیاز است (ژانگ و لو، ۲۰۲۰). شواهد تجربی نشان می دهد که روش سری زمانی ممکن است تاثیر خوبی بر پیش بینی کوتاه مدت قیمت سهام داشته باشد. با این حال، اگر دوره پیش بینی بسیار طولانی باشد، دقت پیش بینی مدل سری زمانی به کاهش خود ادامه می دهد (ژو<sup>۲</sup> و همکاران، ۲۰۱۹). در سال های اخیر، با توسعه سریع تئوری و الگوریتم هوش مصنوعی، شبکه عصبی بدون شک تحقیقات داغ در کاربرد شبکه های عصبی برای پیش بینی قیمت سهام بوده است. در زمینه مالی، بسیاری از محققان در اروپا و آمریکا شبکه های عصبی را مورد مطالعه و استفاده قرار داده اند (ژانگ و لو، ۲۰۲۰). هیرانشا<sup>۳</sup> و همکاران (هیرانشا و همکاران، ۲۰۱۸) چهار مدل یادگیری عمیق مانند شبکه عصبی پیچشی<sup>۴</sup>، LSTM، شبکه عصبی بازگشتی و پرسپترون چند لایه<sup>۵</sup> را برای پیش بینی قیمت سهام بررسی کرد. آنها دریافتند که مدل های یادگیری عمیق بهتر از مدل های غیر خطی مانند مدل میانگین متحرک رگرسیون خودکار هستند.

چن<sup>۶</sup> و همکاران (چن و همکاران، ۲۰۱۸) سه روش سنتی مانند شبکه عصبی تابع پایه شعاعی، ماشین یادگیری افراطی و شبکه عصبی پس انتشار را با یادگیری عمیق مقایسه کرد و دریافت که مدل های یادگیری عمیق قابلیت های پیش بینی بهتری را نشان می دهند.

کاتایاما<sup>۷</sup> (کاتایاما، ۲۰۱۹) یک مدل یادگیری عمیق مبتنی بر شناسایی قطبیت احساسات برای پیش بینی بازار مالی پیشنهاد کرد. رویکرد آنها می تواند پیش بینی بازار مبتنی بر قطبیت را بهبود بخشد.

سینگ<sup>۸</sup> و همکاران (سینگ و همکاران، ۲۰۱۹)، از داده های مربوط به متون خبری، برای فهم نیروهای روان بازار سرمایه، از یک مدل هیبرید مبتنی بر ماشین بردار پشتیبان، نزدیک ترین همسایگی و جنگل های تصادفی در کنار الگوریتم یادگیری عمیق LSTM استفاده شده است. داده های مورد استفاده شامل متون خبری است که با استفاده از پردازش زبان طبیعی - به ویژگی های داده ای برای مدل ها تبدیل شده اند. هدف این مدل ترکیب کمک به سرمایه گذاران سهام تازه کار در بورس می باشد.

لیو و لانگ<sup>۹</sup> (لیو و لانگ، ۲۰۲۰)، با ترکیب روش تبدیلات موجک با روش یادگیری عمیق LSTM، - توانسته نقاط پرت موجود در داده های سری زمانی را در موقعیت های زمانی مختلف پیش بینی کند و اینگونه با بهبود عملکرد مدل پیش بینی در تشخیص نقاط پرت، منجر به افزایش تعمیم پذیری مدل در پیش بینی قیمت سهام شود.

در پژوهش دیگر در سال ۲۰۲۰، با هدف اعمال مهندسی ویژگی کارآمد، یک شبکه عصبی عمیق ترکیبی حاصل از مدل شبکه های عصبی عمیق پیچشی به منظور فهم دوره های زمانی مشابه در داده ها و سپس پیش بینی مقادیر قیمت با الگوریتم LSTM دوره های زمانی مشابه و در نهایت

<sup>1</sup> Zhang and Lou

<sup>2</sup> Zhou

<sup>3</sup> Hiransha

<sup>4</sup> Convolutional Neural Network (CNN)

<sup>5</sup> Multilayer perceptron

<sup>6</sup> Chen

<sup>7</sup> Katayama

<sup>8</sup> Singh

<sup>9</sup> Liu and Long

ارائه پیش بینی نهایی با استفاده از ساختار- یکپارچه ارائه شده است. این مدل ترکیبی که به صورت سری کار می کند، قادر است رفتارهای مشابه و نقطه ی تغییر این رفتارها را در گذر زمان شناسایی کند و از این رو، نقاط عطف قیمتی سهام ها را پیش بینی نماید(هائو و گائو<sup>۱</sup>، ۲۰۲۰). در یک مدل ترکیب مبتنی بر شبکه های عصبی عمیق در سال ۲۰۲۰، مدل ترکیبی بر مبنای تجزیه سری زمانی با الگوریتم<sup>۲</sup> CEEMD در کنار استخراج مهمترین ویژگی ها با تحلیل مولفه اساسی و سپس پیش بینی با الگوریتم یادگیری عمیق LSTM می باشد. تجزیه سری زمانی به عوامل فصلی، روند و تصادفی و پیش بینی جداگانه هر سری منجر به افزایش دقت مدل عمیق در پیش بینی شده است (ژانگ و همکاران، ۲۰۲۰). مشابه این رویکرد در (پانگ<sup>۳</sup> و همکاران، ۲۰۲۰) نیز پیاده سازی شده است.

در (چانگ و شیک شین<sup>۴</sup>، ۲۰۲۰)، ترکیب الگوریتم ژنتیک با شبکه های عصبی عمیق پیشگیری<sup>۵</sup> مورد بررسی قرار گرفته است. با توجه به وجود پارامترهای زیاد در مدل شبکه عصبی عمیق پیشگیری، از الگوریتم ژنتیک به منظور به پیدا کردن بهترین ترکیب پارامترها بدین منظور استفاده شده است. این الگوریتم ترکیبی نسبت به مدل های مرجع پیاده سازی شده عملکرد قابل توجهی از خود نشان داده است. به صورت کلی، طبق اذعان این مقاله، بدون بهینه سازی پارامتر کارا در الگوریتم های عمیق، امکان دستیابی به دقت بالا وجود نخواهد داشت. با این حال بهینه سازی پارامترها ویژه داده های مربوط به هر سهم به صورت مجزا بسیار زمان بر بوده و این مورد از ضعف های چنین بهینه سازی هایی برشمرده شده است. چن و همکاران (چن و همکاران، ۲۰۲۰) مدل یادگیری عمیق ترکیبی را بر اساس LSTM، پرسپترون چند لایه و مکانیسم توجه پیشنهاد کرد. مدل آنها دقت پیش بینی بهتری دارد. با این حال، آنها قصد دارند در آینده آن را با مدل های احساسی بهبود بخشند.

پولاموری و همکاران (پولاموری و همکاران، ۲۰۲۱) Stock-GAN را که یک چارچوب مبتنی بر GAN<sup>۶</sup> برای پیش بینی قیمت سهام پیشنهاد شده است. LSTM و شبکه عصبی پیشگیری به عنوان مدل های مولد و تفکیک کننده استفاده می شوند. GAN ویژگی های انتخابی را از روش شناسی پیش پردازش جدید دریافت می کند. نتایج GAN به منظور تنظیم فرآیندهای هر دو مدل در Stock-GAN تحت یادگیری تقویتی و بهینه سازی بیزی قرار می گیرند. برای تقریب سهام از مدل خطی مانند مدل میانگین متحرک اتورگرسیو استفاده می شود.

لیلی و همکاران (لیلی و همکاران، ۲۰۲۱) رویکرد پروفیت<sup>۷</sup> را پیشنهاد کردند که اهمیت زمان را برای بهبود دقت پیش بینی، برجسته کرد. کتابخانه پروفیت سه فرآیند به نام های فصلی، روند و تعطیلات را تعریف می کند. هر یک از این پارامترها گرانش زمان را در پیش بینی بازار سهام روشن می کند. نویسندگان از مجموعه داده یک شرکت خدمات مالی چندملیتی بنام سانتاندر<sup>۸</sup> استفاده کردند که شامل قیمت سهام گروه سانتاندر است که در اسپانیا واقع شده است. علاوه بر این، شانزدهمین موسسه بانکی بزرگ در جهان است. فرض بر این بود که داده هایی که به داده های قابل پیش بینی نزدیک تر هستند، در مقایسه با داده های تاریخی اهمیت بیشتری دارند و این فرضیه تأیید شد، که نشان دهنده اهمیت داده های مبتنی بر زمان برای پیش بینی دقیق است.

## ب) تحقیقات داخلی

در زمینه کارهای داخلی نیز می توان به سنایی و همکاران (سنایی و همکاران، ۱۳۸۴) اشاره کرد که سعی در پیش بینی شاخص بورس اوراق بهادار تهران با استفاده از شبکه های عصبی مصنوعی داشتند. کمیجانی و سعادت فر در (کمیجانی و سعادت فر، ۱۳۸۵) کاربرد مدل های شبکه عصبی در پیش بینی ورشکستگی اقتصادی شرکتهای بازار بورس را بررسی کردند.

<sup>1</sup> Hao and Gao

<sup>2</sup> ensemble empirical mode decomposition (CEEMD)

<sup>3</sup> Pang

<sup>4</sup> Chung and shik Shin

<sup>5</sup> Convolutional Neural Networks

<sup>6</sup> Generative Adversarial Network

<sup>7</sup> Prophet

<sup>8</sup> Santander

ویسی زاده و همکاران (ویسی زاده و همکاران، ۱۴۰۰) با ارائه مدلی ترکیبی، ارزش در معرض ریسک شبیه سازی تاریخی فیلتر شده (FHS) (مبتنی بر تبدیل موجک با رویکرد استفاده از مزایای مدل FHS و مزایای تبدیل موجک به عنوان یک پیش پردازشگر بر روی داده خام بورس تهران پرداختند.

زینی وند و همکاران (زینی وند و همکاران، ۱۴۰۰)، سعی بر این دارند که تورش های رفتاری سرمایه گذاران و تاثیر آن بر تصمیمات مالی آنها در نقاط حمایت و مقاومت سهم، به عنوان محرکی برای تقویت یا تضعیف برخی تورش های رفتاری مورد مطالعه قرار گیرد. نتایج این پژوهش نشان داد که تورش های رفتاری سرمایه گذاران حقیقی و حقوقی اثرات متفاوتی بر تصمیمات سرمایه گذاری آنها در سطوح مقاومت و حمایت داشته اند و همچنین تورش های رفتاری در بین سرمایه گذاران حقیقی، قدرت پیش بینی کنندگی بیشتری از تصمیمات سرمایه گذاری آنها داشته است. عبدی و همکاران (عبدی و همکاران، ۱۴۰۰)، مدلی ترکیبی برای بهینه سازی سبد سهام براساس پیش بینی قیمت با شبکه عصبی بازگشتی LSTM به کمک محدودیت های کاردینالیتی و روش های تصمیم گیری چندمعیاره برای بورس اوراق بهادار تهران ارائه دادند. آنها با کمک شبکه عصبی بازگشتی حافظه کوتاه مدت ماندگار قیمت سهام در افق های زمانی مورد نظر را پیش بینی کردند. در گام بعد با روش راه حل سازشی ترکیبی، سه سبد سهام با افق زمانی کوتاه مدت، میان مدت و بلند مدت انتخاب و در نهایت براساس مدل دارایی محدود مارکویتز با استفاده از روش برنامه ریزی کوادراتیک مرز کارای سرمایه گذاری را رسم کردند.

با توجه به مرور مقالات پیشین که در رابطه با پیش بینی بازار بورس می باشند می توان دریافت که عموماً مقاله های بررسی شده، توجه خود را به داده های سری زمانی مربوط به قیمت سهم ها معطوف کرده اند. در برخی از مقاله ها نیز، از داده های متون خبری و نیز در برخی موارد، ترکیبی از داده های مربوط به دفاتر نقدی، استفاده شده است. نکته مهم در اینجا، کاربرد قابل استخراج می باشد. بدین صورت که اگر هدف شناخت نیروهای روانی بازار سرمایه باشد، معمولاً داده های متون خبری مورد توجه قرار می گیرد. اما در پیش بینی قیمت سهام عمدتاً داده های سری زمانی سهم ها ملاک قرار گرفته است و بنظر می رسد روش های ترکیبی کارایی مناسبی دارند. همچنین می توان دریافت، LSTM می تواند تغییرات داده های زمانی را بهتر از شبکه عصبی بازگشتی ثبت کند. از سوی دیگر در می یابیم که مدل های یادگیری عمیق از فقدان پیش پردازش (یا کیفیت داده ها) رنج می برند، مگر اینکه یک رویکرد مبتنی بر پردازش زبان طبیعی کارآمد نسبت به انتخاب ویژگی وجود داشته باشد. با توجه به نقص و نقاط قوت کارهای پیشین، در روش پیشنهادی از یک روش ترکیبی بر اساس LSTM و ترکیب آن با روش تعبیه متن، بمنظور طراحی سیستم توصیه گر برای پیش بینی بازار سهام استفاده می شود.

### ۳. سوالات و فرضیه های پژوهش

با مرور ادبیات و تحقیقات انجام شده این سوالات مطرح شد که

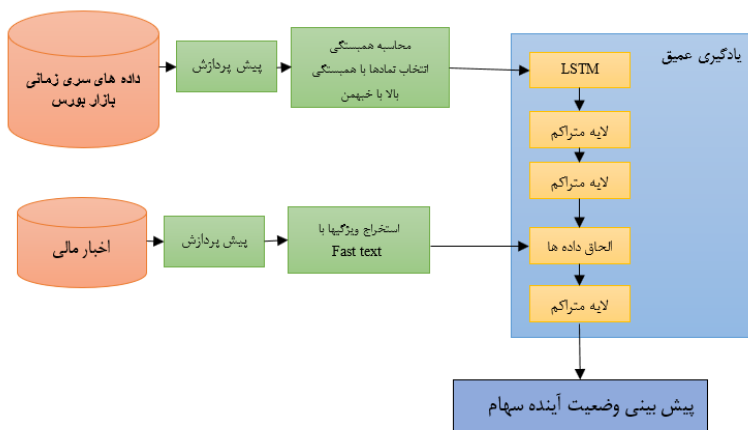
۱. چگونه می توان مدل ترکیبی مبتنی بر الگوریتم های یادگیری عمیق با دقت بالا در پیش بینی قیمت سهام طراحی کرد.
  ۲. چگونه می توان مدل ترکیبی مبتنی بر LSTM طراحی کرد تا با خطای کمتر بازار سهام را پیش گویی کند.
- از میان سوال های تحقیق موجود و بر اساس مرور ادبیات صورت گرفته، می توان فرضیه های زیر را استخراج نمود:
۱. مدل ترکیبی مبتنی بر الگوریتم های یادگیری عمیق، دقت بالایی در پیش بینی قیمت سهام دارند.
  ۲. می توان مدل ترکیبی مبتنی بر LSTM طراحی کرد تا با خطای کمتر بازار سهام را پیش گویی کند.

### ۴. روش شناسی

روش پیشنهادی ترکیبی از روش های سری زمانی و متن کاوی اخبار مربوط به بازار بورس است. در روش پیشنهادی داده های سری زمانی گردآوری و پیش پردازش شده به عنوان ورودی به شبکه های عصبی عمیق LSTM داده می شود، از سوی دیگر داده های خبری با کمک Fasttext کاوش شده و ویژگیها استخراج می گردند. در گام آخر ویژگی های استخراج شده از متون خبری و شبکه های عصبی عمیق LSTM



پس از عبور از یک لایه متراکم<sup>۱</sup> آینده سهام را پیش بینی می کند. داده های سری زمانی آرایش منظم داده ها یا مجموعه ای از نقاط داده است که یک متغیر در بازه های زمانی مساوی می گیرد. هدف از تجزیه و تحلیل سری های زمانی ایجاد مدل هایی است که قادر به توصیف سری های زمانی معین با دقت معقولی باشند. در سال های اخیر شاهد افزایش چند برابری در تحقیقات در رابطه با مدل سازی سری های زمانی بوده ایم. نمادی که برای این تحلیل انتخاب شده است نماد خپهمن است. نماد خپهمن در صنعت خودرو و ساخت قطعات فعال است و در بورس ثبت نام شده است. خپهمن جزو شرکت های بزرگ بازار سرمایه می باشد که از لحاظ ارزش شرکت در رتبه 3 گروه خودش و در رتبه 52 کل بازار قرار دارد. که متعلق به گروه خودرویی می باشد. برای اینکه پیش بینی های دقیق تری داشته باشیم از رفتار سایر نمادهای این گروه نیز استفاده شده است. با توجه به اینکه لزوماً تمام نمادهای گروه خودرویی همبستگی بالایی با نماد خپهمن ندارند، ابتدا همبستگی نمادهای این گروه با نماد خپهمن محاسبه شد و فقط نمادهایی مورد استفاده قرار گرفت که همبستگی بالایی با این نماد دارند. به منظور در نظر گرفتن جنبه روانی بازار، اخبار مرتبط با بازار بورس نیز استفاده شد. ابتدا اخبار مرتبط با این حوزه به کمک یادگیری عمیق به بردارهای عددی تبدیل شدند. سپس این بردارها از یک طرف، و شبکه LSTM از طرف دیگر در یک شبکه عصبی عمیق به کار گرفته شدند. مراحل مدل پیشنهادی در شکل ۲ نشان داده شده است.



شکل ۲- مراحل مدل پیشنهادی

#### ۴-۱ پیش پردازش

برای بدست آوردن اخبار بورس با بررسی آرشیو اخبار سایت های بورسی و برخی کانال های شبکه های مجازی متن های خبری دریافت می شود. در مرحله پیش پردازش اولین و آخرین تاریخ ثبت اطلاعات روزانه نماد و تعداد کل داده های ثبت شده در این بازه نمایش داده شده، نمادهایی که تعداد رکورد آن خیلی کم باشد (بیشتر روزها بسته بوده نماد) حذف می شوند.

داده های از دست رفته را با درونیایی خطی<sup>۲</sup> جایگذاری می شود. درونیایی خطی به معنای برآورد مقدار از دست رفته از طریق اتصال نقاط در یک خط مستقیم با افزایش ترتیب است. به طور خلاصه، مقدار ناشناخته را به همان ترتیب افزایشی از مقادیر قبلی تخمین می زند.

در مرحله پیش پردازش، نرمالسازی داده های نیز انجام می گیرد. نرمالسازی داده ها روشی برای یکنواخت کردن بازه مقادیر مربوط به متغیرهای مختلف پژوهش است و به بی مقیاس سازی داده ها نیز معروف است. اگر واحد سنجش متغیرهای مورد مطالعه متنوع باشد با استفاده از روش های نرمالسازی می توان داده ها را بی مقیاس کرد. برای نرمال سازی ویژگیها از تکنیک نرمالسازی Min-Max استفاده می شود. در این تکنیک

<sup>1</sup> Dense layer

<sup>2</sup> Interpolation Linear

نرمالسازی، یک تبدیل خطی بر روی داده های اولیه انجام می شود. حداقل و حداکثر مقدار از داده ها واکنشی می شود و هر مقدار مطابق فرمول ۸ جایگزین می شود. نرمالسازی Min-Max روابط بین مقادیر داده اصلی را حفظ می کند.

$$A' = \frac{A - \text{min value of } A}{\text{max value of } A - \text{min value of } A} \quad (8)$$

که در آن  $A'$  حاوی داده های نرمال شده Min-Max است و  $A$  محدوده داده های اصلی باشد.

#### ۲-۴ محاسبه همبستگی

در ادامه روند کار طبق فلوجارت شکل ۲ محاسبه همبستگی انجام می گیرد. یکی از نکات مهم بازار بورس، دانستن روابط بین نمادهای بورسی است. بین نمادها و شرکتهای بورسی روابط مختلفی وجود دارد و برخی از نمادها به دلایل مختلف روی یکدیگر اثرگذار هستند که یک سرمایه گذار یا معامله گر با دانستن این روابط می تواند زودتر از دیگران فرصت ها را در بازار شناسایی کند.

روابط بین نمادهای بورسی بسیار گسترده هستند. روابط همگروهی یکی از معروف ترین روابط بورسی است. معمولاً شرکتهای همگروه که در یک صنعت خاص فعالیت می کنند، روی یکدیگر اثر گذار هستند و رفتار مشابهی دارند

در ادامه همبستگی ستون قیمت بسته شدن تمامی نمادها با هم محاسبه می شود. برای این منظور استفاده از ضریب همبستگی پیرسون پیشنهاد شده است. ضریب همبستگی یک مفهوم کلی در ریاضیات و علم آمار است و در بورس نیز کاربرد دارد. در واقع یک ابزار آماری محسوب می شود که می تواند نوع و درجه رابطه دو متغیر کمی را مشخص کند. به بیان دیگر ضریب همبستگی بین دو متغیر (که می تواند نمودار قیمتی دو نماد بورسی باشد)، می تواند نوع (مستقیم و مثبت و یا معکوس و منفی) و شدت رابطه (میزان وابستگی) را مشخص کند. این ضریب بین ۱ تا -۱ است و در صورت عدم وجود رابطه بین دو متغیر، برابر صفر است. یکی از مشهورترین شیوه های اندازه گیری وابستگی بین دو متغیر کمی، محاسبه ضریب همبستگی پیرسون است.

فرض کنید  $X$  و  $Y$  دو متغیر تصادفی هستند که دارای امیدریاضی  $E(X)$  و  $E(Y)$  و واریانس  $V(X)$  و  $V(Y)$  هستند. ضریب همبستگی بین  $X$  و  $Y$  را با  $\rho(X, Y)$  یا  $\text{corr}(X < Y)$  نشان داده و با فرمول ۹ محاسبه می کنیم.

$$p(X, Y) = \text{corr}(X, Y) = \frac{E[(X - E(X))(Y - E(Y))]}{[V(X)V(Y)]^{\frac{1}{2}}} \quad (9)$$

صورت این کسر همان کوواریانس بین دو متغیر  $X$  و  $Y$  محسوب می شود. منظور از  $E$  نیز، امید ریاضی دو متغیر تصادفی  $X$  و  $Y$  است. ستون مربوط به قیمت پایانی تمام نمادها را با توجه به روز در مقابل هم قرار گرفت. همبستگی ستون قیمت بسته شدن تمامی نمادها با هم محاسبه شد. نمادهایی که بیشترین همبستگی را با نماد خبهمن دارند تعیین گردید.

#### ۳-۴ شبکه های عصبی عمیق حافظه های طولانی کوتاه مدت

پس از اینکه نمادهای با بیشترین همبستگی با نماد خبهمن تعیین شد، در مرحله بعد شبکه های عصبی عمیق حافظه های طولانی کوتاه مدت مدل سازی می شود. در این تحقیق از چارچوب یادگیری عمیق کراس<sup>۱</sup> استفاده شده است. امروزه چارچوب های یادگیری عمیق زیادی وجود دارد. کراس پذیرش گسترده ای در صنعت و جامعه تحقیقاتی دارد. کراس با بیش از یک میلیون کاربر فردی تا اواخر سال ۲۰۲۱، هم در صنعت و هم در جامعه تحقیقاتی مورد استقبال قرار گرفته است. همراه با TensorFlow 2، کراس بیش از هر راه حل یادگیری عمیق دیگری پذیرش دارد. در حال حاضر دائماً با ویژگی های ساخته شده با کراس در تعامل هستیم. این ویژگی در Square, Zocdoc, Instacart, Yelp, Uber, Netflix و این ویژگی در بسیاری دیگر مورد استفاده قرار می گیرد. این امر به ویژه در میان استارتاپ هایی که یادگیری عمیق را در هسته محصولات خود قرار می دهند

<sup>1</sup> Keras

بسیار محبوب است. کراس و TensorFlow 2 نیز در بین محققان مورد علاقه هستند و از نظر ذکر در مقالات علمی نمایه شده توسط Google Scholar در رتبه اول قرار دارند. کراس همچنین توسط محققان در سازمان های علمی بزرگ مانند سرن<sup>1</sup> و ناسا پذیرفته شده است. در روش پیشنهادی از توابع فعال سازی که معمولاً در معماری های پرسپترون چند لایه یافت می شوند، تابع سیگموئید مورد استفاده قرار گرفته است. شبکه با پارامترهای optimizer=Adam و loss=MAE و activation\_function=sigmoid و بر روی داده های آموزش مدل سازی انجام می شود. پارامترهای مورد بررسی شامل تعداد EPOCH، تعداد سلول های LSTM، اضافه کردن لایه متراکم<sup>2</sup> به معماری شبکه و BATCH SIZE، که نتایج و دیگر پارامتر مورد ارزیابی تعداد روز قبل برای ورودی شبکه است. لایه متراکم بعد از لایه LSTM اضافه شد. لایه متراکم یا لایه کاملاً متصل در واقع لایه ای است که هر نورون به تمام نورون های لایه بعدی متصل می شود.

#### ۴-۴ لایه متراکم

در هر شبکه عصبی، لایه متراکم به لایه ای گفته می شود که عمیقاً به لایه قبلی خود متصل است، به این معنی که نورون های لایه به هر نورون لایه قبلی متصل هستند. این لایه پرکاربردترین لایه در شبکه های عصبی مصنوعی است. نورون لایه متراکم در یک مدل از هر نورون لایه قبلی خود خروجی دریافت می کند، به طوری که نورون های لایه متراکم ضرب ماتریس-بردار را انجام می دهند. ضرب بردار ماتریس روشی است که در آن بردار ردیف خروجی از لایه های قبلی، برابر با بردار ستون لایه متراکم است. قانون کلی ضرب ماتریس-بردار این است که بردار سطر باید به اندازه بردار ستون، ستون داشته باشد.

نتایج حاصل از هر نورون لایه های قبلی به تک تک نورون های لایه متراکم می رود. بنابراین می توان گفت که اگر لایه قبلی با ترکیب نتایج هر نورون یک ماتریس (M x N) خروجی دهد، این خروجی از لایه متراکم عبور می کند که تعداد نورون ها در یک لایه متراکم باید N باشد. در روش پیشنهادی داده های سری زمانی بورس پس از پیش پردازش و محاسبه همبستگی داده ها به شبکه یادگیری عمیق با دو لایه متراکم تحویل داده می شوند. کراس به وسیله کد ۱ لایه متراکم را مهیا می کند.

```
Dense Layer from Keras
tf.keras.layers.Dense(
    units,
    activation=None,
    use_bias=True,
    kernel_initializer="glorot_uniform",
    bias_initializer="zeros",
    kernel_regularizer=None,
    bias_regularizer=None,
    activity_regularizer=None,
    kernel_constraint=None,
    bias_constraint=None,
    **kwargs )
```

کد ۱) لایه متراکم با دستور کراس

واحدها (units) یکی از اساسی ترین و ضروری ترین پارامترهای لایه متراکم کراس هستند که اندازه خروجی لایه متراکم را مشخص می کنند که باید یک عدد صحیح مثبت باشد زیرا ابعاد بردار خروجی را نشان می دهد. در شبکه های عصبی، تابع فعال سازی، Activation تابعی است که برای تبدیل مقادیر ورودی نورون ها استفاده می شود. اساساً به صورت تابع غیرخطی وارد شبکه های عصبی می شود تا شبکه ها بتوانند رابطه

<sup>1</sup> CERN

<sup>2</sup> Dense layer

بین مقادیر ورودی و خروجی را یاد بگیرند. پارامتر Use\_Bias برای تصمیم گیری در مورد اینکه آیا می خواهیم یک لایه متراکم از بردار بایاس استفاده کند یا خیر استفاده می شود. kernel\_initializer برای مقداردهی اولیه ماتریس وزن هسته استفاده می شود. ماتریس وزن ماتریسی از وزن ها است که با ورودی ضرب می شوند تا هسته های ویژگی مربوطه استخراج شوند. bias\_initializer برای مقداردهی اولیه بردار بایاس استفاده می شود. بردار بایاس را می توان به عنوان مجموعه وزن اضافی که نیازی به ورودی ندارد و با لایه خروجی مطابقت دارد تعریف کرد. به طور پیش فرض صفر تنظیم شده است.

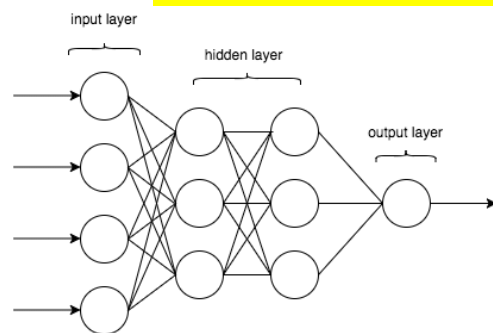
اگر ماتریسی را در kernel\_initializer مقداردهی اولیه کرده باشیم، از این پارامتر برای منظم کردن ماتریس وزن هسته استفاده می شود. اگر هر بردار را در bias\_initializer مقداردهی اولیه کرده باشیم، از پارامتر bias\_regularizer برای منظم کردن بردار بایاس استفاده می شود. به طور پیش فرض، به عنوان هیچ تنظیم شده است. Activity\_regularizer برای تنظیم تابع فعال سازی که در پارامتر فعال سازی تعریف کرده ایم استفاده می شود. روی خروجی لایه اعمال می شود. به طور پیش فرض، به عنوان هیچ تنظیم شده است. kernel\_constraint برای اعمال تابع محدودیت در ماتریس وزن هسته استفاده می شود. به طور پیش فرض، به عنوان هیچ تنظیم شده است. Bias\_constraint برای اعمال تابع محدودیت در بردار بایاس استفاده می شود. به طور پیش فرض، به عنوان هیچ تنظیم شده است.

همانطور که در پارامترها دیدیم، سه ویژگی اصلی داریم: تابع فعال سازی، ماتریس وزن و بردار بایاس. با استفاده از این ویژگی ها یک عملیات لایه متراکم را می توان به صورت زیر نشان داد:

$$\text{Output} = \text{activation}(\text{dot}(\text{input}, \text{kernel}) + \text{bias})$$

که اگر ماتریس ورودی برای لایه متراکم دارای رتبه ای بیش از ۲ باشد، حاصل ضرب نقطه ای بین هسته و ورودی در امتداد آخرین محور ورودی و محور صفر هسته با استفاده از tf.tensordot محاسبه شده توسط لایه متراکم در صورتی که use\_bias نادرست است.

در روش پیشنهادی داده های سری زمانی بورس پس از پیش پردازش و محاسبه همبستگی داده ها به شبکه یادگیری عمیق با دو لایه متراکم تحویل داده می شوند. شکل ۳ یک شبکه عصبی با دو لایه متراکم را نشان می دهد.



شکل ۳) شبکه عصبی با دو لایه متراکم

#### ۴-۵ تحلیل احساسات و اخبار

یکی از نوآوری های این تحقیق افزودن احساسات بازار به تحلیل های سری زمانی است. برای این منظور برای درک بهتر تاثیر احساسات بازار و تاثیر اخبار بر روی نمادها، با استفاده از متون خبری سایت های بورسی تحلیل کامل تری انجام می شود. برای این کار اخبار بورس با بررسی آرشیو اخبار سایت های بورسی نظیر تجارت نیوز، بورس پرس، سنا و برخی کانال های شبکه های مجازی متن های خبری دریافت می شود. با قرار دادن داده های خبری بدست آمده در مقابل نماد مورد نظر و سایر نمادهای مرتبط هم گروه با این نماد بر اساس تاریخ، مجموعه داده جدید بدست می آید. که همانند قبل روزهای پر تلاطم بورس که افزایش قیمت ها غیر واقعی بود از این مجموعه داده حذف می شود.


در این مرحله باید متن اخبار را به بردار عددی قابل فهم برای شبکه عصبی تبدیل کرد. برای این منظور از Fast Text استفاده می شود. FastText یک مدل تعبیه کلمه است و کتابخانه منبع باز، رایگان و سبک است که توسط فیس بوک در سال ۲۰۱۶ برای یادگیری کارآمد بازنمایی کلمات و طبقه بندی جملات ایجاد شده است و به کاربران اجازه می دهد تا بازنمایی متن و طبقه بندی متن را بیاموزند. برای زبان فارسی چندین مدل تعبیه کلمه از جمله Word2Vec، GloVe، و FastText ارائه شده است (زاهدی و همکاران، ۲۰۱۸). زاهدی و همکاران (زاهدی و همکاران، ۲۰۱۸) مقایسه کاملی از مدل ها ارائه کردند و نشان دادند که FastText و Word2Vec از مدل های دیگر بهتر عمل می کنند. بنابراین در روش پیشنهادی از FastText بهره برده شده است.

#### ۴-۶ الحاق داده ها

پس از اینکه بردارها از داده های خبری توسط Fast Text و ویژگی ها از داده های سری زمان به وسیله شبکه های عصبی عمیق LSTM دو لایه متراکم استخراج شد، با هم الحاق می شوند و نتایج مطابق با مدل ترکیبی پیشنهادی پس از یک لایه متراکم صادر می شود. در این بخش، نحوه اجرای یک لایه متراکم در یک شبکه عصبی با یک لایه متراکم واحد و یک شبکه عصبی با یک متراکم را شرح می دهیم.

```
A sequential model with a single dense layer
import tensorflow
model = tensorflow.keras.models.Sequential()
model.add(tensorflow.keras.Input(shape=(16,)))
model.add(tensorflow.keras.layers.Dense(32, activation='relu'))
print(model.output_shape)
print(model.compute_output_signature)
```

کد ۲) یک مدل متوالی با یک لایه متراکم



شکل ۴) شبکه عصبی با یک لایه متراکم

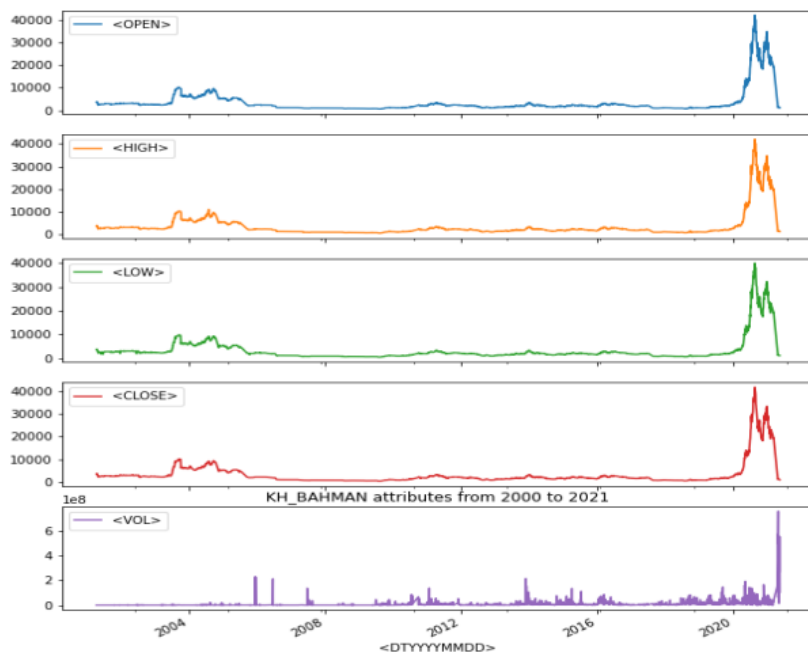
شکل ۴ نشان دهنده شبکه عصبی با یک لایه پنهان است. اگر لایه پنهان را به عنوان لایه متراکم در نظر بگیریم، تصویر می تواند شبکه عصبی را با یک لایه متراکم نشان دهد. در این حالت مدل از یک لایه کراس استفاده می کند.

#### ۵. یافته ها

در این مدل سازی یکبار به صورت تک متغیره یعنی همان متغیر هدف که قیمت بسته شدن نماد است، با استفاده از LSTM مدل سازی می شود، و در مرحله دوم، به کمک قیمت بسته شدن سایر نمادهای با همبستگی بالا با این نماد مدل سازی انجام می شود. در مرحله سوم علاوه بر داده های بازار بورس، داده های شبکه های خبری نیز به نتایج افزوده می شود. عملکرد مدل پیشنهادی با استفاده از معیارهایی مانند مجذور مربعات خطا<sup>۱</sup> (RMSE) ارزیابی می شود. برای مقایسه روش پیشنهادی با روشهای دیگر، روش پیشنهادی را با روش آریمما (خاشعی و حاجی رحیمی، ۲۰۱۹) و روش پروفت (لیلی و همکاران، ۲۰۲۱) مقایسه می کنیم.

<sup>1</sup> Root Mean Squared Error


برای ارزیابی مدل پیشنهادی از کتابخانه پانداس<sup>۱</sup> پایتون بمنظور خواندن فایلها استفاده شده است. پانداس، یک کتابخانه متن‌باز است که کارایی بالا، ساختاری با قابلیت استفاده آسان و ابزارهای تحلیل داده برای زبان برنامه نویسی پایتون را فراهم می‌کند. پس از خواندن گروه خودرویی از فایلها، نمادهایی که رکورد کمتری دارند حذف می‌شوند. همبستگی ستون قیمت بسته شدن تمامی نمادها با هم بدست آمد. و نمادهای (خ بهمن ، خ چرخش، خ کمک، خ شرق، خ کار، ورنه، خ پویش، خ محور، خودرو) که بیشترین همبستگی را با هم دارند حفظ شد. برای پیش بینی نماد خ بهمن تمام اطلاعات روزانه ۸ نماد دیگر مقابل این نماد قرار گرفت.



شکل ۵- طول عمر نماد خبهمن از سال ۲۰۰۰ تا سال ۲۰۲۱

برای متغیرهای نماد خ بهمن نمودار خطی کل طول عمر نماد از سال ۲۰۰۰ تا سال ۲۰۲۱ در نمودار شکل ۵ رسم شده است. در این نمودارها قیمت بازگشایی و قیمت بسته شدن برحسب ریال، همچنین حجم معاملات و کمترین و بیشترین میزان معاملات قابل مشاهده است. همانطور که قابل مشاهده است در بسیاری از روزها قیمت بسته شدن با قیمت باز شدن و قیمت حداقل و حداکثر روزانه برابر می‌باشد این نشان دهنده ثابت بودن قیمت نماد در یک روز دارد. برای نمادهای با همبستگی بالا با نماد خبهمن مثل چرخش ، کمک ، ورنه ، خودرو و... برای قیمت بسته شدن، نمودار خطی طول عمر کل نمادها در کنار هم رسم شد. همانطور که قابل مشاهده است تغییرات قیمت بسته شدن این نمادهای گروه خودرویی به هم وابسته است.

<sup>۱</sup> Pandas



شکل ۶- نمودار خطی قیمت بسته شدن طول عمر نمادهای وابسته به خپهم

در ادامه مدل سازی با شبکه عصبی و LSTM انجام می گیرد. در این مدل سازی یکبار به صورت تک متغیره انجام گرفت؛ یعنی متغیر هدف با همان قیمت بسته شدن نماد خ بهمن مدل سازی انجام شد، و یکبار به کمک قیمت بسته شدن سایر نمادهای با همبستگی بالا با این نماد در گروه خودرویی مدل سازی انجام شد.

شبکه با پارامترهای optimizer=Adam و loss=MAE و activation\_function=sigmoid و بر روی داده های آموزش مدل سازی انجام شد. پارامترهای مورد بررسی شامل تعداد ایپوک، تعداد سلول های LSTM، اضافه کردن لایه متراکم به معماری شبکه و اندازه دسته، که نتایج در جدول ۱ قابل مشاهده است. دیگر پارامتر مورد ارزیابی تعداد روز قبل برای ورودی شبکه که برای آن اعداد ۱، ۲، ۳ و ۷ آزمایش شد.

جدول ۱- مدل سازی تک متغیره با شبکه عصبی و LSTM

تعداد سلول LSTM	EPOCH	اندازه دسته	متراکم	تعداد روز مشاهده از قبل	RMSE
۵۰	۱۰۰	۷۲	None	۱	۹۱.۴۱۶
۵۰	۱۰۰۰	۷۲	None	۱	۹۳.۴۹۷
۵۰	۱۰۰۰	۸۰	None	۱	۹۵.۳۶۱
۵۰	۱۰۰۰	۶۴	None	۱	۸۸.۸۴۹
۵۰	۱۰۰۰	۵۶	None	۱	۹۸.۳۸۸
۵۰	۱۰۰۰	۸۸	None	۱	۹۰.۳۱۱
۱۰۰	۱۰۰۰	۸۸	None	۱	۹۱.۰۶۶
۵۰	۱۰۰۰	۸۸	۵۰،۲۰،۲۰	۱	۹۰.۶۴۷
۵۰	۱۰۰۰	۸۸	None	۲	۸۴.۴۷۷
۵۰	۱۰۰۰	۸۸	None	۳	۸۸.۲۶۷
۱۰۰	۱۰۰	۷۲	۲۰،۴۰	۱	۱۱۱.۲۳
۱۰۰	۱۰۰	۷۲	۲۰،۴۰	۲	۱۵۸.۷۳
۱۰۰	۱۰۰	۷۲	۲۰،۴۰	۳	۱۹۶.۳۵
۱۰۰	۱۰۰	۷۲	۲۰،۴۰	۷	۲۲۰.۶۴
۵۰،۱۰۰	۱۰۰۰	۸۰	۳۰،۲۰،۱۰	۲	۱۸۰.۳۶
۵۰،۱۰۰	۱۰۰۰	۸۰	۳۰،۲۰،۱۰	۳	۲۴۰.۱۱
۵۰،۱۰۰	۱۰۰۰	۸۰	۳۰،۲۰،۱۰	۷	۲۷۰.۳۶
۲۰۰	۳۰۰	۷۲	None	۱	۱۶۱.۳۵
۲۰۰	۳۰۰	۷۲	None	۲	۱۴۳.۱۲
۲۰۰	۳۰۰	۷۲	None	۳	۱۹۶.۱۸
۲۰۰	۳۰۰	۷۲	None	۷	۲۳۱.۸۶

منبع: یافته های پژوهشگر

جدول ۲- مدل سازی چند متغیره با شبکه عصبی و LSTM

تعداد سلول LSTM	EPOCH	اندازه دسته	متراکم	تعداد روز مشاهده از قبل	RMSE
۱۰۰	۱۰۰	۷۲	۲۰، ۴۰	۱	۱۴۰، ۳۲
۱۰۰	۱۰۰	۷۲	۲۰، ۴۰	۲	۱۱۱، ۲۶
۱۰۰	۱۰۰	۷۲	۲۰، ۴۰	۳	۱۰۵، ۱۲
۱۰۰	۱۰۰	۷۲	۲۰، ۴۰	۷	۱۷۰، ۶۶
۵۰، ۱۰۰	۱۰۰۰	۸۰	۳۰، ۲۰، ۱۰	۲	۱۸۰، ۳۲
۵۰، ۱۰۰	۱۰۰۰	۸۰	۳۰، ۲۰، ۱۰	۳	۲۰۰، ۰۲
۵۰، ۱۰۰	۱۰۰۰	۸۰	۳۰، ۲۰، ۱۰	۷	۲۲۰، ۶۵
۲۰۰	۳۰۰	۷۲	None	۱	۱۶۰، ۳۲
۲۰۰	۳۰۰	۷۲	None	۲	۱۱۰، ۶۴
۲۰۰	۳۰۰	۷۲	None	۳	۱۸۰، ۶۵
۲۰۰	۳۰۰	۷۲	None	۷	۲۰۰، ۵
۵۰	۱۰۰	۷۲	None	۱	۱۱۹، ۳۹۹
۵۰	۱۰۰۰	۷۲	None	۱	۱۱۲، ۴۹۶
۵۰	۱۰۰۰	۸۰	None	۱	۶۶، ۳۳۴
۵۰	۱۰۰۰	۶۴	None	۱	۱۲۳
۵۰	۱۰۰۰	۵۶	None	۱	۱۰۶، ۷۷۲
۵۰	۱۰۰۰	۸۸	None	۱	۷۱، ۱۶۹
۱۰۰	۱۰۰۰	۸۸	None	۱	۸۴، ۸۸
۵۰	۱۰۰۰	۸۸	۳۰، ۲۰، ۱۰	۱	۸۹، ۸۸۲
۵۰	۱۰۰۰	۸۸	None	۲	۶۴، ۹۱۴
۵۰	۱۰۰۰	۸۸	None	۳	۱۳۹، ۳۷۳
۵۰	۱۰۰۰	۸۸	None	۷	۱۸۵، ۰۹۲

منبع: یافته های پژوهشگر

همانطور که در جدول ۲ مشخص است بهترین راه حل، مدل استفاده از الگوریتم شبکه عصبی و لایه LSTM با پارامترهای تعداد سلول ۵۰، ساخت متغیر lag دوروزه، تعداد ایپوک برابر ۱۰۰۰ مرتبه بود که میزان پائین ترین خطا در پیش بینی قیمت بسته شدن نماد خبهنم را داشت. و همچنین استفاده از قیمت بسته شدن سایر نمادهای با همبستگی بالا با این نماد در بالا بردن دقت مدل تاثیر مثبت داشت.

با توجه به نوسانات غیر واقعی ۳۰۰ روز پایانی دیتا برای تحلیل و مدل سازی این قسمت از دیتا کنار گذاشته شد. مدل سازی با آریمما و الگوریتم پروفت یکبار فقط به صورت تک متغیره خود متغیره هدف همان قیمت پیلانی مورد بررسی قرار گرفت، یکبار با کمک بقیه متغیرها شامل بالاترین قیمت روزانه، پائین ترین قیمت روزانه، قیمت باز شدن روزانه و حجم معاملات خود نماد و قیمت بسته شدن نمادهای با همبستگی بالا با ایجاد lag متغیرها و یکبار با rolling متغیرها انجام گرفت که نتایج در جدول ۳ قابل مشاهده می باشد. شایان ذکر است که ۴۰۰ روز از انتهای داده به عنوان داده آزمایش و ۳۶۰۰ روز ابتدائی داده به عنوان داده آموزش مورد استفاده قرار گرفت، و معیار ارزیابی مجذور مربعات خطا یا همان RMSE بود. همانطور که در جدول ۳ دیده می شود روش پیشنهادی در هر دو روش مدل سازی تک متغیره و چند متغیره میزان مجذور مربعات

خطای کمتری نسبت به روش های پروفت و آریمما دارد.


جدول ۳- مقایسه نتایج مدل های مختلف

مدل	RMSE
الگوریتم پروفت بدون متغیرهای کمکی سایر نمادها	۸۴۳، ۳۶۸
الگوریتم پروفت با ساخت rolling هفت روزه متغیرها با کمک متغیرهای بقیه نمادها	۱۴۳، ۴۸




الگوریتم پروفت با ساخت lag یک روزه متغیرها با کمک متغیرهای بقیه نمادها	۱۱۴.۹۶۶
مدل آریمما	۱۲۸.۴۳۵
مدل سازی چند متغیره با شبکه عصبی و LSTM	۶۴.۹۱۴
مدل سازی تک متغیره با شبکه عصبی و LSTM	۹۰.۶۴۷

منبع: یافته های پژوهشگر



شکل ۸- خطای مدل در فاز آموزش و آزمایش را در ۱۰۰۰ ایپوک

منبع: یافته های پژوهشگر



شکل ۷- مقدار پیش بینی شده توسط مدل و مقدار واقعی قیمت بسته شدن نماد خبهمن در ۴۰۰ روز پایانی داده ها

منبع: یافته های پژوهشگر

شکل ۷ مقدار پیش بینی شده توسط مدل و مقدار واقعی قیمت بسته شدن نماد خبهمن در ۴۰۰ روز پایانی داده ها را نشان می دهد. شکل ۸ خطای مدل در فاز آموزش و آزمایش را در ۱۰۰۰ ایپوک نشان می دهد.

برای درک بهتر تاثیر احساسات بازار و تاثیر اخبار بر روی نماد ها، با استفاده از متون خبری سایت های بورسی تحلیل کامل تری انجام می شود. برای این کار ابتدا برای بدست آوردن اخبار بورس با بررسی آرشیو اخبار سایت های بورسی نظیر تجارت نیوز، بورس پرس، سنا و برخی کانال های شبکه های مجازی، با توجه به اینکه تاریخچه سایت تجارت نیوز بیشتر از بقیه سایت ها بود با استفاده از تکنیک های وب کاوی و کتابخانه سلیوم متن های خبری از تاریخ ۲۰۱۷/۰۵/۱۵ (اولین روزی که اخبار در آرشیو سایت موجود بود) تا تاریخ ۲۰۲۱/۰۹/۰۵ از سایت تجارت نیوز دریافت شد. با قرار دادن داده های خبری بدست آمده در مقابل نماد خبهمن و ۸ نماد مرتبط هم گروه با این نماد بر اساس تاریخ دیتا ست جدید با ۸۹۷ روز برای تحلیل بدست آمد که همانند قبل روزهای پر تلاطم بورس که افزایش قیمت ها غیر واقعی بود از این دیتا ست حذف شد و نهایتا این تحلیل و پیش بینی با ۵۰۰ روز از دیتا ست انجام گردید که ۴۰۰ روز به عنوان داده آموزش و ۱۰۰ روز به عنوان داده آزمایش برای ارزیابی مدل ترکیبی مورد استفاده قرار گرفت.

برای مقایسه تحلیل بدون در نظر گرفتن متون خبری و با متون خبری پیش بینی این دیتا ست در دو حالت بدون ویژگی های متون خبری و با استفاده از ویژگی های بدست آمده از Fast Text برای متون خبری درباره بازار بورس انجام شد که برای هر دو حالت پارامترها و معماری های مختلف با هم مقایسه شد که نتایج در جدول ۴ قابل مشاهده است.


جدول ۴- مقایسه نتایج بدون در نظر گرفتن داده های خبری و با استفاده از داده های خبری

بدون استفاده از داده های خبری				
RMSE	اندازه دسته	تعداد نوروں های لایه های متراکم	تعداد EPOCH	تعداد سلول LSTM

۱۰۰,۵۰	۵۰۰	۲۰,۵۰	۱۶	۲۵۰,۹۶۸
۱۰۰	۴۰۰	۲۰	۶۴	۲۲۰,۴۵۱
۵۰	۱۰۰۰	-----	۸	۲۰۶,۴۲۷
۵۰	۲۰۰	-----	۶۴	۸۵,۱۲۸
۵۰	۴۰۰	۲۰,۳۰	۳۲	۱۷۰,۳۲۲
<b>با استفاده از داده های خبری</b>				
LSTM تعداد سلول	EPOCH تعداد	تعداد نورون های لایه های مترکم	اندازه دسته	RMSE
۱۰۰,۵۰	۴۰۰	-----	۱۲۸	۹۸,۱۵۸
۱۰۰,۵۰	۶۰۰	۳۰,۲۰	۶۴	۹۵,۶۲۴
۱۰۰	۶۰۰	۵۰,۳۰,۱۰	۳۲	۷۸,۴۱۲
۵۰	۵۰۰	۵۰,۳۰,۱۰	۶۴	۷۲,۴۲۶
۵۰	۴۰۰	-----	۱۲۸	۷۶,۱۴۵


منبع: یافته های پژوهشگر

نتیجه اینکه در نظر گرفتن اخبار مرتبط با بورس به پیش بینی کمک می کند همانطور که در جدول ۴ مشخص است هنگامی که از داده های خبری در تحلیل کمک گرفتیم میزان خطا کاهش یافت و پیش بینی ها بهتر انجام شد و نتیجه بهترین پارامتر ها و معماری شبکه عصبی که منجر به کمترین میزان خطا شده بود در زیر نمایش داده شده است.



شکل ۱۰- میزان خطا در فاز آموزش روی داده های آموزش

منبع: یافته های پژوهشگر



شکل ۹- حرکت واقعی بازار و مقادیر پیش بینی شده توسط مدل ترکیبی

منبع: یافته های پژوهشگر

در شکل ۹ همانطور که مشخص است خط آبی حرکت واقعی بازار و خط قرمز رنگ مقادیر پیش بینی شده توسط مدل ترکیبی می باشد. شکل ۱۰ نمایانگر میزان خطا در فاز آموزش روی داده های آموزش است همانطور که مشهود است در فاز آموزش همگرایی در ایپوک های اولیه اتفاق افتاده ولی همگرایی فاز آزمایش در ایپوک ۴۰۰ اتفاق افتاده است.

## ۶. نتیجه گیری و بحث

پیش بینی بازار سهام به دلیل عدم قطعیت های متفاوتی که بر قیمت بازار تأثیر می گذارد، کار بسیار دشواری است که شامل رویدادهای سیاسی، اقتصادی و احساسات سرمایه گذاران است. بازار سهام در طبیعت پویا و پر نویز است و نوسانات قیمت بازار سهام منجر به نوسانات تصادفی می شود. یک الگوریتم پشتیبانی تصمیم مالی می تواند تصمیم گیری سرمایه گذاران را پس از افشای صورت های مالی تا حد زیادی تسهیل کند و می تواند به شناسایی سهام سودمند مالی و اعمال مالکیت کمک کند. هر چقدر الگوریتم مورد استفاده قدرتمند و کامل باشد، پیش گویی ها درست تر خواهد بود پس لازم است از الگوریتم های کارا برای این امر استفاده شود که با میزان خطای کمتر و دقت مناسب توان پیش بینی را داشته

باشد. تحقیقات گذشته عموماً توجه خود را به داده‌های سری زمانی مربوط به قیمت سهام معطوف کرده‌اند. گستردگی داده‌های مورد استفاده، عملاً دستیابی به رویکردی متن و کارا در پیش بینی قیمت اکثریت سهم‌ها در بازارهای سرمایه مختلف را به دست نمی‌دهد. با توجه به اینکه علاوه بر تاریخچه هر سهم، عوامل سیاسی و روانی دیگری بر ارزش هر سهم تأثیر می‌گذارد، در این تحقیق یک مدل ترکیبی بر اساس LSTM و تعبیه متن پیشنهاد می‌شود که علاوه بر داده‌های سری زمانی، به منظور بررسی نیروی روانی بازار، ویژگی‌هایی را نیز از سایتهای خبری استخراج می‌کند و براساس ترکیب داده‌های خبری و داده‌های سری زمانی آینده بازار سهام را پیش بینی می‌کند. نتایج ارزیابی نشان داد که با ترکیب داده‌های استخراج شده از شبکه‌های خبری و افزودن آن به داده‌های سری زمانی بازار بورس، مدل پیشنهادی توانست به خوبی آینده بازار را پیش بینی نماید.

در انجام پژوهش حاضر محدودیت‌های اجرایی و روش شناختی وجود داشت. محدوده زمانی داده‌های سری زمانی بازار بورس و همچنین محدوده زمانی داده‌های خبری، همچنین استفاده از تنها چند سایت خبری به عنوان داده‌های خبری بازار بورس، از محدودیت‌های این تحقیق می‌باشد. برای انجام تحقیق از داده‌های ۲۶ نماد گروه خودرویی از تاریخ شروع تا تاریخ ۲۰۲۱/۵/۱۸ از سایت [www.tsetmc.com](http://www.tsetmc.com) استفاده شد.

با توجه به اینکه پیکربندی شبکه‌های عصبی عمیق یک کار چالش برانگیز است برای کارهای آینده پیشنهاد می‌شود تا با جزئیات و پارامترهای بیشتر، شبکه LSTM را دقیقتر آموزش داد و دستاوردهای عملکرد پیش‌بینی‌کننده حاصل از یادگیری عمیق برای داده‌های روزانه (از جمله اثرات تأخیر احتمالی) و درازمدت مورد بررسی قرار گیرد. همچنین می‌توان روی تعداد لایه‌های پنهان شبکه‌های عصبی یادگیری عمیق بررسی نمود. با توجه به پیشرفت‌های صورت گرفته در الگوریتم‌های فراابتکاری، می‌توان به روش‌های ترکیبی بر پایه الگوریتم‌های فراابتکاری برای پیش بینی بازار بورس نیز توجه داشت و وزن‌های شبکه عصبی عمیق را با کمک این الگوریتم‌ها تنظیم نمود.

موجک‌ها<sup>۱</sup> نتیجه تبدیل‌های زمان-فرکانس برای به دست آوردن نمایشی از تغییرات محلی در مقیاس‌های مختلف هستند. موجک‌ها می‌توانند به عنوان روشی پیچیده‌تر برای استخراج اطلاعات مربوطه از بازه‌های زمانی سری‌های قیمت سهام استفاده شوند. از آنجایی که موجک‌ها برای حذف نویز سیگنال‌ها مفید هستند، برای کارهای آینده بررسی تأثیر موجک در استخراج اطلاعات برای پیش بینی قیمت سهام پیشنهاد می‌شود.

## ۷. تعارض منافع

هیچ گونه تعارض منافع توسط نویسندگان بیان نشده است.

## منابع

- سینایی حسعلی، مرتضوی سعیداله، تیموری اصل یاسر. (۱۳۸۴). پیش بینی شاخص بورس اوراق بهادار تهران با استفاده از شبکه‌های عصبی مصنوعی، بررسی‌های حسابداری و حسابرسی، پاییز ۱۳۸۴، دوره ۱۲، شماره ۴۱، از صفحه ۵۹ تا صفحه ۸۳.
- داودی، سید محمدرضا، عبدالباقی عطاآبادی، عبدالمجید، یوسفی، جواد. (۱۴۰۱). سودمندی راهبردهای سرمایه‌گذاری مبتنی بر تناوب زمانی در بورس اوراق بهادار تهران: تحلیل محتوایی نوسانگرهای هارمونیک و تناوب موج. *اقتصاد مالی* شماره ۱۶ دوره ۵۸، صفحه ۱۳۹-۱۵۸.
- زینی وند، محمد، جنانی، محمد حسن، همت فر، محمود، ستایش، محمدرضا. (۱۴۰۰). سوگیریهای رفتاری و تصمیمات سرمایه‌گذاران حقیقی و حقوقی مبتنی بر اطلاعات تکنیکال در بورس اوراق بهادار تهران. *اقتصاد مالی* 15(57), 233-258. doi: 10.30495/fed.2021.687929
- کیمیجانی اکبر، سعادت فر جواد. (۱۳۸۵). کاربرد مدل‌های شبکه عصبی در پیش بینی ورشکستگی اقتصادی شرکتهای بازار بورس، جستارهای اقتصادی، پاییز و زمستان ۱۳۸۵، دوره ۳، شماره ۶، از صفحه ۱۱ تا صفحه ۴۴.
- عبدی، نسیمه. مرادزاده فرد، مهدی. احمدزاده، حمید، خدام محمود (۱۴۰۰). ارائه مدل ترکیبی بهینه‌سازی سبد سهام براساس پیش بینی قیمت با شبکه عصبی بازگشتی LSTM به کمک محدودیت‌های کاردینالیتی و روش‌های تصمیم‌گیری چندمعیاره (مطالعه موردی بورس اوراق بهادار تهران). فصلنامه علمی چشم انداز مدیریت مالی، دوره ۱۱، شماره ۳۶.
- ویسی زاده، وحید، شکرخواه، جواد، امیری، میثم. (۱۴۰۰). مدل ترکیبی ارزش در معرض ریسک شبیه سازی تاریخی فیلتر شده مبتنی بر تبدیل موجک در افقهای زمانی سرمایه‌گذاری مختلف در بورس اوراق بهادار تهران. *اقتصاد* 15(57), 1-22. doi: 10.30495/fed.2021.687929

<sup>1</sup> Wavelets

- A. Tsantekidis, N. Passalis, A. Tefas, J. Kannianen, M. Gabbouj, and A. Iosifidis. (2017). Forecasting stock prices from the limit order book using convolutional neural networks. *Proc. - 2017 IEEE 19th Conf. Bus. Informatics, CBI 2017, 1*, pp. 7–12.
- Adil MOGHAR , Mhamed Hamiche. (2020). Stock Market Prediction Using LSTM Recurrent Neural Network. *Procedia Computer Science, 170*, 1168–1173.
- Chen, L., Qiao, Z., Wang, M., Wang, C., Du, R., Stanley, H.E., . (2018). Which artificial intelligence algorithm better predicts the chinese stock market? . *IEEE Access, 6*, 48625–48633.
- Chen, Q., Zhang, W., Lou, Y.u. (2020). Forecasting stock prices using a hybrid deep learning model integrating attention mechanism, multi-layer perceptron, and bidirectional long-short term memory neural network. . *IEEE Access., 8*, 117365–117376.
- D. Zhang and S. Lou,. (2020). The application research of neural network and BP algorithm in stock price pattern classification and prediction. . *Future Generation Computer Systems.*
- Dattatray P. Gandhmal, K. Kumar, . (2019). Systematic analysis and review of stock market prediction techniques. *Comput. Sci. Rev. , 34*, 1-13.
- David O. Oyewola , Asabe Ibrahim, Joshua.A. Kwanamu , Emmanuel Gbenga Dada . (2021). A new auditory algorithm in stock market prediction on oil and gas sector in Nigerian stock exchange . *Soft Computing Letters, 3*.
- David Oyewola, Emmanuel Gbenga Dada, Ezekiel Olaoluwa Omole, K.A. Al- Mustapha. (2019). Predicting Nigerian stock returns using technical analysis and machine learning. *Eur. J. Electric. Comput. Eng. , 3(2)*, 1-8.
- E. Avci. (2007). Forecasting daily and seasonal returns of the ISE-100 Index with neuralnetwork models. *Dogus Univ. J., 8(2)*, 128-142.
- H. Chung and K. shik Shin. (2020). Genetic algorithm-optimized multi-channel convolutional neural network for stock market prediction. *Neural Comput. Appl., 32(12)*, 7897–7914.
- H. Liu and Z. Long. (2020). An improved deep learning model for predicting stock market price time series. *Digit. Signal Process. A Rev. J., 102*, 102741.
- Hiransha, M., Gopalakrishnan, E.A., Menon, V.K., Soman, K.P. (2018). NSE stock market prediction using deep-learning models. *Procedia Comput. Sci. , 132*, 1351–1362.
- Hosseni Ebrahimabad, S.A., Jahangiri, Kh, Hasan Heydari, H., Ghaemi Asl, M. (2019) Study of Shock and Volatility Spillovers among Selected Indices of the Tehran Stock Exchange Using Asymmetric BEKK-GARCH Model. *Applied Economics Studies, Iran (AESI). 7(29)*. 123-155.
- Hochreiter, S. , Schmidhuber, J. , " Long short-term memory.," *Neural computation* , vol. 9, no. 8, p. 1735–1780 ., 1997.
- Huang, G. (2021). Missing data filling method based on linear interpolation and lightgbm. *Journal of Physics: Conference Series , 1754*.
- I. Goodfellow, Y. Bengio, A. Courville. (2017). Deep Learning. *MIT Press, Cambridge.*
- K. Chourmouziadis, P.D. Chatzoglou, . (2016). An intelligent short term stock trading fuzzy system for assisting investors in portfolio management. . *Expert Syst. Appl. , 43*, 298–311.
- Khashei M, Hajirahimi Z (2019) A comparative study of series arima/mlp hybrid models for stock price forecasting. Commun Stat Simul Comput 48(9):2625–2640.**
- Katayama, D. K. (2019). A method of sentiment polarity identification in financial news using deep learning. *Procedia Comput. Sci., 159*, 1287–1294.
- Katayama, D., Kino, Y., Tsuda, K. (2019). A method of sentiment polarity identification in financial news using deep learning. *Procedia Comput. Sci. , 159*, 1287–1294.
- Liu, Y., Zeng, Q., Yang, H., Carrio, A. (2018). Stock price movement prediction from financial news with deep learning and knowledge graph embedding. . *Springer International Publishing.*
- Lilly, Sheeba, S; Gupta, Neha; Ragavender, R M Anirudh; Divya, D. (2021) . Time Series Model for Stock Market Prediction Utilising Prophet. *Turkish Journal of Computer and Mathematics Education; Trabzon . 12(6)*, 4529-4534.
- Mai, F., Tian, S., Lee, C., Ma, L. (2019). Deep learning models for bankruptcy prediction using textual disclosures. *Eur. J. Oper. Res., 274*, 743–758.
- Mathias Kraus, Stefan Feuerriegel, . (2017). Decision support from financial disclosures with deep neural networks and transfer learning. *Decision Support Systems.*
- Nau, R. (2014). Mathematical structure of ARIMA models. *1*, 1-8.
- Polamuri, S.R., Srinivas, K., Krishna Mohan, A. (2019). Stock market prices prediction using random forest and extra tree regression. *Int. J. Recent Technol. Eng. , 8*, 1224-1228.
- Nguyen Thi-Thu, Yoon Seokhoon .(2019). A Novel Approach to Short-Term Stock Price Movement Prediction using Transfer Learning. *Appl. Sci, 9*, 4745; doi:10.3390/app9224745.
- R. Sutkatti and D. A. Torse. (2008). Stock Market Forecasting Techniques: A Survey. *Int. Res. J. Eng. Technol., 4842*, 4842–4844.
- Reza Ramezani, Arsalan Peymanfar, Seyed Babak Ebrahimi. (2019). An integrated framework of genetic network programming and multi-layer perceptron neural network for prediction of daily stock return: An application in Tehran stock exchange market . *Applied Soft Computing Journal , 82*, 1-16.
- S. Feuerriegel, H. Prendinger, . (201). News-based trading strategies, . *Decision Support Systems , 90*, 65-74.
- S. Singh, M. Ahmad, A. Bhattacharya, and M. Azhagiri. (2019). Predicting stock market trends using hybrid SVM model and LSTM with sentiment determination using natural language processing. *Int. J. Eng. Adv. Technol., 9(1)*, 2870–2875.

- Subba Rao Polamuri, Kudipudi Srinivas, A. Krishna Mohan . (2021). Multi-Model Generative Adversarial Network Hybrid Prediction Algorithm (MMGAN-HPA) for stock market prices prediction . *Journal of King Saud University – Computer and Information Sciences*.
- Vargas, M.R., De Lima, B.S.L.P., Evsukoff, A.G. (2017). Deep learning for stock market prediction from financial news articles. *2017 IEEE Int. Conf. Comput. Intell. Virtual Environ. Meas. Syst. Appl. CIVEMSA 2017* , (pp. 60-65).
- X. Pang, Y. Zhou, P. Wang, W. Lin, and V. Chang. (2020). An innovative neural network approach for stock market prediction., *J. Supercomput.*, 76(3), 2098–2118.
- Y. Hao and Q. Gao,. (2020). Predicting the trend of stock market index using the hybrid neural network based on multiple time scale feature learning. *Appl. Sci.*, 10(11).
- Y. Libo, Y. Q. (2016). Predicting the oil prices: Do technical indicators help. *Energ. Econo.* , 56, 338–350.
- Y. Xu, C. Yang, S. Peng, and Y. Nojima. (2020). A hybrid two-stage financial stock forecasting algorithm based on clustering and ensemble learning. *Appl. Intell.*
- Y. Zhang, B. Yan, and M. Aasma,. (2020). A novel deep learning framework: Prediction and analysis of financial time series using CEEMD and LSTM. *Expert Syst. Appl.*, 159, 113609.
- Zahedi Mohammad Sadegh, Bokaei Mohammad Hadi, Shoeleh Farzaneh, Yadollahi Mohammad Mehdi, Doostmohammadi Ehsan, Mojgan Farhoodi., "Persian word embedding evaluation benchmarks," *Electrical Engineering (ICEE), Iranian Conference*, pp. 1583–1588,, 2018.
- Zhang, Z., Zohren, S., Roberts, S. (2019). DeepLOB: Deep convolutional neural networks for limit order books. . *IEEE Trans. Signal Process.*, 67(11), 3001–3012.
- Zhou S , Shen C Y , Zhang L , et al. . (2019). Dual-optimized adaptive Kalman filtering algorithm based on BP neural network and variance compensation for laser absorption spectroscopy[J]. . *Optics Express*, 27(22).