



## پیش‌بینی قیمت سهام شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران با استفاده از شبکه مولد تخصصی

رضا راعی<sup>۱\*</sup>

علی نمکی<sup>۲</sup>

سعید باجلان<sup>۳</sup>

سارا نجف زاده<sup>۴</sup>

تاریخ دریافت: ۱۴۰۱/۰۷/۲۷ تاریخ پذیرش: ۱۴۰۲/۰۲/۱۷

### چکیده

سرمایه‌گذاران زمانی مایل به سرمایه‌گذاری در بازار سرمایه می‌باشند که بتوانند سود مناسبی از فعالیت خود کسب نمایند و این مهم از طریق داشتن پیش‌بینی مناسب از روندها و قیمت‌های آتی امکان‌پذیر است. در این راستا شبکه‌های یادگیری عمیق توانسته‌اند کمک زیادی به پیش‌بینی روند حرکتی بازار سرمایه داشته باشند. یادگیری عمیق به دلیل ظرفیت قوی در فرآیند داده‌کاوی اخیراً در بسیاری از زمینه‌ها به موفقیت‌های زیادی دست یافته‌است. به عنوان مثال، در زمینه‌های مالی از جمله پیش‌بینی حرکت بازار سهام، بهینه‌سازی سبد سهام، پردازش اطلاعات مالی و ... به طور گسترده استفاده شده است. اخیراً شبکه‌های مولد تخصصی (GAN) با هدف تحلیل و پیش‌بینی داده‌های سری زمانی نتایج قابل قبولی نشان دادند. از اینرو در این مقاله، شبکه GAN متشکل از شبکه عصبی پیچشی به عنوان مولد و حافظه کوتاه مدت طولانی در شبکه متخاصم برای پیش‌بینی قیمت سهام، پیشنهاد شده‌است. علاوه بر این به منظور افزایش دقت پیش‌بینی قیمت سهام در آموزش شبکه از روش‌های انتخاب ویژگی استفاده شده‌است. نتیجه پژوهش بر روی داده‌های روزانه بورس اوراق بهادار تهران در سال‌های ۱۳۹۴ تا ۱۳۹۸ نشان می‌دهد که دقت پیش‌بینی شبکه GAN در صورت آموزش با استفاده از مناسبترین ویژگی‌ها تا ۱۰ درصد نسبت به سایر شبکه‌های یادگیری عمیق برتری دارد. نتایج تجربی این مدل نشان می‌دهد که شبکه GAN با معماری مذکور می‌تواند عملکرد امیدوارکننده‌ای در پیش‌بینی قیمت سهام در مقایسه با سایر مدل‌های یادگیری عمیق داشته باشد.

واژه‌های کلیدی: یادگیری عمیق، شبکه مولد تخصصی، پیش‌بینی بازار سهام، بازارهای مالی.

<sup>۱</sup>استاد، گروه مالی و بیمه، دانشکده مدیریت دانشگاه تهران، تهران، ایران (نویسنده مسئول) [raei@ut.ac.ir](mailto:raei@ut.ac.ir)

<sup>۲</sup>استادیار، گروه مالی و بیمه، دانشکده مدیریت دانشگاه تهران، تهران، ایران. [alinamaki@ut.ac.ir](mailto:alinamaki@ut.ac.ir)

<sup>۳</sup>استادیار، گروه مالی و بیمه، دانشکده مدیریت دانشگاه تهران، تهران، ایران. [saeedbajalan@ut.ac.ir](mailto:saeedbajalan@ut.ac.ir)

<sup>۴</sup>کارشناس ارشد، گروه مالی و بیمه، دانشکده مدیریت، دانشگاه تهران، تهران، ایران [rjj3260@gmail.com](mailto:rjj3260@gmail.com)

## ۱- مقدمه

بازار بورس به عنوان پشتوانه اقتصاد کشورها و نبض اقتصاد جهانی محسوب می‌شود. در این بازار این امکان فراهم می‌شود که پس اندازهای کوچک به نحو بهینه در مسیر حرکت به سوی سرمایه‌گذاری‌های بزرگ قرار گیرد. بورس از طریق جذب سرمایه‌ها و پس‌اندازهای راکد موجود در جامعه و هدایت آن‌ها در امور تولیدی منجر به افزایش تولید و رشد اقتصادی می‌شود و از طریق کاهش نقدینگی موجود در جامعه، متغیرهایی نظیر حجم پول، نرخ تورم و نرخ بهره را تحت تأثیر قرار می‌دهد [۲]. پیش‌بینی مناسب از رفتار آتی بازار اوراق بهادار دارای اهمیت فراوانی است و با توجه به نقش مهمی که بازار سهام در رشد اقتصادی ایفا می‌کند، تحلیل رفتار و پیش‌بینی آنی آن می‌تواند در دستیابی به اهداف اقتصادی بسیار موثر واقع شود [۴]. به منظور جذب پس اندازها و دستیابی به اهداف کلان اقتصادی، لازم است افراد جامعه به سرمایه‌گذاری در این بازار ترغیب شوند و از آنجایی که سرمایه‌گذاری در این بازار با ریسک و عدم اطمینان همراه است یکی از مهم‌ترین گام‌ها، تلاش در جهت کاهش ریسک سرمایه‌گذاری بوده و بی‌تردید پیش‌بینی بازار یکی از ابزارهای کاهش ریسک می‌باشد. با توجه به این موضوع که در کشور ایران ضریب نفوذ بورس در جامعه بسیار پایین‌تر از متوسط جهانی است، تلاش در جهت افزایش مشارکت مردم به منظور توسعه بازار و در نهایت توسعه اقتصاد کشور ضروری می‌باشد. سرمایه‌گذاران زمانی مایل به سرمایه‌گذاری در بازار سرمایه می‌باشند که بتوانند سود مناسبی از فعالیت خود کسب نمایند و این مهم از طریق داشتن پیش‌بینی مناسب از روندها و قیمت‌های آتی امکان‌پذیر است.

## ۲- طرح مسئله تحقیق

هدایت و جذب نقدینگی سرگردان جامعه و ایجاد شرایط مناسب برای کسب بازدهی بیشتر از این منابع پولی برای کل جامعه حایز اهمیت است. صاحبان سرمایه‌های کوچک نه

توانایی آن را دارند که از سرمایه خود بازده مناسبی به دست آورند و نه حجم اقتصادی امروزی به آن‌ها اجازه خواهد داد به تنهایی از تولید برخوردار بوده و در به حرکت در آوردن گوشه‌ای از چرخ اقتصادی جامعه فعال باشند اما در صورتی که همین سرمایه‌های کوچک با مکانیزم مناسب جمع‌آوری شوند، می‌توانند کارایی بالایی را برای جامعه به ارمغان آورند. یکی از مهم‌ترین ابزارها و مکانیزم‌هایی که توانایی جذب نقدینگی را دارد، بازار اوراق بهادار می‌باشد. نقش اصلی بازار اوراق بهادار جذب و هدایت نقدینگی سرگردان و پراکنده جامعه به مسیرهای بهینه است. در واقع وظیفه اصلی بازار اوراق بهادار تخصیص بهینه منابع مالی کمیاب است. از آن جایی که ویژگی اصلی سرمایه‌گذاری ریسک آن است، صاحبان پس‌انداز یا سرمایه‌گذاران باید مطمئن شوند که بر اساس ریسکی که متحمل می‌شوند بازدهی مناسب از سرمایه‌گذاری خود به دست می‌آورند [۱]، به همین منظور افزایش دقت و قدرت پیش‌بینی بازار در جهت کاهش ریسک سرمایه‌گذاران و ترغیب آنان به سمت بازار سرمایه ضروری می‌باشد. پیش‌بینی قیمت سهام در دنیای مالی حایز اهمیت است زیرا یک پیش‌بینی با دقت قابل قبول و متعارف، توانایی کسب منافع مالی و پوشش ریسک بازار را فراهم می‌کند. تحقیقات در زمینه پیش‌بینی بازار سهام دارای سابقه‌ای طولانی در اقتصاد مالی است. اگرچه دیدگاه‌ها در خصوص کارایی بازار متفاوت است، اما بسیاری با مطالعات تجربی انجام شده در این حوزه که قابلیت پیش‌بینی بازار را تا حدودی ثابت کرده‌اند، هم نظر می‌باشند. لذا هدف از انجام این پژوهش پیش‌بینی روزانه قیمت سهام در بورس اوراق بهادار تهران با استفاده از داده‌های مربوط به سهام و انتخاب بهترین ویژگی‌ها جهت افزایش دقت پیش‌بینی شبکه مولد تخصصی ( $GAN^1$ ) است.

## ۳- مبانی نظری و پیشینه تحقیق

### ۳-۱- شبکه مولد تخصصی

شبکه مولد تخصصی ( $GAN$ ) [۵] شبکه‌ای است که در فرآیند خصومت آموزش می‌بیند. این شبکه به منظور دستیابی

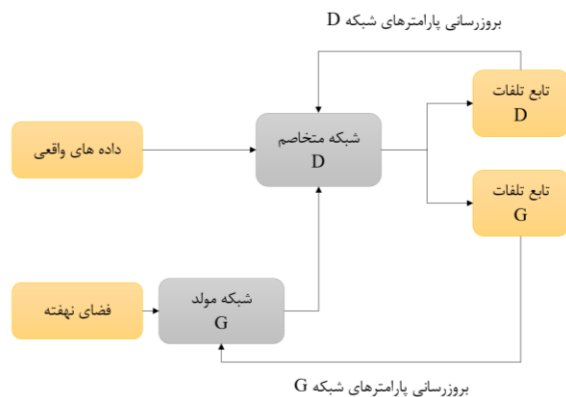
<sup>1</sup> Generative Adversarial Network

منجر به بهبود عملکرد مدل، افزایش دقت آموزش و دستیابی به نتایج بهتر می‌شود. بر اساس این اصل، در این مقاله معماری شبکه  $GAN$  به منظور پیش‌بینی قیمت پایانی سهام پیشنهاد شده است. این شبکه در تلاش است با استفاده از مدل‌ها و معماری‌های مختلف برای شبکه‌های مولد و متخاصم و بهینه نمودن پارامترهای شبکه‌ها، به یک مدل با دقت بالا در امر پیش‌بینی دست یابد.

### ۳-۲- انتخاب ویژگی

روش‌های انتخاب ویژگی<sup>۳</sup> به منظور مواجهه با داده‌های ابعاد بالا، به مولفه‌های جدایی‌ناپذیر از فرآیند یادگیری مبدل شده‌اند. یک انتخاب ویژگی صحیح می‌تواند منجر به بهبود یادگیرنده استقرایی از جهت‌های گوناگون از جمله سرعت یادگیری، ظرفیت تعمیم و سادگی مدل استنتاج شده، شود [۶]. انتخاب ویژگی را می‌توان به عنوان فرآیند شناسایی ویژگی‌های مرتبط و حذف ویژگی‌های غیر مرتبط و تکراری با هدف مشاهده زیرمجموعه‌ای از ویژگی‌ها که مساله را به خوبی و با حداقل کاهش درجه کارایی تشریح می‌کنند، تعریف کرد. این کار مزایای گوناگونی دارد که از جمله آن‌ها می‌توان به بهبود کارایی الگوریتم‌های یادگیری ماشین، درک داده، کسب دانش درباره فرآیند و کمک به بصری‌سازی آن و سادگی و قابلیت استفاده از مدل‌های ساده‌تر و کسب سرعت اشاره کرد. این امر سبب شده است، انتخاب ویژگی در سناریوهای «تحلیل کلان داده»، انتخاب ویژگی نقشی اساسی ایفا کند [۷]. تحقیقات انجام شده در زمینه تاثیر انتخاب ویژگی‌های مناسب در عملکرد روش‌های یادگیری ماشین، نشان داده است که انتخاب مجموعه مناسب از ویژگی‌ها در هنگام طراحی مدل‌های یادگیری ماشین، عملکرد، دقت و کارایی روش‌های یادگیری نظارت شده<sup>۴</sup> و نظارت نشده<sup>۵</sup> را بهبود می‌بخشد [۸]. همچنین، وقتی که ابعاد فضای ویژگی داده‌ها بسیار زیاد است و با معضل ابعاد بالا مواجه هستیم، استفاده از مجموعه ویژگی‌های مناسب، هزینه‌های محاسباتی لازم برای آموزش بهینه سیستم را به شدت کاهش می‌دهد.

به یک دقت بالا، از دو شبکه جداگانه مولد ( $G^1$ ) و متخاصم ( $D^2$ ) تشکیل شده است. در این فرآیند، شبکه مولد می‌تواند به عنوان یک متقلب برای تولید داده‌های مشابه به داده‌های واقعی عمل کند، در حالی که شبکه متخاصم نقش قاضی را برای تشخیص داده‌های واقعی و داده‌های تولید شده ایفا می‌کند. آن‌ها می‌توانند به نقطه ایده‌آلی برسند که شبکه متخاصم نتواند این دو نوع داده را از هم متمایز کند. در این مرحله، شبکه مولد می‌تواند توزیع داده‌های این بازی را آموزش ببیند. مقدار اتلاف در دو شبکه براساس میزان اشتباه‌های هر شبکه که توسط تابع تلفات مشخص می‌شود، محاسبه می‌شود. در نهایت، خطا پس‌انتشار و پارامترهای هر شبکه برزورسانی می‌شود. ساختار کلی شبکه  $GAN$  در شکل (۱) نشان داده شده است.



شکل-۱: ساختار کلی شبکه  $GAN$

شبکه  $GAN$  از نوع بدون نظارت است، در واقع این نوع یادگیری بر روی داده‌های بدون برچسب و برای یافتن الگوهای پنهان در این داده‌ها انجام می‌شود و هدف اصلی آن، یادگیری ساختار داده‌ها می‌باشد. برچسب‌دار کردن داده‌ها یک فرآیند دستی و زمانبر است. شبکه  $GAN$  به داده‌های برچسب‌دار نیازی ندارد و بدون برچسب آموزش می‌بیند. با توجه به اینکه آموزش شبکه برخلاف سایر شبکه‌های عصبی با دو دسته داده، یعنی داده‌های اصلی و همینطور داده‌های جعلی تولید شده توسط شبکه مولد انجام می‌شود. این موضوع

<sup>4</sup> Supervised

<sup>5</sup> Unsupervised

<sup>1</sup> Generator

<sup>2</sup> Discriminator

<sup>3</sup> Feature Selection Methods

کردند و به این نتیجه رسیدند که شبکه مولد به دقت پیش‌بینی قابل مقایسه نسبت به روش‌های دیگر دست یافته است. در همان سال، ژو و همکاران [۱۴] کار دیگری را بر روی مجموعه داده‌های ترافیک وب منتشر کردند و بیشترین تأکید آن‌ها بر این مسئله بوده است که نتایج شبکه  $GAN$  مشابه نتایج سایر مدل‌ها بوده است. از سوی دیگر، در سال ۲۰۲۱، لین<sup>۱۱</sup> و همکاران [۱۵] نتایج بهتری را با استفاده از شبکه  $GAN$  به دست آورد، اما مدل‌های در نظر گرفته شده را در طول سری زمانی یک سهام واحد ( $Apple Inc.$ ) ارزیابی کرد. استفانی<sup>۱۲</sup> در سال ۲۰۲۲ [۱۶] یک شبکه  $GAN$  با معماری ( $DCGAN$ <sup>۱۳</sup>) را برای مقابله با مشکل پیش‌بینی قیمت پایانی سهام معرفی کرده است که بدین منظور از داده‌های سری زمانی شاخص بازار سهام بورس ملی ایتالیا استفاده کرده‌اند. با انجام پیش‌بینی تک‌مرحله‌ای و چند مرحله‌ای، مشاهده شده است که مدل  $DCGAN$  نسبت به مدل‌های استاندارد پرکاربرد  $ARIMA$  و  $LSTM$  عملکرد بهتری دارد [۱۷].

دینگ<sup>۱۴</sup> و همکاران [۱۸] یک روش یادگیری عمیق برای پیش‌بینی بازار سهام مبتنی بر رویداد پیشنهاد کرد. در مرحله اول، رویدادها از متن خبر استخراج شده و به عنوان بردارهای متراکم، با استفاده از یک شبکه تنسور عصبی جدید ( $NTN$ <sup>۱۵</sup>) آموزش داده شدند. سپس از  $CNN$  برای مدل‌سازی تأثیرات کوتاه‌مدت و بلندمدت رویدادها بر تغییرات قیمت سهام استفاده شده است. چونگ<sup>۱۶</sup> و همکاران [۱۹] اثرات سه روش استخراج ویژگی بدون نظارت شامل تجزیه و تحلیل مؤلفه اصلی<sup>۱۷</sup>، خودرزم‌گذار<sup>۱۸</sup>، و ماشین محدود شده بولتزمن<sup>۱۹</sup> را به منظور بررسی توانایی کلی شبکه برای پیش‌بینی رفتار بازار بررسی کرده‌اند. سینگه<sup>۲۰</sup> و همکاران [۲۰] به بررسی عملکرد شبکه عصبی عمیق ( $DNN$ ) با روش

محاسبه درجه اهمیت ویژگی‌ها و استفاده از آن‌ها در مرحله انتخاب ویژگی، گام مهمی در جهت تفسیرپذیری<sup>۱</sup> مدل‌های یادگیری ماشین خواهد بود.

### ۳-۳- مروری بر پیشینه پژوهش

محققان اخیراً سعی کرده‌اند شبکه‌های مولد تخصصی [۵] را با هدف تحلیل و پیش‌بینی داده‌های سری زمانی آموزش دهند. این شبکه از یک شبکه متخاصم و مولد تشکیل شده است که با یکدیگر در تعامل هستند، شبکه متخاصم در تلاش برای تشخیص واقعی یا جعلی بودن یک نمونه خاص، و شبکه مولد برای به اشتباه انداختن شبکه متخاصم با تولید داده‌های واقعی تر تلاش می‌کند. در سال ۲۰۱۸، ژو<sup>۲</sup> و همکاران [۹] یک شبکه  $GAN$  را توسعه دادند که از مدل حافظه طولانی کوتاه مدت ( $LSTM$ <sup>۳</sup>) به عنوان مولد و شبکه عصبی پیچشی ( $CNN$ <sup>۴</sup>) به عنوان شبکه متخاصم برای پیش‌بینی بازار سهام استفاده می‌کرد. در همان سال، لو<sup>۵</sup> و همکاران [۱۰] مدل مشابهی را برای پیش‌بینی قیمت نفت خام پیشنهاد کرد. سال بعد، در سال ۲۰۱۹ کوچالی<sup>۶</sup> و همکاران [۱۱] یک  $GAN$  شرطی را برای محاسبه پیش‌بینی‌های احتمالی در داده‌های ترافیک وب معرفی کردند. دوباره، در سال ۲۰۱۹، ژانگ<sup>۷</sup> و همکاران [۱۲] یک  $GAN$  با پرسپترون چندلایه ( $MLP$ <sup>۸</sup>) پیشنهاد نمودند که به عنوان یک شبکه متخاصم برای پیش‌بینی قیمت پایانی برخی از سهام  $S\&P 500 Index$  و  $PAICC$  عمل می‌کند. همه این کارها عملکردهای به دست آمده را با سایر مدل‌های یادگیری ماشین و سری‌های زمانی، مانند  $LSTM$  و  $ARIMA$  مقایسه کردند و نتایج امیدوارکننده‌ای را به دست آوردند. در سال ۲۰۲۰، ژو<sup>۱۰</sup> و همکاران [۱۳] شبکه  $GAN$  را با مدل‌های دیگر (مانند  $ARIMA$ ، شبکه پیچشی زمانی و  $LSTM$ ) توسط مقایسه آن‌ها بر روی مجموعه داده‌های معیار عمومی مقایسه

<sup>11</sup> Lin

<sup>12</sup> Staffini

<sup>13</sup> Deep Convolutional Generative Adversarial Network

<sup>14</sup> Ding

<sup>15</sup> neural tensor Network

<sup>16</sup> Chong

<sup>17</sup> principal component analysis

<sup>18</sup> autoencoder,

<sup>19</sup> restricted Boltzmann machine

<sup>20</sup> Singh

<sup>1</sup> Interpretability

<sup>2</sup> Zhou

<sup>3</sup> Long short-term memory

<sup>4</sup> Convolutional Neural Network

<sup>5</sup> Luo

<sup>6</sup> Koochali

<sup>7</sup> Zhang

<sup>8</sup> Multi Layer Perceptron

<sup>9</sup> AutoRegressive Integrated Moving Average

<sup>10</sup> Zhou

دقیق‌تر الگوهای نوسان قیمت سهام، به ویژگی ورودی جدیدتری در مدل یادگیری عمیق نیاز است. برای پیش‌بینی نوسان قیمت سهام، مدل یادگیری عمیق را با استفاده از ۷۱۵ ویژگی ورودی جدید که بر اساس تحلیل‌های فنی پیکربندی شده‌اند، طراحی کرده‌اند. سپس عملکرد مدل پیش‌بینی با مدل دیگری که از ویژگی‌های ورودی مبتنی بر قیمت ساده استفاده می‌کرد، مقایسه شده‌اند. این<sup>۸</sup> و همکاران [۲۶] یک مدل یادگیری عمیق پیشنهاد کرده‌اند که مسیرهای چندگانه شبکه عصبی کانولوشنال و سلول‌های حافظه کوتاه‌مدت دو جهته را ترکیب می‌کند. مدل پیشنهادی عملکرد پیش‌بینی را تا ۹ درصد نسبت به مدل یادگیری عمیق تکی مسیر به بهبود بخشیده است. مقصود<sup>۹</sup> و همکاران [۲۷] تأثیر رویدادهای مهم مختلف رخ داده در طی سال‌های ۲۰۱۲-۲۰۱۶ را بر بازارهای سهام با استفاده از شبکه *CNN* بررسی کرده‌اند. زنگ<sup>۱۰</sup> و همکاران [۳۳] یک رویکرد جدید توسط موجک، شبکه عصبی بازگشتی مبتنی بر توجه (*ARNN*<sup>۱۱</sup>) و میانگین متحرک یکپارچه اتورگرسیو (*ARIMA*<sup>۱۲</sup>) را ادغام کرده‌اند. تبدیل موجک نویز را از سری زمانی حذف می‌کند تا ساختار داده را تثبیت کند. مدل *ARNN* روابط قوی و غیرخطی را در توالی ثبت می‌کند و *ARIMA* می‌تواند به خوبی با همبستگی خطی اطلاعات متوالی مطابقت داشته باشد. با ترکیب سه مدل، این روش قادر به مدل‌سازی سیستم‌های پویا مانند بازار فارکس است. چن و همکاران [۲۸] یک رویکرد جدید با استفاده از یک مدل ترکیبی مبتنی بر یادگیری ماشین برای پیش‌بینی سهام و مدل میانگین واریانس (*MV*<sup>۱۳</sup>) برای انتخاب پورتفولیو توسعه یافته است. به طور خاص، دو مرحله در این مدل درگیر است: پیش‌بینی سهام و انتخاب پرتفوی. در مرحله اول، یک مدل ترکیبی ترکیبی از تقویت گرادیان فوق‌العاده (*XGBoost*<sup>۱۴</sup>) با یک الگوریتم کرم شب تاب

تحلیل مؤلفه اصلی و شبکه عصبی تابع پایه شعاعی (*Radial Basis Function Neural Network*)<sup>۱</sup> پرداخته‌اند. همچنین نتایج مدل پیشنهادی را با شبکه عصبی بازگشتی (*RNN*) مقایسه شده است. ناکاوا<sup>۲</sup> و همکاران [۲۱] به بررسی کاربرد انتشار ربط لایه‌ای (*LRP*<sup>۳</sup>) را برای تجزیه ویژگی‌های بازده پیش‌بینی شده به عنوان یک مدل ریسک ارائه پرداخته‌اند. با اعمال *LRP* برای یک سهام منفرد یا یک سبد سهام که تعیین کنند کدام عامل در پیش‌بینی نقش دارند.

چاتیزس<sup>۴</sup> و همکاران [۲۲] مجموعه‌ای از الگوریتم‌های یادگیری ماشین را برای انتخاب مرتبط‌ترین متغیرها از میان مجموعه بزرگی از متغیرهای پیشنهادی اعمال کرده‌اند. در نهایت، از نمونه‌گیری بوت استرپ برای تنظیم ماهیت نامتعادل مجموعه داده برازش موجود استفاده می‌کنند. ابه<sup>۵</sup> و همکاران [۲۳] یادگیری عمیق را برای پیش‌بینی بازده سهام یک ماهه به صورت مقطعی در بازار سهام ژاپن پیاده‌سازی می‌کنند و عملکرد این روش را بررسی می‌کنند. آن‌ها نشان دادند که شبکه‌های عصبی عمیق عموماً از شبکه‌های عصبی کم‌عمق بهتر عمل می‌کنند. نایک<sup>۶</sup> و همکاران [۲۴] ۳۳ شاخص فنی بر اساس قیمت روزانه سهام از قبیل قیمت باز، بالا، پایین و بسته استخراج کرده‌اند. آن‌ها به بررسی، انتخاب ویژگی شاخص فنی و شناسایی شاخص‌های فنی مربوطه با استفاده از تکنیک انتخاب ویژگی بوروتا و پیش‌بینی دقیق برای حرکت قیمت سهام پرداخته‌اند. برای پیش‌بینی حرکت قیمت سهام، تکنیک‌های یادگیری ماشین و مدل مبتنی بر یادگیری عمیق استفاده کرده‌اند و نشان داده‌اند عملکرد مدل یادگیری عمیق بهتر از تکنیک‌های یادگیری ماشینی است. سونگ<sup>۷</sup> و همکاران [۲۵] نشان داده‌اند عملکرد مدل‌های قیمت سهام با توجه به ویژگی‌های ورودی متنوع پیکربندی شده بر اساس قیمت سهام تغییر می‌کند که برای پیش‌بینی

<sup>8</sup> Eapen

<sup>9</sup> Maqsood

<sup>10</sup> Zeng

<sup>11</sup> Attention-based Recurrent Neural Network

<sup>12</sup> Autoregressive Integrated Moving Average

<sup>13</sup> mean-variance

<sup>14</sup> eXtreme Gradient Boosting

<sup>1</sup> Radial Basis Function Neural Network

<sup>22</sup> Nakagawa

<sup>3</sup> layer-wise relevance propagation

<sup>4</sup> Chatzis

<sup>5</sup> Abe

<sup>6</sup> Naik

<sup>7</sup> Song

بهبود یافته ( $IFA^1$ ) برای پیش‌بینی قیمت سهام پیشنهاد کرده‌اند.

سن<sup>۲</sup> و همکاران [۲۹] یک مدل ترکیبی برای پیش‌بینی قیمت سهام ارائه کرده‌اند و از مدل‌های مبتنی بر یادگیری عمیق استفاده کرده‌اند و همچنین هشت مدل رگرسیون را با استفاده از داده‌های آموزشی ایجاد کرده‌اند. چاجر<sup>۳</sup> و همکاران [۳۰] ما نقاط قوت و ضعف یادگیری ماشینی را برای پیش‌بینی بازار سهام مورد بحث قرار داده و بینشی درباره فرصت‌ها و تهدیدها در استفاده از فناوری‌های پیشرفته برای پیش‌بینی بازار سهام ارائه کرده‌اند و با استفاده از شبکه عصبی بازگشتی متشکل از سلول‌های  $LSTM$  به پیش‌بینی روند حرکتی بازار پرداخته‌اند. آچیوتا<sup>۴</sup> و همکاران [۳۱] ویژگی‌های میانگین حجم، میانگین قیمت، میانگین شاخص بازار، میانگین گردش مالی روزانه و شاخص اختلاف احساسات بر اساس توییت‌های یک شرکت و ارزش پیش‌بینی شده عملکرد سهام را مورد بررسی قرار داده‌اند. علاوه بر این با استفاده از الگوریتم ماشین بردار پشتیبانی به طبقه بندی قیمت سهام پرداخته اند.

در سال‌های اخیر،  $GAN$ ها نتایج امیدوارکننده‌ای را در حل بسیاری از مسائل پیچیده (مانند تولید تصویر و ویدیوی واقعی، تبدیل تصویر به تصویر و متن به تصویر) نشان داده‌اند، علاوه بر این در مطالعات اخیر [۱۴، ۳۲] این شبکه‌های در بررسی سری‌های زمانی مالی نیز نتایج خوبی از خود نشان داده‌اند. اما پیش‌بینی سری‌های زمانی مالی با استفاده از این شبکه‌ها (در مقایسه با رویکردهای قدیمی‌تر) همچنان یک چالش است که هنوز حل نشده باقی مانده است.

#### ۴- روش شناسی پژوهش

##### ۴-۱- نوع پژوهش

این تحقیق از نظر هدف، تحقیق کاربردی و از جنبه استدلال، استدلال استقرایی استفاده شده است و همچنین تحقیق

حاضر به عنوان یک تحقیق علی (پس رویدادی) شناخته می‌شود. در این پژوهش اطلاعات گردآوری شده با استفاده از نرم افزار پایتون مورد تجزیه و تحلیل قرار گرفته است.

#### ۴-۲- فرضیه‌های پژوهش

۱- دقت پیش‌بینی قیمت سهام توسط شبکه مولد تخصصی نسبت به مدل شبکه عصبی پیچشی ( $CNN$ ) و شبکه عصبی بازگشتی ( $RNN$ ) با مدل حافظه طولانی کوتاه مدت ( $LSTM$ ) بیشتر می‌باشد.

۲- استفاده از روش‌های انتخاب ویژگی منجر به افزایش دقت پیش‌بینی قیمت سهام با استفاده از شبکه مولد تخصصی می‌شود.

#### ۴-۳- نمونه و جامعه آماری

داده‌های مورد استفاده در این پژوهش از اطلاعات منتشره در سایت شرکت بورس اوراق بهادار تهران، نرم افزار ره آورد نوین و سایر پایگاه‌های اطلاعاتی استخراج شده‌اند. دوره زمانی داده‌های استخراج شده به منظور آزمایش فرضیه‌ها، فاصله سال-های ۱۳۹۴ الی ۱۳۹۸ می‌باشد و قلمرو مکانی تحقیق، بورس اوراق بهادار تهران می‌باشد. جامعه آماری شامل کلیه شرکت-های پذیرفته شده در بورس اوراق بهادار تهران می‌باشد. با استفاده از روش نمونه گیری حذفی، شرکت‌های دارای ویژگی‌های زیر به عنوان نمونه انتخاب خواهند شد:

- ۱- قبل از سال ۱۳۹۴ در بورس اوراق بهادار تهران پذیرفته شده باشد،
- ۲- جزء شرکت‌های سرمایه گذاری و بانک‌ها نباشد،
- ۳- حداقل در ۶۰ درصد از روزهای معاملاتی، سهام آن معامله شده باشد (نماد باز بوده باشد).
- ۴- اطلاعات شرکت در دوره مورد بررسی موجود باشد.

که در انتها از بین کلیه شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران تعداد ۱۵۲ شرکت واجد ذکر شده بودند و در روند آموزش و ارزیابی شبکه مورد بررسی قرار گرفتند.

<sup>3</sup> Chhajer

<sup>4</sup> Achyutha

<sup>1</sup> improved firefly algorithm

<sup>2</sup> Sen

#### ۴-۴- متغیرهای پژوهش

متغیرهای مستقل این پژوهش شامل متغیری‌هایی می‌باشند که در تعیین آخرین قیمت روز سهام نقش داشته‌اند، که این متغیرها عبارتند از: قیمت پایانی تعدیل شده، اولین قیمت، آخرین قیمت، کمترین قیمت، بیشترین قیمت، میانگین متحرک پنج، ده، و پانزده روزه، حجم خرید حقوقی، حجم معاملات، نرخ گردش معاملات، ارزش بازاری سهام شرکت، تعداد معاملات، نسبت قیمت به سود سهام ( $P/E$ )، تغییر قیمت، درصد تغییر قیمت، حجم خرید حقیقی، حجم فروش حقیقی، تعداد خرید حقیقی، تعداد فروش حقیقی، حجم خرید حقوقی، تعداد خرید حقوقی، تغییر مالکیت حقوقی به حقیقی، میانگین خرید حقوقی، میانگین خرید حقیقی و میانگین فروش حقوقی قیمت سهام می‌باشد.

شبکه‌های معرفی شده در نرم افزار پایتون با استفاده از کتابخانه کراس<sup>۱</sup> [۳۳] شبیه سازی و آموزش داده شده‌اند. در این پژوهش داده‌ها به سه دسته تقسیم شده‌اند؛ ۸۰ درصد به عنوان داده‌ها آموزش، ۱۰ درصد به عنوان داده‌های آزمون و ۱۰ درصد باقی مانده به عنوان داده‌های اعتبارسنجی<sup>۲</sup> انتخاب شده‌اند.

#### ۵- مدل سازی و تحلیل یافته‌های تحقیق

##### ۵-۱- مدل پژوهش

بخش اصلی الگوریتم پیشنهادی، پیش‌بینی کننده آن است که جهت پیش‌بینی قیمت سهام استفاده شده‌است. روش پیشنهادی استفاده از روش‌های  $SVM$  و شبکه‌های یادگیری عمیق  $CNN$ ،  $RNN$  و  $GAN$  است. پس از انتخاب بردار ویژگی، قبل از آنکه ویژگی جدید وارد پیش‌بینی کننده شود بایستی تعداد ویژگی‌ها جهت تعیین تعداد پارامترها چک شود، تا متناسب با آن ساختار شبکه تعیین گردد. لذا در این پژوهش با استفاده از روش‌های ضریب همبستگی پیرسون، ضریب پیوستگی کندال، ضریب همبستگی رتبه‌ای اسپیرمن، انتخاب ویژگی با روش تجزیه و تحلیل واریانس‌ها، انتخاب ویژگی با اطلاعات متقابل، الگوریتم رگرسیون خطی،

لاسو<sup>۳</sup> و ستیغی<sup>۴</sup> و الگوریتم جنگل تصادفی به بررسی و انتخاب بهترین ویژگی‌ها در آموزش داده‌ها پرداخته شده‌است. در ادامه ساختار شبکه‌های مورد استفاده عنوان شده‌است.

۵-۱-۱- مدل پیش بینی قیمت سهام با استفاده از مدل

ماشین بردار پشتیبان

تنظیم پارامترها برای الگوریتم ماشین بردار پشتیبان به طور مؤثر باعث بهبود کارایی مدل می‌شود. پارامتر جریمه  $C=I$  به عنوان جمله خطا و به منظور برقراری تعادل بین مرزهای تصمیم‌گیری هموار و طبقه‌بندی نقاط داده تعیین می‌شود. علاوه بر این با توجه به غیر خطی بودن مسئله از کرنل  $rbf$  با درجه ۳ استفاده شده‌است.

۵-۱-۲- مدل پیش بینی قیمت سهام با استفاده از مدل

شبکه عصبی پیچشی

ساختار شبکه عصبی پیچشی ( $CNN^5$ ) از چهار لایه پیچشی تشکیل شده است. لایه ابتدایی دارای سایز مشخصی از داده ورودی است. دو لایه پنهان پیچشی استخراج ویژگی از داده‌های ورودی را با استفاده از فیلترها و تابع فعال‌سازی  $ReLU$  بر عهده دارند. اولین لایه پیچشی دارای ۲۵۶ فیلتر با ابعاد  $1 \times 3$  است و ابعاد داده ورودی-خروجی در این لایه برابر هستند. این فیلترها ۲۵۶ نقشه ویژگی که به عنوان ورودی لایه دوم با  $128$  فیلتر با سایز  $1 \times 3$  هستند تولید می‌کنند. لایه سوم مانند لایه دوم دارای  $128$  فیلتر با سایز  $1 \times 3$  و لایه آخر دارای  $80$  فیلتر با سایز  $1 \times 3$  است. برای جلوگیری از بیش‌برازش در هر لایه منظم‌سازی با برون‌اندازی  $0.5$  مورد استفاده قرار گرفته است. در انتها یک لایه کاملاً متصل با  $256$  نورون و تابع فعال‌سازی  $ReLU$  اضافه شده است. خروجی این لایه به یک طبقه بند بیشینه-هموار<sup>۶</sup> داده شده است که میزان شباهت سیگنال ورودی ( $x$ ) و کلاس ( $y$ ) را مشخص می‌کند. این ساختار در شکل ۲ قابل مشاهده است.

<sup>4</sup> Ridge

<sup>5</sup> Convolutional Neural Network

<sup>6</sup> Softmax

<sup>1</sup> Keras

<sup>2</sup> Validation set

<sup>3</sup> Lasso

$t$  امین سلول  $LSTM$   $C_t$  از یک شبکه (شکل ۴) مرحله‌ی  $t$ ام از یک توالی را نشان می‌دهد و اطلاعات سلول قبلی  $C_{t-1}$  را دریافت می‌کند. هر سلول  $x_t$  را به عنوان داده  $t$ ام دریافت می‌کند و اطلاعات سلول  $C_t$  و خروجی سلول  $h_t$  به روز می‌شود. سلول‌های  $LSTM$  دارای لایه‌هایی به نام "دروازه" هستند که وظیفه از بین بردن و یا نگه داشتن اطلاعات برای مراحل / سلول‌های بعدی را بر عهده دارند [۳۶].

دو دروازه برای از بین بردن اطلاعات  $f_t$  و نگه داری اطلاعات جدید  $i_t$  (مقدار  $\tilde{C}_t$  را داده مرحله فعلی و خروجی مرحله قبل محاسبه می‌کند) است به صورت فرمول (۱) نشان داده می‌شود.

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

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

دروازه خروجی  $O_t$  مقدار خروجی هر سلول،  $h_t$  را کنترل می‌کند و مقدار جدید به روز شده به صورت زیر خواهد بود که در فرمول (۵) نشان داده شده است.


$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (3)$$


$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (4)$$

$$h_t = o_t * \tanh(C_t) \quad (5)$$

که  $W$  و  $b$  به ترتیب پارامترهای وزن و بایاس شبکه را نشان می‌دهند [۴۳].




شکل-۴: شبکه  $LSTM$



شکل-۲: ساختار شبکه عصبی پیچشی با چهار لایه  $conv2D$

۵-۱-۲- مدل پیش‌بینی قیمت سهام با استفاده از شبکه عصبی بازگشتی

ساختار  $RNN^1$  از دو لایه متشکل از سلول‌های  $LSTM$  تشکیل شده است. لایه ابتدایی دارای سایز مشخصی از داده ورودی است. لایه اول و دوم به ترتیب دارای ۱۲۸ و ۶۴ سلول  $LSTM$  هستند. برای جلوگیری از بیش‌برازش در هر لایه منظم‌سازی با برون‌اندازی  $0/3$  مورد استفاده قرار گرفته است. خروجی این لایه به یک طبقه بند بیشینه-هموار داده شده است که میزان شباهت سیگنال ورودی ( $x$ ) و کلاس ( $y$ ) را مشخص می‌کند. این ساختار در شکل ۳ قابل مشاهده است.



شکل-۳: ساختار شبکه عصبی بازگشتی

$LSTM$  یک دنباله با طول متغیر  $y = (y_1, y_2, \dots, y_n)$  را با افزودن تدریجی داده‌های جدید به قسمتی از حافظه پردازش می‌کند. که این عمل توسط گیت‌هایی که کنترل ذخیره‌سازی داده‌های جدید، پاک کردن داده‌های قدیمی باید پاک شود و مشاهده داده‌های فعلی را بر عهده دارند، انجام می‌شود [۳۴، ۳۵].

<sup>1</sup> Recurrent Neural Network

<sup>2</sup> Gates



$$D^* = \arg \max_D V(G, D)$$

که در فرمول (۶)  $V(G, D)$  به صورت زیر تعریف می‌شوند.

$$\begin{aligned} & \min_G \max_D V(D, G) & (7) \\ & = E_{x \sim P_{data}(x_{t+1})} \log D(x_{t+1}) \\ & + E_{x \sim P_g(x)} \log G(x) \end{aligned}$$

$G(z)$  داده تولید شده توسط  $G$  و  $D(x)$  احتمال یافتن داده-های واقعی است.  $G$  از داده‌های واقعی و جعلی با احتمال توزیع  $P_{data}(x)$  از داده‌های  $x$  و احتمال  $P_g(x)$ ، ورودی را آموزش می‌بیند. در نتیجه، فرمول بهینه‌سازی  $G$  را می‌توان به صورت فرمول (۸) نوشت:

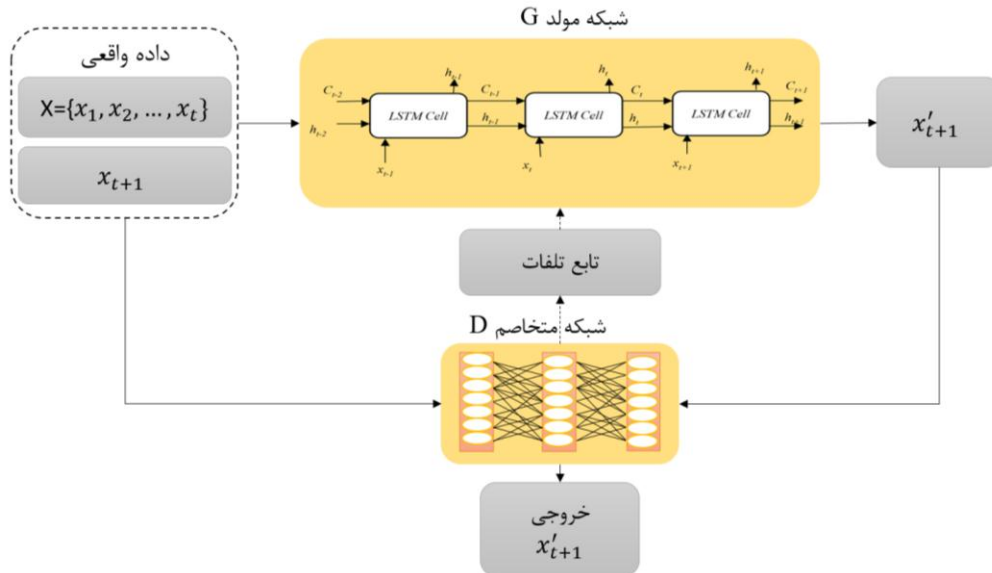
$$G^* = \arg \min_G \max_D V(G, D)$$

در واقع هدف  $D$  ایجاد یک تابع مشتق‌پذیر برای طبقه‌بندی داده‌های ورودی است. در صورت ورود داده‌های جعلی، متخصص عدد صفر و در صورت ورود داده‌های واقعی، عدد یک تولید خواهد کرد. بدین منظور در این پژوهش از شبکه عصبی پیچشی استفاده شده‌است. در نهایت، شبکه‌های مولد و متخصص برای بهینه نمودن تابع هدف با یکدیگر رقابت خواهند نمود (شکل ۸).

۵-۴-۳- مدل پیش‌بینی قیمت سهام با استفاده از مدل

شبکه مولد تخصصی

شبکه مولد  $g(\cdot)$ ، وظیفه تولید نمونه‌های جعلی به منظور فریب شبکه متخصص را دارد، لذا به منظور تولید بهترین نمونه‌ها و افزایش دقت پیش‌بینی مدل، تلاش می‌شود از چندین مدل به عنوان شبکه مولد استفاده گشته و نتایج با یکدیگر مقایسه گردد. با توجه به اینکه داده‌های ورودی مورد استفاده در پژوهش حاضر، از نوع سری زمانی می‌باشند، از شبکه حافظه طولانی کوتاه مدت ( $LSTM^1$ ) به دلیل قدرت بالا در پردازش داده‌های سری زمانی استفاده شده است که مهم‌ترین ویژگی این مدل‌ها امکان یادگیری وابستگی‌های بلندمدت است. اگر داده‌های ورودی (به طور مثال قیمت سهام) را  $X = \{x_1, \dots, x_t\}$  فرض نماییم، خروجی مولد برای تولید  $\hat{x}_{t+1}$  استفاده خواهد شد که در واقع تقریبی برای قیمت سهام در روز  $t+1$  خواهد بود. سپس از  $\hat{x}_{t+1}$  برای تولید  $\hat{x}_{t+2}$  استفاده خواهد شد و این فرآیند به همین ترتیب ادامه خواهد یافت. در فرآیند بهینه‌سازی شبکه،  $G$  سعی می‌کند یک راه حل بهینه پیدا کند که در آن  $D$  داده‌های واقعی را به اشتباه تشخیص دهد. بنابراین، برای پرداختن به این موضوع و تخمین احتمال داده‌های واقعی یا جعلی، تابع هدف برای  $D$  را میتوان به صورت زیر تعریف کرد:



<sup>1</sup> Long Short Term Memory

شکل ۸- ساختار شبکه GAN پیشنهادی

میانگین قدرمطلق درصد خطا<sup>۳</sup> و میانگین بازدهی<sup>۴</sup> استفاده خواهد شد. چنانچه قیمت پایانی و قیمت پایانی پیشنهاد شده سهم در روز  $K$ ام به ترتیب،  $y_k$  و  $\hat{y}_k$  باشد، معیارهای فوق الذکر به صورت زیر محاسبه خواهند شد:

$$MAE = \frac{1}{N} \sum_{k=1}^N |\hat{y}_k - y_k| \quad (۱۳)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (\hat{y}_k - y_k)^2} \quad (۱۴)$$

$$MAPE = \frac{1}{N} \sum_{k=1}^N \frac{|\hat{y}_k - y_k|}{y_k} \quad (۱۵)$$

$$AR = \frac{1}{N-1} \sum_{k=1}^N (y_{k+1} - y_k), \quad \text{if } \hat{y}_{k+1} > \hat{y}_k \quad (۱۶)$$

۵-۲- یافته‌های پژوهش

با توجه به نتایج حاصله از روش‌های استخراج ویژگی دو معیار میانگین و انتخاب وابسته به فراوانی مورد بررسی قرار گرفته‌اند. انتخاب وابسته به فراوانی یک فرایند فرگشتی است که در آن شایستگی یک ویژگی وابسته به فراوانی آن نسبت به سایر ویژگی‌ها مورد بررسی قرار می‌گیرد (جدول ۱).

در این شبکه به منظور بهینه‌سازی شبکه، تابع تلفات  $G$  و  $D$  را به صورت  $g_{loss}$  و  $D_{loss}$  تعریف می‌شود.

$$D_{loss} = -\frac{1}{m} \sum_{i=1}^m \log D(x_{t+1}^i) \quad (۹)$$

$$g_{loss} = \frac{1}{m} \sum_{i=1}^m \log(1 - D(x_{t+1}^i)) \quad (۱۰)$$

علاوه بر این به منظور بهبود عملکرد و افزایش دقت شبکه میانگین مربعات خطا در تابع تلفات  $G$  به صورت فرمول (۱۱) به کار گرفته شده است.

$$g_{MSE} = \frac{1}{m} \sum_{i=1}^m (x_{t+1}^i - x_{t+1}^i)^2 \quad (۱۱)$$

با توجه به توابع تلفات تعریف شده  $G_{loss}$ ،  $g_{MSE}$  و  $g_{loss}$  به صورت ترکیبی از دو تابع تلفات به صورت فرمول (۱۲) تعریف می‌شود.

$$G_{loss} = g_{MSE} + g_{loss} \quad (۱۲)$$

۳-۵-۲- متغیرهای اندازه‌گیری شده در پژوهش

به منظور آزمون فرضیه‌ها و مقایسه دقت پیش‌بینی مدل‌ها از معیارهای میانگین قدرمطلق خطا<sup>۱</sup>، جذر میانگین مربع خطا<sup>۲</sup>،

جدول ۱- نتایج استخراج ویژگی برای قیمت سهام شرکت‌ها

میانگین	انتخاب وابسته به فراوانی
تغییر قیمت	8.6
درصد تغییر قیمت	2.6
قیمت پایانی تعدیل شده	4.6
بیشترین قیمت	1.2

<sup>3</sup> Mean Absolute Percentage Error (MAPE)

<sup>4</sup> Average Return (AR)

<sup>1</sup> Mean Absolute Error (MAE)

<sup>2</sup> Root Mean Squared Error (RMSE)

ارزش بازاری سهام شرکت	5.949179	1
تعداد معاملات	3.808102	0.2
آخرین قیمت	1.314205	0
کمترین قیمت	1.147436	0
تعداد فروش حقیقی	2.534471	0.6
اولین قیمت	0.998586	0
تعداد خرید حقیقی	3.944051	0.8
میانگین متحرک ۵ روزه	0.729272	0.4
میانگین متحرک ده روزه	0.703284	0
میانگین متحرک پانزده روزه	0.698815	0.2
حجم معاملات	5.830238	0
حجم فروش حقیقی	0.316063	0
میانگین خرید حقوقی	1.155504	0.2
میانگین خرید حقیقی	1.141144	0
میانگین فروش حقوقی	1.158853	0.4
حجم خرید حقیقی	8.078394	0.6
حجم خرید حقوقی	2.241633	0.6
تعداد خرید حقوقی	5.143337	0
نرخ گردش معاملات	4.965477	0.8
تعداد فروش حقوقی	1.788299	0.8
حجم فروش حقوقی	8.422057	1
<i>P/E</i>	0.21631	3
تغییر مالکیت حقوقی به حقیقی	2.607811	2.2

گردش معاملات"، "حجم فروش حقوقی" و "تغییر مالکیت حقوقی به حقیقی" این ویژگی‌ها در آموزش شبکه مورد استفاده قرار گرفته‌اند.

با توجه به تاثیر بیشتر "تغییر قیمت"، "درصد تغییر قیمت"، "ارزش بازاری سهام شرکت"، "تعداد معاملات"، "تعداد فروش حقیقی"، "تعداد خرید حقیقی"، "حجم معاملات"، "حجم خرید حقیقی"، "حجم خرید حقوقی"، "تعداد خرید حقوقی"، "نرخ

جدول ۲- نتایج پیش‌بینی قیمت سهام شرکت‌ها

	<i>MAE</i>	<i>RMSE</i>	<i>MAPE</i>	<i>AR</i>
<i>SVM</i>	9.4956	12.5864	0.1574	0.4462
<i>CNN</i>	8.0152	8.2615	0.0793	0.5463
<i>LSTM</i>	5.1675	7.6998	0.0958	0.7139
<i>GAN</i>	4.0251	4.9264	0.0245	0.8452

جدول ۲ با خطوط پررنگ نشان داده شده است، شبکه *GAN* بهترین نتایج را در میان سایر شبکه‌ها داشته است (کمترین

روش‌های *SVM*، *CNN* و *LSTM* روش‌های یادگیری عمیق برای پیش‌بینی بازار سهام هستند که در این پژوهش این روش‌ها با شبکه *GAN* مقایسه شده‌اند. همانطور که در

داده‌های حاصل شده از روش‌های انتخاب ویژگی آموزش داده شده‌اند و در آموزش شبکه *GAN-WoFS* از همه ویژگی‌های موجود در پایگاه داده، استفاده شده است. در بررسی عملکرد شبکه‌ها با توجه به اینکه میزان داده‌های وارد شده به شبکه در *GAN-WFS* کمتر از *GAN-WoFS* می‌باشد، دقت شبکه *GAN-WFS* بالاتر است که نشان دهنده تاثیر صحیح ویژگی در روند آموزش شبکه است.

مقدار سه معیار *MAE*، *RMSE* و *MAPE* نشان دهنده بهترین نتایج پیش‌بینی قیمت داده‌ها است). همانطور که در جدول ۳ نشان داده شده است، پیش‌بینی روزانه قیمت سهام در بورس اوراق بهادار تهران با استفاده از ویژگی‌های استخراج شده از داده‌های مربوط به قیمت روزانه سهام جهت افزایش صحت پیش‌بینی به وسیله مدل شبکه *GAN* پرداخته شده است. شبکه *GAN-WFS* با استفاده از

جدول ۳- نتایج استفاده از روش‌های انتخاب ویژگی در پیش‌بینی قیمت سهام شرکت‌ها با استفاده از شبکه <i>GAN</i>				
	<i>MAE</i>	<i>RMSE</i>	<i>MAPE</i>	<i>AR</i>
<i>GAN-WFS</i>	4.0251	4.9264	0.0245	0.8452
<i>GAN-WoFS</i>	4.8821	4.9615	0.0351	0.8029

*LSTM* و *SVM* مورد بررسی قرار گرفته‌اند که در این بین شبکه *GAN* بعد از اعمال روش‌های انتخاب ویژگی بهترین عملکرد را نسبت به سایر شبکه‌ها داشته است. معیارهای میانگین قدر مطلق خطا (*MAE*)، میانگین مجموع مربعات خطا (*MSE*)، میانگین قدر مطلق درصد خطا (*MAPE*) و میانگین بازدهی (*AR*) شبکه *GAN* مورد بررسی قرار گرفته شده است و با یکدیگر مقایسه گردیدند.

با توجه به جدول ۲ معیار مجذور خطاها نشان می‌دهد که شبکه *GAN* پیشنهادی کمترین میزان خطا نسبت به سایر مدل‌ها را دارد. با توجه به این معیار می‌توان گفت فرضیه اول مبنی بر برتری شبکه *GAN* تایید می‌گردد. معیار میانگین قدر مطلق خطا (*MAE*) نیز مانند معیار مجذور خطاها نشان می‌دهد که شبکه *GAN* نسبت به سه مدل دیگر دارای خطای کمتری می‌باشد، در این معیار هم فرضیه اول نیز تایید می‌گردد. با توجه به معیار میانگین قدر مطلق خطا (*MAPE*) شبکه *GAN* کمترین میزان خطا را نسبت به شبکه‌های دیگر دارا می‌باشد. یافته‌های این معیار با توجه به دو معیار دیگر انطباق داشته است. علاوه بر سه معیار اشاره شده میانگین بازدهی نیز نشان دهنده برتری شبکه *GAN* است که این موضوع نیز فرضیه اول را تایید می‌نماید. همانطور که در جدول ۳ نشان داده شده‌است استفاده از روش‌های انتخاب ویژگی، سبب افزایش دقت و بهبود عملکرد شبکه مولد تخصصی شده‌است. بر اساس نتایج حاصل شده، فرضیه دوم

در جدول ۳ به بررسی میزان تاثیر ویژگی‌های انتخاب شده در عملکرد شبکه *GAN* پرداخته شده است. لذا شبکه *GAN* در جدول ۳ با معیارهای میانگین قدر مطلق خطا (*MAE*)، میانگین مجموع مربعات خطا (*MSE*)، میانگین قدر مطلق درصد خطا (*MAPE*) و میانگین بازدهی (*AR*) شبکه *GAN* مورد بررسی قرار گرفته شده است.

##### ۵- نتیجه‌گیری و پیشنهادات آتی

سیستم‌های تولیدی و اقتصادی ملتها متأثر از عملکرد بازار سرمایه است. به علاوه بورس به عنوان یک ابزار سرمایه‌گذاری در دسترس، هم برای سرمایه‌گذاران کلان و هم برای عموم مردم شناخته شده است. بازارهای سرمایه علاوه بر پارامترهای کلان متأثر از هزاران عامل دیگر نیز می‌باشند و سبب عدم اطمینان به آن می‌شوند که امر نامطلوبی برای پیش‌بینی محسوب می‌شود و از طرفی برای سرمایه‌گذارانی که بازار بورس را به عنوان مکان سرمایه‌گذاری انتخاب نموده‌اند، امری اجتناب ناپذیر است. بنابراین بطور طبیعی تمام تلاش سرمایه‌گذاران کاهش عدم اطمینان است و از این جهت کمینه کردن عدم اطمینان از اهداف پیش‌بینی بازار بورس می‌باشد. در این راستا شبکه‌های یادگیری عمیق توانسته‌اند کمک زیادی به پیش‌بینی روند حرکتی بازار سرمایه داشته باشند.

در این پژوهش به مطالعه پیش‌بینی روزانه قیمت سهام در بورس اوراق بهادار تهران با استفاده از داده‌های مربوط به سهام جهت افزایش دقت پیش‌بینی توسط شبکه‌های یادگیری عمیق پرداخته شده است. شبکه‌های *GAN*، *CNN*،

Hoseinzade, E., & Haratizadeh, S. (2019). CNNpred: CNN-based stock market prediction using a diverse set of variables. *Expert Systems with Applications*, 129, 273-285.

Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... & Bengio, Y. (2020). Generative adversarial networks. *Communications of the ACM*, 63(11), 139-144.

Guyon, I., & Elisseeff, A. (2003). An introduction to variable and feature selection. *Journal of machine learning research*, 3(Mar), 1157-1182.

Peng, Y., Albuquerque, P. H. M., Kimura, H., & Saavedra, C. A. P. B. (2021). Feature selection and deep neural networks for stock price direction forecasting using technical analysis indicators. *Machine Learning with Applications*, 5, 100060.

Powell, N., Foo, S. Y., & Weatherspoon, M. (2008, March). Supervised and unsupervised methods for stock trend forecasting. In *2008 40th Southeastern Symposium on System Theory (SSST)* (pp. 203-205). IEEE.

Zhou, X., Pan, Z., Hu, G., Tang, S., & Zhao, C. (2018). Stock market prediction on high-frequency data using generative adversarial nets. *Mathematical Problems in Engineering*

Luo, Z., Chen, J., Cai, X. J., Tanaka, K., Takiguchi, T., Kinkyō, T., & Hamori, S. (2018, August). Oil price forecasting using supervised GANs with continuous wavelet transform features. In *2018 24th International Conference on Pattern Recognition (ICPR)* (pp. 830-835). IEEE.

Koochali, A., Schichtel, P., Dengel, A., & Ahmed, S. (2019). Probabilistic forecasting of sensory data with generative adversarial networks-forgan. *IEEE Access*, 7, 63868-63880

Zhang, K., Zhong, G., Dong, J., Wang, S., & Wang, Y. (2019). Stock market prediction based on generative adversarial network. *Procedia computer science*, 147, 400-406.

Zhou, K., Wang, W., Hu, T., & Deng, K. (2020). Time series forecasting and classification models based on recurrent with attention mechanism and

مبنی بر تأثیر مثبت روش‌های انتخاب ویژگی در بهبود عملکرد شبکه GAN تایید می‌گردد.

با توجه به نتایج به دست آمده از این تحقیق و مطالعات مشابه، شبکه‌های مولد تخصصی قادرند به خوبی و حتی در برخی موارد

پیش‌بینی‌هایی دقیق‌تر از سایر روش‌ها انجام دهند. لذا با استفاده از این شبکه‌ها می‌توان به شناسایی و رتبه‌بندی عوامل تأثیر گذار بر رکود بورس اوراق بهادار و پیش‌بینی پرداخت. از آنجا که تمرکز تحقیق حاضر بر استفاده از متغیرهای تحلیل تکنیکال در پیش‌بینی قیمت سهام و روند شاخص بازار می‌باشد، لذا محققین می‌توانند در تحقیقات آتی متغیرهای کلان اقتصادی را نیز وارد مدل کرده و بهبود دقت پیش‌بینی شبکه مولد تخصصی را با دقت پیش‌بینی‌های تحقیق حاضر مقایسه نمایند. همچنین با توجه به اینکه دوره زمانی تحقیق حاضر تا پایان سال ۱۳۹۸ می‌باشد و نظر به ریزش قیمت‌ها و شاخص بازار سهام بعد از پایان دوره زمانی تحقیق حاضر، پیشنهاد می‌شود عملکرد شبکه مولد تخصصی در این دوره زمانی نیز بررسی شود تا قدرت پیش‌بینی این شبکه در زمان وقوع بحران‌ها نیز بررسی شود.

### منابع داخلی

اله یاری. (۲۰۰۹). بررسی شکل ضعیف کارایی بازار سرمایه در بورس اوراق بهادار تهران. فصلنامه بورس اوراق بهادار. 1(4), 75-108.

فراحتی، م.، (۱۳۸۹). بررسی عوامل موثر و آرایه یک الگوی پیش‌بینی قیمت سهام با استفاده از مدل تصمیمگیری چند شاخصه فازی در بورس اوراق بهادار تهران. پایاننامه کارشناسی ارشد. دانشکده مهندسی صنایع و مرکز برنامه ریزی سیستمها، دانشگاه صنعتی اصفهان.

Ariyo, A. A., Adewumi, A. O., & Ayo, C. K. (2014, March). Stock price prediction using the ARIMA model. In *2014 UKSim-AMSS 16th international conference on computer modelling and simulation* (pp. 106-112). IEEE.

- Naik, N., & Mohan, B. R. (2019, May). *Stock price movements classification using machine and deep learning techniques-the case study of indian stock market*. In *International Conference on Engineering Applications of Neural Networks* (pp. 445-452). Springer, Cham.
- Song, Y., Lee, J. W., & Lee, J. (2019). *A study on novel filtering and relationship between input-features and target-vectors in a deep learning model for stock price prediction*. *Applied Intelligence*, 49(3), 897-911.
- Eapen, J., Bein, D., & Verma, A. (2019, January). *Novel deep learning model with CNN and bi-directional LSTM for improved stock market index prediction*. In *2019 IEEE 9th annual computing and communication workshop and conference (CCWC)* (pp. 0264-0270). IEEE
- Maqsood, H., Mehmood, I., Maqsood, M., Yasir, M., Afzal, S., Aadil, F., ... & Muhammad, K. (2020). *A local and global event sentiment based efficient stock exchange forecasting using deep learning*. *International Journal of Information Management*, 50, 432-451.
- Zeng, Z., & Khushi, M. (2020, July). *Wavelet denoising and attention-based RNN-ARIMA model to predict forex price*. In *2020 International joint conference on neural networks (IJCNN)* (pp. 1-7). IEEE.
- Chen, W., Zhang, H., Mehlawat, M. K., & Jia, L. (2021). *Mean-variance portfolio optimization using machine learning-based stock price prediction*. *Applied Soft Computing*, 100, 106943.
- Mehtab, S., Sen, J., & Dutta, A. (2020, October). *Stock price prediction using machine learning and LSTM-based deep learning models*. In *Symposium on Machine Learning and Metaheuristics Algorithms, and Applications* (pp. 88-106). Springer, Singapore.
- Chhajer, P., Shah, M., & Kshirsagar, A. (2022). *The applications of artificial neural networks, support vector machines, and long-short term memory for stock market prediction*. *Decision Analytics Journal*, 2, 100015.
- generative adversarial networks. *Sensors*, 20(24), 7211.
- Zhou, K., Wang, W., Huang, L., & Liu, B. (2021). *Comparative study on the time series forecasting of web traffic based on statistical model and Generative Adversarial model*. *Knowledge-Based Systems*, 213, 106467.
- Lin, H. C., Chen, C., Huang, G. F., & Jafari, A. (2021). *Stock price prediction using generative adversarial networks*. *J. Comp. Sci*, 17-188.
- Staffini, A. (2022). *Stock Price Forecasting by a Deep Convolutional Generative Adversarial Network*. *Frontiers in Artificial Intelligence*, 5.
- Kim, K. J., & Han, I. (2000). *Genetic algorithms approach to feature discretization in artificial neural networks for the prediction of stock price index*. *Expert systems with Applications*, 19(2), 125-132.
- Ding, X., Zhang, Y., Liu, T., & Duan, J. (2015, June). *Deep learning for event-driven stock prediction*. In *Twenty-fourth international joint conference on artificial intelligence*
- Chong, E., Han, C., & Park, F. C. (2017). *Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies*. *Expert Systems with Applications*, 83, 187-205.
- Singh, R., & Srivastava, S. (2017). *Stock prediction using deep learning*. *Multimedia Tools and Applications*, 76(18), 18569-18584.
- Nakagawa, K., Uchida, T., & Aoshima, T. (2018, September). *Deep factor model*. In *ECML PKDD 2018 Workshops* (pp. 37-50). Springer, Cham
- Chatzis, S. P., Siakoulis, V., Petropoulos, A., Stavroulakis, E., & Vlachogiannakis, N. (2018). *Forecasting stock market crisis events using deep and statistical machine learning techniques*. *Expert systems with applications*, 112, 353-371.
- Abe, M., & Nakayama, H. (2018, June). *Deep learning for forecasting stock returns in the cross-section*. In *Pacific-Asia conference on knowledge discovery and data mining* (pp. 273-284). Springer, Cham.

overview. *ieee vehicular technology magazine*, 14(1), 62-70.

Graves, A. (2012). Long short-term memory. *Supervised sequence labelling with recurrent neural networks*, 37-45.

Olah, C. (2015). *Understanding lstm networks*.

Drumond, R. R., Marques, B. A. D., Vasconcelos, C. N., & Clua, E. (2018). An LSTM recurrent network for motion classification from sparse data. In *Proceedings of the 13th international joint conference on computer vision, imaging and computer graphics theory and applications (Vol. 1, pp. 215-22)*.

Achyutha, P. N., Chaudhury, S., Bose, S. C., Kler, R., Surve, J., & Kaliyaperumal, K. (2022). *User Classification and Stock Market-Based Recommendation Engine Based on Machine Learning and Twitter Analysis. Mathematical Problems in Engineering*, 2022.

Romero, R. A. C. *Generative adversarial network for stock market price prediction*.

Keras. (2015). [Online]. Available: Available: <https://github.com/fchollet/keras>

Ferdowsi, A., Challita, U., & Saad, W. (2019). *Deep learning for reliable mobile edge analytics in intelligent transportation systems: An*

## **Predicting prices of stocks listed in Tehran Stock Exchange using Generative Adversarial Networks**

<sup>1</sup>Reza Raei\*

<sup>2</sup>Ali Namaki

<sup>3</sup>Saeed Bajalan

<sup>4</sup>Sara Najafe zade

### **Abstract**

*Investors are willing to invest in the capital market which would earn a proper profit and would make the possibility of an accurate forecast of future trends and prices. In this regard, deep learning (DL) networks have been able to help in predicting the capital market movement. Due to the high capacity of DL approaches in many fields due to their strong capacity, they have been widely used in financial issues such as stock market movement prediction, portfolio optimization, financial information processing, etc. Recently, generative adversarial networks (GANs) illustrated suitable results intending to analyze and predict time series data. Therefore, in this study, the GAN consisting of a convolutional neural network as a generator and long short-term memory in the adversarial network is proposed for stock price prediction. In addition, in order to increase the accuracy of the network, other DL approaches have been used in network training. The results of the daily data of the Tehran Stock Exchange between 1394 to 1398 demonstrate that the prediction accuracy of the GAN network using the most appropriate features is up to 10%. The experimental results of this model show that the GAN network with the mentioned architecture can have a promising performance in stock price prediction compared to other DL models.*

**Keywords:** *Deep learning; generative adversarial network; stock market prediction; financial markets.*

---

<sup>1</sup> Professor of Finance, Finance and Insurance Department, Faculty of Management, University of Tehran, Tehran, Iran. (Corresponding Author) raei@ut.ac.ir

<sup>2</sup> Assistant professor of Finance, Finance and Insurance Department, Faculty of Management, University of Tehran, Tehran, Iran. alinamaki@ut.ac.ir

<sup>3</sup> Assistant professor of Finance, Finance and Insurance Department, Faculty of Management, University of Tehran, Tehran, Iran. saeedbajalan@ut.ac.ir

<sup>4</sup> Master of Finance, Finance and Insurance Department, Faculty of Management, University of Tehran, Tehran, Iran rjj3260@gmail.com