



## مدل سازی تأثیر متغیرهای کمی بر روی رفتار سرمایه گذاران فردی با استفاده از شبکه های

### عصبی مصنوعی در بورس تهران

مهران عباسی کارچگان<sup>۱</sup>

مهرزاد مینویی<sup>۲</sup>

حسین ممبینی<sup>۳</sup>

تاریخ دریافت مقاله: ۱۴۰۴/۰۴/۱۷ تاریخ پذیرش مقاله: ۱۴۰۴/۰۶/۰۱

#### چکیده

امروزه سرمایه گذاران فردی نقشی کلیدی در پویایی بازارهای مالی ایفا می کنند و تصمیمات آن ها تأثیر بسزایی بر نوسانات قیمتی، نقدینگی و کارایی بازار دارد. رفتار این گروه از سرمایه گذاران معمولاً تحت تأثیر عوامل مختلفی از جمله شاخص های کلان اقتصادی، شرایط بازار و روانشناسی سرمایه گذاری قرار می گیرد. درک صحیح این رفتارها می تواند به بهبود استراتژی های معاملاتی و توسعه مدل های پیش بینی دقیق تر کمک کند. به همین منظور مطالعه حاضر با هدف، مدل سازی تأثیر متغیرهای کمی بر روی رفتار سرمایه گذاران فردی و هم چنین پیش بینی رفتار سرمایه گذاران حقیقی در بازار سرمایه ایران با استفاده از شبکه های عصبی مصنوعی و عمیق انجام شد. در این راستا، شش متغیر وابسته شامل حجم خرید و فروش، تغییرات قیمت سهام، بازدهی کل سرمایه گذاری، تمایل به نگهداری یا فروش، تصمیمات ورود یا خروج از بازار و الگوهای معاملاتی (بلندمدت یا کوتاهمدت) انتخاب و با استفاده از چهار مدل یادگیری شامل ANN، LSTM، RNN و DNN بر پایه داده های واقعی بازار از جمله اطلاعات بازار، شاخص های تکنیکال و شاخص های اقتصادی آموزش داده شدند. نتایج مطالعه نشان داد مدل های بازگشتی (به ویژه LSTM) در پیش بینی متغیرهای زمانی و پیوسته عملکرد دقیق تری نسبت به سایر مدل ها دارند. همچنین در متغیرهای باینری (کلاسه بندی شده)، مدل DNN در برخی موارد (مانند تصمیمات سرمایه گذاری و الگوهای معاملاتی) دقت بیشتری را نسبت به سایر مدل ها ارائه کرد. در عین حال، یافته ها بیانگر آن است که صرف استفاده از معماری های پیچیده تر، لزوماً منجر به عملکرد بهتر نمی شود. از آنجاکه تمرکز این مطالعه بر متغیرهای کمی بوده، پیشنهاد می شود در مطالعات آتی، متغیرهای کیفی نیز وارد فرآیند مدل سازی شوند تا تبیین دقیق تری از رفتار سرمایه گذاران به دست آید.

#### کلمات کلیدی:

پیش بینی، سرمایه گذاران فردی، ANN، DNN، RNN، LSTM، شبکه های عصبی مصنوعی

۱- گروه مدیریت مالی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران. m.abbasikarchegan@iau.ac.ir

۲- گروه مدیریت مالی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران (نویسنده مسئول) 2200077025@iau.ac.ir

۳- گروه مدیریت مالی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران. hos.mombeini@iauctb.ac.ir

امروزه سرمایه گذاری در بورس بخش مهمی از اقتصاد را تشکیل می دهد (دولو و همکاران، ۲۰۱۷). سرمایه گذاران فردی نقشی کلیدی در پویایی بازارهای مالی ایفا می کنند و تصمیمات آن ها تأثیر بسزایی بر نوسانات قیمتی، نقدینگی و کارایی بازار دارد. رفتار این گروه از سرمایه گذاران معمولاً تحت تأثیر عوامل مختلفی از جمله شاخص های کلان اقتصادی، شرایط بازار و روانشناسی سرمایه گذاری قرار می گیرد (باربر و همکاران، ۲۰۱۳). درک صحیح این رفتارها می تواند به بهبود استراتژی های معاملاتی و توسعه مدل های پیش بینی دقیق تر کمک کند.

در سال های اخیر، استفاده از روش های هوش مصنوعی به عنوان یکی از کارآمدترین ابزارها برای تحلیل الگوهای پیچیده رفتاری در بازارهای مالی مورد توجه قرار گرفته و موجب ایجاد تحول عظیمی در این حوزه شده است. پویایی بازارهای مالی و تغییرات دائمی در آن، موجب شده است که این بازار نیازمند یک فرآیند تصمیم گیری سریع و دقیق باشد (میلانا و همکاران، ۲۰۲۱؛ لئونگ و همکاران، ۲۰۰۰). مدل های سنتی اقتصادسنجی اگرچه در تحلیل سری های زمانی مالی موفق بوده اند، اما با توجه به تعدد پارامترهای موجود در بازارهای مالی و غیرخطی و نوسان پذیر بودن آن ها، این مدل ها در شناسایی روابط غیرخطی و پیچیده میان متغیرهای متعدد بازارهای مالی محدودیت دارند (سزر و همکاران، ۲۰۲۰). در مقابل، شبکه های عصبی مصنوعی قادرند از طریق یادگیری الگوهای پنهان در داده های مالی، پیش بینی های دقیق تری ارائه دهند. این مدل ها با استفاده از الگوریتم های بهینه سازی و یادگیری، قادرند داده های کمی و کیفی را به صورت هم زمان پردازش کرده و الگوهای معاملاتی سرمایه گذاران را شناسایی کنند (فیشر، ۲۰۱۸).

در ایران نیز استفاده از هوش مصنوعی برای تحلیل و پیش بینی بازارهای مالی در چند سال اخیر بسیار مورد توجه قرار گرفته است. با توجه به پیچیدگی و نوسانات بازارهای مالی ایران، فناوری هوش مصنوعی می تواند با تحلیل حجم بالای داده ها و شناسایی صحیح الگوها به کاهش عدم قطعیت و افزایش دقت در تصمیم گیری های سرمایه گذاری کمک کند. عوامل متعددی بر تصمیم گیری سرمایه گذاران فردی در بورس تهران تأثیرگذار است، از جمله نرخ بهره، نرخ تورم، نرخ ارز، تولید ناخالص داخلی<sup>۱</sup>، حجم معاملات، شاخص کل بورس و تغییرات قیمت سهام؛ بنابراین، در این پژوهش، از روش های یادگیری عمیق نظیر ANN، DNN، RNN و LSTM برای مدل سازی رفتار سرمایه گذاران در بورس تهران استفاده شده است.

## فصلنامه مهندسی مالی و مدیریت اوراق بهادار / دوره ۱۶ / شماره ۶۵ / زمستان ۱۴۰۴

انتخاب روش مناسب برای پیش‌بینی رفتار سرمایه‌گذاران اهمیت زیادی دارد. تحقیقات نشان داده‌اند که مدل‌های LSTM و RNN برای تحلیل داده‌های سری زمانی بهتر عمل می‌کنند، زیرا می‌توانند وابستگی‌های زمانی بلندمدت را در نظر بگیرند (هوخرایتر، ۱۹۹۷). در مقابل، مدل‌های ANN و DNN در تحلیل روابط پیچیده بین متغیرها و استخراج ویژگی‌های مؤثر بر تصمیمات معاملاتی عملکرد مطلوبی دارند (هیتون، ۲۰۱۶). این پژوهش به بررسی عملکرد این مدل‌ها در پیش‌بینی رفتار سرمایه‌گذاران پرداخته و نتایج آن‌ها را با یکدیگر مقایسه می‌کند.

نتایج این پژوهش می‌تواند به فعالان بازار سرمایه، تحلیلگران و سیاست‌گذاران کمک کند تا رفتار سرمایه‌گذاران فردی را بهتر درک کرده و از آن در تدوین استراتژی‌های معاملاتی و سیاست‌گذاری‌های مالی استفاده کنند. همچنین، یافته‌های این تحقیق می‌تواند به بهبود مدل‌های پیش‌بینی در بازارهای مالی دیگر نیز کمک کند.

**مبانی نظری پژوهش:**

### **مقدمه‌ای بر رفتار سرمایه‌گذاران در بازارهای مالی**

رفتار سرمایه‌گذاران در بازارهای مالی همواره یکی از موضوعات مهم در اقتصاد مالی و مدیریت سرمایه‌گذاری بوده است. سرمایه‌گذاران فردی در تصمیم‌گیری‌های خود تحت تأثیر عوامل مختلفی مانند نرخ بهره، تورم، نرخ ارز و شاخص‌های کلان اقتصادی قرار دارند (فاما، ۱۹۷۰). نظریه بازارهای کارا بیان می‌کند که قیمت‌های دارایی‌ها منعکس‌کننده تمامی اطلاعات در دسترس است و هیچ سرمایه‌گذاری نمی‌تواند به‌طور سیستماتیک بازدهی بیش‌ازحد بازار کسب کند (مالکیل، ۲۰۰۳). با این حال، مطالعات نشان داده‌اند که سرمایه‌گذاران فردی اغلب رفتارهای غیرعقلانی از خود نشان می‌دهند و تصمیمات آن‌ها ممکن است از عوامل احساسی و شناختی نیز تأثیر بپذیرد (باربر، ۲۰۱۳).

### **اهمیت مدل‌سازی رفتار سرمایه‌گذاران با داده‌های کمی**

مدل‌سازی رفتار سرمایه‌گذاران بر اساس داده‌های کمی می‌تواند به درک بهتر روندهای بازار کمک کند. داده‌های کمی شامل متغیرهایی مانند نرخ بهره، تورم، نرخ ارز، GDP، حجم معاملات، قیمت پایانی سهام، تغییرات قیمت سهام و شاخص کل بورس هستند. این متغیرها معمولاً از منابع معتبر اقتصادی مانند بانک مرکزی، سازمان بورس و مرکز آمار ایران استخراج می‌شوند و در بسیاری از مطالعات به‌عنوان عوامل تأثیرگذار بر رفتار سرمایه‌گذاران مورد بررسی قرار گرفته‌اند (فرسون، ۱۹۹۱). روش‌های سنتی مانند مدل‌های سری زمانی (ARIMA, GARCH) و مدل‌های رگرسیونی برای

## مدل سازی تاثیر متغیرهای کمی بر روی رفتار سرمایه گذاران.../عباسی کارچگان، مینویی و ممبینی

تحلیل این داده‌ها استفاده می‌شوند، اما در سال‌های اخیر، روش‌های یادگیری ماشین و شبکه‌های عصبی مصنوعی عملکرد بهتری در پیش‌بینی تغییرات بازار نشان داده‌اند (لئونگ، ۲۰۰۰).

### شبکه‌های عصبی مصنوعی<sup>۲</sup> و یادگیری عمیق<sup>۳</sup> در پیش‌بینی بازار

شبکه‌های عصبی مصنوعی (ANN) و یادگیری عمیق به دلیل توانایی آن‌ها در کشف الگوهای پیچیده و غیرخطی در داده‌های مالی، مورد توجه محققان بازار سرمایه قرار گرفته‌اند (هیتون، ۲۰۱۶). مدل‌های ANN و DNN با استفاده از چندین لایه پردازشی، روابط میان متغیرهای ورودی و خروجی را به‌طور خودکار یاد می‌گیرند. در حالی که مدل‌های سنتی ممکن است در شناسایی روابط غیرخطی میان متغیرهای اقتصادی محدودیت داشته باشند، مدل‌های یادگیری عمیق می‌توانند ارتباطات پیچیده‌تر را کشف کنند (جو و همکاران، ۲۰۲۰). مطالعات نشان داده‌اند که استفاده از شبکه‌های عصبی برای پیش‌بینی بازارهای مالی می‌تواند دقت بیشتری نسبت به روش‌های سنتی داشته باشد (فیشر، ۲۰۱۸). مدل‌های LSTM و RNN به‌ویژه در تحلیل داده‌های سری زمانی بازارهای مالی موفق عمل کرده‌اند، زیرا قادرند الگوهای وابسته به زمان را در داده‌های معاملاتی در نظر بگیرند (هوخرایت، ۱۹۹۷).

مطالعاتی که تنها از داده‌های کمی برای پیش‌بینی رفتار سرمایه‌گذاران استفاده کرده‌اند، نشان داده‌اند که مدل‌های یادگیری عمیق می‌توانند وابستگی‌های پیچیده میان متغیرهای کلان اقتصادی و روندهای معاملاتی را کشف کنند (آتلاکیس و همکاران، ۲۰۰۹). با این حال، این مدل‌ها هنوز نمی‌توانند تأثیر عوامل رفتاری و روان‌شناختی سرمایه‌گذاران را به‌طور کامل در نظر بگیرند. در این پژوهش، از داده‌های کمی مانند شاخص‌های کلان اقتصادی و داده‌های معاملاتی بورس تهران برای پیش‌بینی رفتار سرمایه‌گذاران فردی استفاده خواهد شد؛ و در مطالعات آینده، مدل توسعه‌یافته و داده‌های کیفی (رفتاری) به آن اضافه خواهند شد تا میزان تأثیر عوامل روان‌شناختی بر تصمیمات سرمایه‌گذاران بررسی شود. این پژوهش قصد دارد نشان دهد که تا چه اندازه مدل‌های مبتنی بر شبکه‌های عصبی مصنوعی قادرند رفتار سرمایه‌گذاران را بر اساس داده‌های کمی پیش‌بینی کنند.

### مروری بر مطالعات پیشین:

سینایی و همکاران (۲۰۰۵) در مطالعه‌ای با عنوان "پیش‌بینی شاخص بورس اوراق بهادار تهران با استفاده از شبکه‌های عصبی مصنوعی" به پیش‌بینی شاخص قیمت سهام در بورس اوراق بهادار تهران پرداختند. دو مجموعه از داده‌ها شامل وقفه‌های مختلفی از شاخص و عوامل کلان اقتصادی به‌عنوان

## فصلنامه مهندسی مالی و مدیریت اوراق بهادار / دوره ۱۶ / شماره ۶۵ / زمستان ۱۴۰۴

متغیرهای مستقل و ورودی شبکه عصبی انتخاب شدند. هم‌چنین از مدل خطی ARIMA برای پیش‌بینی شاخص قیمت در هفته‌ی بعدی استفاده شد. نتایج حاصل از پژوهش نشان می‌دهد که شبکه‌های عصبی عملکرد بهتری نسبت به مدل خطی ARIMA برای پیش‌بینی شاخص قیمت دارند.

تهرانی و همکاران (۲۰۱۴) در مطالعه‌ای با عنوان پیش‌بینی رفتار سرمایه‌گذاری شرکت‌های بورس اوراق بهادار تهران با استفاده از شبکه‌های عصبی در یک رویکرد جامع‌نگر و با استفاده از روش فرا تلفیق، ابتدا عوامل اثرگذار بر سرمایه‌گذاری شرکتی را شناسایی کردند. سپس با استفاده از روش مدل‌سازی علی، روابط میان متغیرهای مدل استخراج و در نهایت مدل به‌وسیله شبکه‌ی عصبی آزمون شد. نتایج مطالعه نشان‌دهنده توانایی بیش از ۶۲ درصد مدل، در پیش‌بینی رفتار سرمایه‌گذاری شرکت‌ها در بورس اوراق بهادار تهران بود.

سهرابی و همکاران (۲۰۲۳) در مطالعه‌ای با عنوان "مقایسه مدل‌های مختلف یادگیری ماشین در پیش‌بینی شاخص بازار سهام" با بهره‌گیری از مقایسه مدل‌های مختلف یادگیری ماشین از قبیل رویکردهای RF، SVM، ANN و LSTM به بررسی توانایی مدل‌های مختلف یادگیری ماشین در پیش‌بینی شاخص کل بورس اوراق بهادار تهران در طی دوره ۱۳۹۲ تا ۱۳۹۹ پرداختند. نتایج پیش‌بینی دوره‌های ۱، ۳ و ۶ روزه نشان داد که روش LSTM در مقایسه با سایر مدل‌های موردبررسی نتیجه بهتری داشته است.

### **روش پژوهش:**

#### **متغیرها:**

در مطالعه حاضر متغیرها به دو دسته کلی متغیرهای مستقل و متغیرهای وابسته تقسیم می‌شوند. کلیه داده‌ها در بازه ۱۳۹۳ تا پایان ۱۴۰۳ جمع‌آوری شدند. در ادامه به تفکیک به شرح و توضیح هر یک پرداخته می‌شود.

#### **متغیرهای مستقل:**

در این مطالعه متغیرهای مستقل به سه گروه اطلاعات بازار، شاخص‌های اقتصادی و شاخص‌های تکنیکال تقسیم می‌شوند.

**اطلاعات بازار:** این دسته از متغیرها، متغیرهای مالی بورس می‌باشند که شامل اطلاعات حجم معاملات، قیمت پایانی، بیشترین قیمت معامله‌شده، کمترین قیمت معامله‌شده و شاخص کل است. اطلاعات مذکور از طریق شرکت مدیریت فناوری بورس تهران<sup>۴</sup>، بورس تهران<sup>۵</sup> و سازمان بورس اوراق

## مدل سازی تاثیر متغیرهای کمی بر روی رفتار سرمایه گذاران.../عباسی کارچگان، مینویی و ممبینی

بهادار<sup>۶</sup> جمع آوری شدند. گزارش متغیر شاخص کل به صورت روزانه بود حال آنکه سایر متغیرها به تفکیک کلیه نمادهای معامله شده در هر روز گزارش شدند. به همین دلیل کلیه اطلاعات به صورت روزانه تجمیع شدند. حجم معاملات روزانه از حاصل جمع معاملات کلیه نمادهای معامله شده در هر روز محاسبه گردید. به منظور محاسبه قیمت پایانی، بیشتری و کمترین قیمت روزانه نیز از میانگین قیمت گزارش شده برای نمادهای معامله شده در هر روز استفاده شد.

**شاخص های اقتصادی:** این دسته از متغیرها شامل متغیرهای GDP، نرخ ارز (دلار)، قیمت طلا، نرخ بهره و نرخ تورم می باشد. اطلاعات مربوط به نرخ بهره از بانک مرکزی<sup>۷</sup>، اطلاعات نرخ تورم و آمارهای اقتصادی از مرکز آمار ایران<sup>۸</sup> و نرخ ارز و قیمت طلا از بازار آزاد<sup>۹</sup> استخراج شدند. داده های GDP، نرخ تورم و نرخ بهره به صورت سالیانه و داده های نرخ ارز و قیمت طلا به صورت روزانه گزارش شدند. داده های گزارش شده برای GDP و نرخ تورم به ترتیب تا پایان سال ۴۰۱ و ۴۰۲ بود به همین دلیل در فرآیند آماده سازی داده های پژوهش، به منظور تکمیل داده های ناقص از روش های تخمین داده استفاده شد. برای متغیر GDP که ماهیتی پایدار و تغییرات آن در بلندمدت نسبتاً یکنواخت است، میانگین نرخ رشد سالیانه در کل دوره زمانی موجود (سال های ۱۳۹۳ تا ۱۴۰۱) محاسبه گردید و این مقدار به عنوان مبنای برآورد برای سال های فاقد داده (۱۴۰۲ و ۱۴۰۳) مورد استفاده قرار گرفت. این انتخاب مبتنی بر ویژگی بنیادی متغیر GDP و ثبات نسبی آن طی دوره های اقتصادی می باشد. در مقابل، برای متغیر نرخ تورم، با توجه به نوسانات شدید و وابستگی بالای آن به شرایط اقتصادی، سیاسی و ارزی کشور در سال های اخیر، از میانگین نرخ رشد سالیانه تورم در سه سال پایانی دوره (۱۴۰۰ تا ۱۴۰۲) استفاده گردید. این رویکرد به منظور انعکاس بهتر شرایط جاری اقتصادی و افزایش دقت پیش بینی نرخ تورم سال ۱۴۰۳ اتخاذ شد. بدین ترتیب سعی شده است در تخمین داده های ناقص، ماهیت آماری و رفتار زمانی هر متغیر به دقت مدنظر قرار گیرد تا خطای برآورد حداقل گردد. با توجه به اینکه اطلاعات GDP، نرخ بهره و نرخ تورم به صورت سالیانه گزارش شدند مقادیر هر سال به تمام روزهای سال مربوطه تعمیم داده شد.

**شاخص های تکنیکال:** در این پژوهش، به منظور استخراج ویژگی های فنی از داده های بورس تهران، از شاخص های متداول تحلیل تکنیکال شامل میانگین متحرک<sup>۱۰</sup>، شاخص قدرت نسبی<sup>۱۱</sup>، همگرایی-واگرایی میانگین متحرک<sup>۱۲</sup>، میانگین دامنه واقعی<sup>۱۳</sup> و حجم تعادلی<sup>۱۴</sup> استفاده شد. بازه های زمانی این شاخص ها به شرح زیر تعیین گردیده است:

متغیر MA-10 در یک بازه ۱۰ روزه محاسبه شد. در این بازه نوسانات کوتاه مدت و رفتار سریع

## فصلنامه مهندسی مالی و مدیریت اوراق بهادار / دوره ۱۶ / شماره ۶۵ / زمستان ۱۴۰۴

بازار مشخص می‌شود. MA-20 با بازه حدود یک ماه معاملاتی محاسبه شد و MA-50 به منظور تحلیل روندهای میان مدت استفاده شد. این بازه نوسانات موقتی را فیلتر کرده و روندهای پایدارتر را مشخص می‌کند.

شاخص قدرت نسبی ۱۴ روزه (RSI-14): بازه ۱۴ روز برای محاسبه RSI، مقدار استاندارد و توصیه شده توسط خالق این شاخص، J. Welles Wilder، می‌باشد. این بازه به اندازه‌ای کوتاه هست که نوسانات سریع بازار را ثبت کند و درعین حال به اندازه‌ای طولانی هست که نویزهای تصادفی کاهش یابد (ویلدر، ۱۹۷۸).

MACD (۱۲,۲۶,۹): پارامترهای استاندارد محاسبه MACD، یعنی میانگین متحرک نمایی ۱۲ و ۲۶ روزه و خط سیگنال ۹ روزه، به طور گسترده در تحلیل‌های تکنیکال استفاده می‌شوند. این پارامترها توسط Gerald Appel، طراح این شاخص، معرفی شده‌اند و اثبات شده که تعادلی مناسب میان حساسیت به تغییرات بازار و پایدار بودن روندها ایجاد می‌کنند (اپل، ۱۹۸۵).

ATR-14: مشابه RSI، محاسبه ATR بر مبنای ۱۴ روز یکی از استانداردهای اولیه تحلیل تکنیکال است که توسط ویلدر<sup>۱۵</sup> معرفی شده و در اکثر منابع معتبر مالی پذیرفته شده است. ATR-14 موجب می‌شود نوسانات قیمتی به شکلی متعادل و قابل اتکا برای مدل‌های پیش‌بینی کمی شوند (ویلدر، ۱۹۷۸).

### متغیرهای وابسته:

در این مطالعه متغیرهای حجم خرید و فروش، تمایل به نگهداری یا فروش سهام، تصمیمات سرمایه‌گذاری (ورود یا خروج از بازار)، الگوهای معاملاتی (بلندمدت یا کوتاه‌مدت)، تغییرات قیمت سهام و بازدهی کل سرمایه‌گذاری به عنوان متغیر وابسته در نظر گرفته شد. در ادامه متغیرهای مذکور شرح داده می‌شوند:

**حجم خرید و فروش:** تحلیل این متغیر کمک می‌کند رفتار بازار را بهتر تحلیل کنیم به عبارت دیگر افزایش حجم به معنای ورود سرمایه جدید یا افزایش تقاضا و کاهش حجم به معنای کم شدن علاقه‌ی معامله‌گران یا افزایش عرضه می‌باشد.

**تغییرات قیمت سهام:** این متغیر به منظور بررسی تغییرات روزانه قیمت سهام در نظر گرفته شد که اختلاف قیمت پایانی هر روز نسبت به روز قبل را نشان می‌دهد. این متغیر بیانگر رفتار نوسانی قیمت در بازار است.

## مدل سازی تاثیر متغیرهای کمی بر روی رفتار سرمایه گذاران.../عباسی کارچگان، مینویی و ممبینی

**بازدهی کل سرمایه گذاری:** برای سنجش بازده کل، ابتدا قیمت پایانی روز گذشته از طریق اختلاف بین قیمت پایانی امروز و تغییرات قیمت روزانه محاسبه شد. سپس بازده کل به صورت درصد تغییر قیمت پایانی نسبت به روز گذشته از طریق فرمول یک محاسبه شد:

$$\text{بازدهی کل} = \left( \frac{\text{قیمت پایانی روز گذشته} - \text{قیمت پایانی}}{\text{قیمت پایانی روز گذشته}} \right) * 100 \quad (1)$$

این شاخص معیاری از سود یا زیان نسبی سرمایه گذاری در هر روز ارائه می دهد.

**تمایل به نگهداری یا فروش:** برای تعیین تمایل سرمایه گذاران به نگهداری یا فروش دارایی ها، از بازده کل و حجم معاملات استفاده شد. معیار به شرح زیر تعریف شد:

اگر بازده روزانه مثبت باشد و حجم معاملات کمتر از میانه ی کل حجم معاملات باشد، فرض بر این است که سرمایه گذاران تمایل به نگهداری دارایی های خود دارند. در غیر این صورت، تمایل به فروش دارایی ها فرض شده است.

**تصمیمات سرمایه گذاری (ورود یا خروج از بازار):** با بررسی تغییرات حجم معاملات بین دو روز متوالی، رفتار سرمایه گذاران به شرح زیر طبقه بندی شد:

اگر حجم معاملات نسبت به روز قبل افزایش یافته باشد، نشان دهنده ی ورود سرمایه گذاران جدید به بازار است، در غیر این صورت، خروج سرمایه گذاران از بازار فرض گرفته شد.

**الگوهای معاملاتی (بلندمدت یا کوتاه مدت):** برای تعیین نوع الگوهای معاملاتی، نوسانات قیمت و حجم معاملات مورد استفاده قرار گرفت. اگر تغییرات قیمت فراتر از یک انحراف معیار باشد و حجم معاملات نیز بیشتر از میانه ی حجم باشد، فرض شد معامله گران کوتاه مدت فعالیت بیشتری دارند، در غیر این صورت، رفتار سرمایه گذاران بلندمدت فرض گرفته شده است.

### **روش تحلیل:**

پس از آماده سازی داده های مورد نیاز به منظور مدل سازی و پیش بینی رفتار سرمایه گذاران فردی از چهار مدل شبکه عصبی ANN، RNN، DNN و LSTM استفاده شد. به منظور مدل سازی ۷۰ درصد داده ها (از سال ۱۳۹۳ تا پایان ۱۴۰۰) به عنوان داده های آموزش مدل، ۱۰ درصد داده ها (۱۴۰۱) برای اعتبارسنجی مدل و ۲۰ درصد داده ها (از سال ۱۴۰۲ تا پایان ۱۴۰۳) برای پیش بینی در نظر گرفته شد. در متغیرهای حجم خرید و فروش، بازدهی کل سرمایه گذاری و تغییرات قیمت سهام با توجه به پیوسته بودن داده ها از معیارهای MSE و MAE برای اعتبارسنجی مدل استفاده شد؛ و در متغیرهای



## فصلنامه مهندسی مالی و مدیریت اوراق بهادار / دوره ۱۶ / شماره ۶۵ / زمستان ۱۴۰۴

الگوهای معاملاتی، تصمیمات سرمایه‌گذاری و تمایل به نگهداری یا فروش سهام با توجه به اینکه داده‌ها کلاسه‌بندی (۰ و ۱) می‌باشند، معیار Accuracy به‌منظور اعتبارسنجی مدل در نظر گرفته شد. ساختار شبکه‌های عصبی، شامل تعداد نوروها و نرخ حذف تصادفی نوروها، عمدتاً از طریق رویکردهای تجربی، مبتنی بر قواعد رایج در یادگیری عمیق و فرآیند تنظیم هیپرپارامترها<sup>۱۶</sup> تعیین می‌شود. در این پژوهش نیز ساختار نهایی هر مدل پس از ارزیابی چندین ساختار مختلف انتخاب شد. کلیه مراحل مدل‌سازی با استفاده از نرم‌افزار پایتون انجام شد. در ادامه در جدول‌های ۱ تا ۶ جزئیات مدل‌سازی به تفکیک متغیر شرح داده شده است:

### جدول ۱- ساختار مدل شبکه عصبی مصنوعی برای متغیر حجم خرید و فروش

Table 1- Artificial Neural Network Model Structure for the Variable of Trading Volume

	ANN	DNN	RNN	LSTM
تعداد لایه مخفی	۲	۳	۱	۱
تعداد نوروها در هر لایه	۶۴→۳۲	۱۲۸→۶۴→۳۲	۵۰	۶۴
ساختار ورودی	۱۰ ویژگی	۱۰ ویژگی	نمونه‌ها، ۱ گام زمانی، ۹ ویژگی	نمونه‌ها، ۱ گام زمانی، ۹ ویژگی
ساختار خروجی	۱ خروجی عددی	۱ خروجی عددی	۱ خروجی عددی	۱ خروجی عددی
تابع فعال‌سازی لایه‌های پنهان	ReLU	ReLU	tanh	tanh
تابع فعال‌سازی لایه خروجی	خطی	خطی	خطی	خطی
تابع هزینه	MSE	MSE	MSE	MSE
حذف تصادفی نوروها (dropout)	۰/۲، ۰/۳	۰/۳، ۰/۳، ۰/۲	۰/۳ بعد از لایه RNN	LSTM بعد از لایه LSTM
دوره	۱۰۰	۱۰۰	۱۰۰	۱۰۰
دسته	۳۲	۳۲	۳۲	۳۲

منبع: یافته‌های پژوهشگر

در مدل‌های ANN و DNN، افزایش تدریجی تعداد نوروها از لایه‌های خروجی به سمت ورودی، با هدف افزایش ظرفیت مدل برای درک روابط غیرخطی بین ویژگی‌ها انجام شده است. به‌عنوان مثال، مدل DNN از سه لایه پنهان با ۱۲۸، ۶۴ و ۳۲ نورو استفاده می‌کند. این ساختار پلکانی کمک می‌کند که اطلاعات در ابتدا به‌صورت گسترده پردازش شده و در مراحل بعدی فشرده‌تر شوند که باعث افزایش دقت در مسائل رگرسیونی می‌شود.

در مدل‌های ANN و DNN داده‌ها به‌صورت برداری به کار گرفته شد. برای مدل‌های RNN و LSTM داده‌ها به‌صورت دنباله‌ای با یک گام زمانی وارد شدند (فرمت سه‌بعدی)، زیرا این مدل‌ها

## مدل سازی تاثیر متغیرهای کمی بر روی رفتار سرمایه گذاران.../عباسی کارچگان، مینویی و ممبینی

قابلیت تحلیل سری‌های زمانی را دارند. در همه مدل‌ها تعداد دوره ۱۰۰ و اندازه دسته برابر ۳۲ در نظر گرفته شد تا تعادل مناسبی بین سرعت آموزش و دقت مدل برقرار شود.

در مدل‌های ANN و DNN، از تابع فعال‌سازی ReLU در لایه‌های پنهان استفاده شد. ReLU به دلیل کارایی محاسباتی بالا و جلوگیری از مشکل ناپدید شدن گرادیان‌ها یکی از رایج‌ترین توابع در مدل‌های یادگیری عمیق است. در مدل‌های RNN و LSTM، تابع فعال‌سازی tanh استفاده شد که مناسب پردازش داده‌های ترتیبی و زمانی است. این تابع در بازه  $[-1, 1]$  خروجی می‌دهد و در شبکه‌های بازگشتی باعث پایداری رفتار در زنجیره‌های طولانی می‌شود. چون مدل رگرسیونی است (خروجی مدل یک مقدار پیوسته برای حجم خرید و فروش است)، تابع فعال‌سازی خطی برای خروجی انتخاب شد تا مدل بتواند مقادیر واقعی را بدون محدودیت دامنه بازتولید کند.

برای تمامی مدل‌ها، MSE به عنوان تابع هزینه استفاده شد، چرا که برای مسائل رگرسیونی رایج‌ترین و مناسب‌ترین معیار است. این تابع خطای مدل را نسبت به مقادیر واقعی کمینه می‌کند و حساس به خطاهای بزرگ است. در تمام مدل‌ها از تکنیک Dropout برای جلوگیری از بیش‌برازش استفاده شد. در مدل‌های ANN و DNN پس از هر لایه مخفی از dropout بین ۲۰٪ تا ۳۰٪ استفاده شد، در حالی که در مدل‌های RNN و LSTM فقط پس از لایه بازگشتی این تکنیک به کار گرفته شد، چون ساختار بازگشتی خود موجب کاهش بیش‌برازش می‌شود و لایه‌های زیادی هم ندارد.

جدول ۲- ساختار مدل شبکه عصبی مصنوعی برای متغیر تغییرات قیمت سهام

Table 2- Artificial Neural Network Model Structure for the Variable of Stock Price Changes

	ANN	DNN	RNN	LSTM
تعداد لایه مخفی	۲	۳	۱	۱
تعداد نورون‌ها در هر لایه	۶۴ → ۳۲	۱۲۸ → ۶۴ → ۳۲	۵۰	۵۰
ساختار ورودی	۱۰ ویژگی	۱۰ ویژگی	۱ گام زمانی، ۹ ویژگی	۱ گام زمانی، ۹ ویژگی
ساختار خروجی	۱ خروجی عددی	۱ خروجی عددی	۱ خروجی عددی	۱ خروجی عددی
تابع فعال‌سازی لایه‌های پنهان	ReLU	ReLU	tanh	tanh
تابع فعال‌سازی لایه خروجی	خطی	خطی	خطی	خطی
تابع هزینه	MSE	MSE	MSE	MSE
dropout	ندارد	۰/۲، ۰/۲	۰/۳	۰/۳
دوره	۱۰۰	۱۰۰	۱۰۰	۱۰۰
دسته	۳۲	۳۲	۳۲	۳۲

منبع: یافته‌های پژوهشگر

### فصلنامه مهندسی مالی و مدیریت اوراق بهادار / دوره ۱۶ / شماره ۶۵ / زمستان ۱۴۰۴

در مدل‌های RNN و LSTM، تنها یک لایه بازگشتی با ۵۰ نورون استفاده شده است. دلیل آن، حفظ تعادل میان دقت و پیچیدگی مدل و جلوگیری از بیش‌برازش است، به‌ویژه که داده‌ها فقط دارای یک گام زمانی هستند و عمق زمانی زیادی نیاز ندارند.

در مدل DNN، دو لایه ابتدایی با dropout ۰/۲ مجهز شدند تا احتمال بیش‌برازش کاهش یابد. همچنین در مدل‌های RNN و LSTM، یک dropout با نرخ ۰/۳ بعد از لایه اصلی در نظر گرفته شد. در شبکه‌های بازگشتی که اغلب ظرفیت زیادی برای حفظ الگوها دارند، استفاده از حذف تصادفی نورون‌ها برای حفظ تعمیم‌پذیری ضروری است.

جدول ۳- ساختار مدل شبکه عصبی برای متغیر بازدهی کل سرمایه‌گذاری

Table 3- Artificial Neural Network Model Structure for the Variable of Total Investment Return

	ANN	DNN	RNN	LSTM
تعداد لایه مخفی	۲	۳	۱+۱	۱+۱
تعداد نورون‌ها در هر لایه	۱۲۸ → ۶۴	۲۵۶ → ۱۲۸ → ۶۴	۶۴+۳۲	۶۴+۳۲
ساختار ورودی	۱۷ ویژگی	۱۷ ویژگی	نمونه‌ها، ۱ گام زمانی، ۱۷ ویژگی	نمونه‌ها، ۱ گام زمانی، ۱۷ ویژگی
ساختار خروجی	۱ خروجی	۱ خروجی	۱ خروجی	۱ خروجی
تابع فعال‌سازی لایه‌های پنهان	ReLU	ReLU	ReLU, tanh (RNN), tanh (چگال)	ReLU, tanh (RNN), tanh (چگال)
تابع فعال‌سازی لایه خروجی	خطی	خطی	خطی	خطی
تابع هزینه	MSE	MSE	MSE	MSE
dropout	۰/۳	۰/۴، ۰/۳	۰/۳	۰/۳
دوره	۱۰۰	۱۰۰	۱۰۰	۱۰۰
دسته	۳۲	۳۲	۳۲	۳۲

منبع: یافته‌های پژوهشگر

در مدل ANN، از دو لایه پنهان با تعداد نورون‌های نسبتاً زیاد (۱۲۸ و ۶۴) استفاده شد تا ظرفیت مدل برای درک روابط پیچیده‌ی میان ویژگی‌های ورودی افزایش یابد. مدل DNN با افزایش عمق شبکه (سه لایه با ۲۵۶، ۱۲۸ و ۶۴ نورون) به دنبال استخراج ویژگی‌های سطح بالا و کاهش خطای مدل در داده‌های پیچیده است. مدل‌های RNN و LSTM که برای پردازش داده‌های ترتیبی و وابستگی‌های زمانی مناسب‌اند، از یک لایه بازگشتی با ۶۴ نورون آغاز شدند، سپس از یک لایه چگال با ۳۲ نورون برای پردازش غیرخطی استفاده شد.

مدل سازی تاثیر متغیرهای کمی بر روی رفتار سرمایه گذاران.../عباسی کارچگان، مینویی و ممبینی

در مدل های RNN و LSTM تابع tanh در لایه های اصلی مدل استفاده شد و در لایه های چگال بعدی ReLU و در خروجی ها، تابع خطی استفاده شد. برای جلوگیری از بیش برآزش، لایه های Dropout با نرخ ۳۰٪ تا ۴۰٪ بعد از برخی لایه ها در همه مدل ها اضافه شد.

جدول ۴- ساختار مدل شبکه عصبی برای متغیر تمایل به نگهداری یا فروش

**Table 4- Artificial Neural Network Model Structure for the Variable of Holding or Selling Tendency**

	ANN	DNN	RNN	LSTM
تعداد لایه مخفی	۲	۳	۱+۱	۱+۱
تعداد نورون ها در هر لایه	۶۴ → ۳۲	۱۲۸ → ۶۴ → ۳۲	۶۴+ ۳۲	۶۴+۳۲
ساختار ورودی	۱۵ ویژگی	۱۵ ویژگی	نمونه ها، ۱ گام زمانی، ۱۵ ویژگی	نمونه ها، ۱ گام زمانی، ۱۵ ویژگی
ساختار خروجی	۱ خروجی	۱ خروجی	۱ خروجی	۱ خروجی
تابع فعال سازی لایه های پنهان	RELU	ReLU	tanh + ReLU	tanh + ReLU
تابع فعال سازی لایه خروجی	sigmoid	sigmoid	sigmoid	sigmoid
تابع هزینه	Binary Crossentrop	Binary Crossentrop	Binary Crossentrop	Binary Crossentrop
dropout	ندارد	۰/۳	۰/۳	۰/۳
دوره	۱۰۰	۱۰۰	۱۰۰	۱۰۰
دسته	۳۲	۳۲	۳۲	۳۲

منبع: یافته های پژوهشگر

با توجه به اینکه این متغیر یک متغیر باینری می باشد تابع فعال سازی خروجی sigmoid انتخاب شد، زیرا خروجی مدل باید بین صفر و یک باشد. در تمام مدل ها تابع Binary Crossentrop به عنوان تابع هزینه انتخاب شد، زیرا مناسب ترین انتخاب برای مسائل باینری می باشد. این تابع اختلاف میان احتمال پیش بینی شده و برچسب واقعی را به خوبی اندازه گیری می کند.

جدول ۵- ساختار مدل شبکه عصبی برای متغیر تصمیمات سرمایه‌گذاری

**Table 5- Artificial Neural Network Model Structure for the Variable of Investment Decisions**

	ANN	DNN	RNN	LSTM
تعداد لایه مخفی	۲	۲	۱ + ۱	۲
تعداد نورون‌ها در هر لایه	۶۴ → ۳۲	۱۲۸ → ۶۴	۶۴ + ۳۲	۱۲۸ → ۶۴
ساختار ورودی	۱۵ ویژگی	۱۵ ویژگی	۱۵ ویژگی، ۱۰	۱۵ ویژگی
ساختار خروجی	۱ خروجی	۱ خروجی	۱ خروجی	۱ خروجی
تابع فعال‌سازی لایه‌های پنهان	ReLU	ReLU	tanh + ReLU	ReLU
تابع فعال‌سازی لایه خروجی	sigmoid	sigmoid	sigmoid	sigmoid
تابع هزینه	Binary Crossentropy	Binary Crossentropy	Binary Crossentropy	Binary Crossentropy
dropout	۰/۳	۰/۳	۰/۳	۰/۲
دوره	۱۰۰	۱۰۰	۱۰۰	۱۵۰
دسته	۳۲	۳۲	۳۲	۳۲

منبع: یافته‌های پژوهشگر

در مدل RNN ورودی به صورت دنباله‌ای تعریف شد. به این معنی که مدل برای پیش‌بینی روز یازدهم دنباله‌ای از ۱۰ روز متوالی دریافت می‌کند. در مدل LSTM تعداد دوره به‌منظور آموزش دقیق‌تر و کاهش پیوسته دوره به ۱۵۰ افزایش یافت.

جدول ۶- ساختار مدل شبکه عصبی مصنوعی برای متغیر الگوی معاملاتی

**Table 6- Artificial Neural Network Model Structure for the Variable of Trading Pattern**

	ANN	DNN	RNN	LSTM
تعداد لایه مخفی	۲	۳	۱	۱
تعداد نورون‌ها در هر لایه	۳۲ → ۱۶	۶۴ → ۳۲ → ۱۶	۳۲	۶۴ × ۲ لایه
ساختار ورودی	۸ ویژگی	۸ ویژگی	توالی تک‌گامی (۸ و ۱)	توالی تک‌گامی (۸ و ۱)
ساختار خروجی	۱ خروجی	۱ خروجی	۱ خروجی	۱ خروجی
تابع فعال‌سازی لایه‌های پنهان	ReLU	ReLU	tanh	tanh
تابع فعال‌سازی لایه خروجی	خطی بدون sigmoid	sigmoid	sigmoid	sigmoid
تابع هزینه	BCEWithLogitsLoss	BCELoss	BCELoss	BCELoss
dropout	ندارد	ندارد	ندارد	ندارد
دوره	۱۰۰	۱۰۰	۱۰۰	۱۰۰
دسته	ندارد	ندارد	Full_batch	Full_batch

منبع: یافته‌های پژوهشگر

## مدل سازی تاثیر متغیرهای کمی بر روی رفتار سرمایه گذاران.../عباسی کارچگان، مینویی و ممبینی

الگوهای معاملاتی اغلب دارای ویژگی‌های پنهان و وابستگی‌های زمانی پیچیده هستند که در طول بازه‌های زمانی کوتاه یا بلند بروز می‌کنند. به همین دلیل برای مدل‌سازی این متغیر از LSTM چندلایه استفاده شد زیرا ظرفیت بیشتری برای یادگیری وابستگی‌های زمانی عمیق‌تر بین داده‌ها دارد. از طرفی با توجه به اینکه طراحی مدل‌های بازگشتی پیچیده‌تر مانند LSTM چندلایه، نیاز به اعمال کنترل دقیق‌تر بر روی جریان داده‌ها، ساختار زمان‌مند ورودی‌ها و نحوه مدیریت حالت‌های پنهان دارد، در این متغیر برخلاف متغیرهای پیشین محیط PyTorch برای پیاده‌سازی مدل به کار گرفته شد. استفاده از محیط PyTorch به دلیل ارائه انعطاف بیشتر در تعریف مدل‌های سفارشی و مدیریت صریح‌تر لایه‌ها و توابع از نظر فنی مناسب‌تر ارزیابی شد.

در این متغیر، مدل ANN با ساختار ساده به کار گرفته شد، زیرا از تابع BCEWithLogitsLoss به عنوان تابع هزینه استفاده شد. این تابع به صورت داخلی شامل تابع فعال‌سازی sigmoid می‌باشد.

یافته‌ها:

### حجم خرید و فروش:

نتایج حاصل از بررسی عملکرد مدل‌های شبکه عصبی مصنوعی برای متغیر حجم خرید و فروش به شرح جدول ۷ می‌باشد:

جدول ۷- نتایج مدل‌سازی متغیر حجم خرید و فروش

Table 7- Modeling Results for the Variable of Trading Volume

مدل	MSE	MAE
ANN	۰/۰۱۸۸	۰/۱۰۲۱
DNN	۰/۰۱۸۷۸	۰/۱۰۲۳
RNN	۰/۰۰۴۸	۰/۰۳۹۸
LSTM	۰/۰۰۴۵	۰/۰۳۸۸

منبع: یافته‌های پژوهشگر

مقایسه عملکرد مدل‌ها نشان می‌دهد که مدل‌های مبتنی بر شبکه‌های بازگشتی (RNN و به‌ویژه LSTM) عملکرد بسیار بهتری نسبت به مدل‌های مبتنی بر شبکه‌های کاملاً متصل (ANN و DNN) داشته‌اند. کاهش قابل توجه در مقدار MSE و MAE در مدل‌های RNN و LSTM نشان می‌دهد که این مدل‌ها توانایی بالاتری در یادگیری وابستگی‌های زمانی داده‌های مربوط به «حجم خرید و فروش» دارند. در میان تمامی مدل‌ها، مدل LSTM با مقدار MSE برابر با ۰/۰۰۴۵ و MAE برابر با ۰/۰۳۸۸

### فصلنامه مهندسی مالی و مدیریت اوراق بهادار / دوره ۱۶ / شماره ۶۵ / زمستان ۱۴۰۴

کمترین میزان خطا را از خود نشان داد. این موضوع بیانگر آن است که مدل LSTM به دلیل داشتن حافظه بلندمدت قادر به درک بهتر روندهای زمانی و الگوهای نهفته در داده‌های حجمی بازار بوده و در نتیجه می‌تواند تصمیمات معاملاتی را دقیق‌تر پیش‌بینی کند. از سوی دیگر، عملکرد نسبتاً ضعیف‌تر مدل‌های ANN و DNN (با MSE در حدود ۰/۰۱۸۸ و MAE بالای ۰/۱۰) نشان می‌دهد که مدل‌های بدون مکانیزم حافظه زمانی در تحلیل متغیرهایی با ماهیت دنباله‌دار نظیر حجم خرید و فروش، دقت کمتری دارند؛ بنابراین، می‌توان نتیجه گرفت که در پیش‌بینی رفتارهای معاملاتی مرتبط با حجم، استفاده از مدل‌های بازگشتی مانند LSTM توصیه می‌شود.

#### تغییرات قیمت سهام:

نتایج حاصل از بررسی عملکرد مدل‌های شبکه عصبی مصنوعی برای متغیر تغییرات قیمت سهام به شرح جدول ۸ می‌باشد:

جدول ۸- نتایج مدل‌سازی متغیر تغییرات قیمت سهام

Table 8- Modeling Results for the Variable of Stock Price Changes

مدل	MSE	MAE
ANN	۰/۰۰۰۱۴۷	۰/۰۰۶
DNN	۰/۰۰۰۱۲۳۹	۰/۰۰۵۶
RNN	۰/۰۰۰۱۳۲۲	۰/۰۰۴۹
LSTM	۰/۰۰۰۱۲۰۲	۰/۰۰۵۲

منبع: یافته‌های پژوهشگر

بر اساس جدول فوق، می‌توان مشاهده کرد که تمام مدل‌ها عملکرد نسبتاً خوبی در پیش‌بینی الگوهای معاملاتی مبتنی بر تغییرات قیمت داشته‌اند، چراکه مقادیر MSE و MAE برای تمام مدل‌ها در سطح بسیار پایینی قرار دارند. در این میان، مدل LSTM با مقدار MSE برابر با ۰/۰۰۰۱۲۰۲ و MAE برابر با ۰/۰۰۵۲ پایین‌ترین سطح خطا را به خود اختصاص داده است که بیانگر دقت بالای این مدل در پیش‌بینی تغییرات قیمتی می‌باشد. مدل RNN نیز با MAE برابر با ۰/۰۰۴۹ کمترین میزان خطای مطلق را در میان تمام مدل‌ها داشته است که این مسئله حاکی از توانایی خوب این مدل در پیش‌بینی دقیق نتایج در اغلب نمونه‌ها می‌باشد. بر اساس نتایج مدل‌های ANN و DNN، تفاوت در عملکرد مدل‌ها چندان شدید نیست، اما همچنان مدل‌های RNN و LSTM با داشتن قابلیت تحلیل وابستگی‌های زمانی، نتایج بهتری ارائه داده‌اند. این امر نشان می‌دهد که تغییرات قیمت سهام نیز دارای

### مدل سازی تاثیر متغیرهای کمی بر روی رفتار سرمایه گذاران.../عباسی کارچگان، مینویی و ممبینی

الگوهای زمانی مشخصی است که توسط مدل های حافظه دار بهتر شناسایی می شوند. در نهایت، می توان نتیجه گرفت که هر چند همه مدل ها عملکرد مناسبی داشته اند، اما مدل های مبتنی بر حافظه (مخصوصاً LSTM) در استخراج و استفاده از ویژگی های زمانی تغییرات قیمت دقیق تر عمل کرده اند و گزینه های بهتری برای مدل سازی این متغیر محسوب می شوند.

#### بازده کل سرمایه گذاری:

نتایج حاصل از بررسی عملکرد مدل های شبکه عصبی مصنوعی برای متغیر بازده کل سرمایه گذاری به شرح جدول ۹ می باشد:

جدول ۹- نتایج مدل سازی متغیر بازده کل سرمایه گذاری

Table 9- Modeling Results for the Variable of Total Investment Return

مدل	MSE	MAE
ANN	۰/۰۰۰۲۰۵۳	۰/۰۰۶۱۹
DNN	۰/۰۰۱۱۷	۰/۰۲۹۶۵
RNN	۰/۰۰۰۱۷۲	۰/۰۰۶۰۷
LSTM	۰/۰۰۰۱۷۶	۰/۰۰۵۳

منبع: یافته های پژوهشگر

بر اساس جدول بالا، مدل DNN با داشتن بیشترین مقادیر MSE و MAE، ضعیف ترین عملکرد را در بین مدل ها داشته است. این ضعف می تواند ناشی از ناتوانی ساختار DNN در استخراج ویژگی های پیچیده زمانی در داده های مربوط به بازدهی کل سرمایه گذاری باشد. در مقابل، مدل های RNN و LSTM عملکرد بسیار بهتری داشته اند. مدل LSTM با MAE برابر ۰/۰۰۵۳ کمترین میزان خطای مطلق را ثبت کرده است که نشان دهنده دقت بالای آن در پیش بینی مقادیر واقعی است. همچنین، RNN با پایین ترین مقدار MSE برابر با ۰/۰۰۰۱۷۶، بهترین عملکرد را از نظر میانگین مربعات خطا داشته است. مدل ساده تر ANN نیز عملکرد نسبتاً مناسبی داشته و مقادیری در حد RNN و LSTM ارائه داده است که نشان دهنده تأثیر مناسب متغیر بازدهی کل در تفکیک پذیری داده ها حتی بدون در نظر گرفتن توالی زمانی است. در مجموع، نتایج نشان دادند که متغیر بازدهی کل سرمایه گذاری نقش مؤثری در پیش بینی تصمیمات معاملاتی دارد و مدل های مبتنی بر حافظه (LSTM و RNN) قادرند روابط پنهان در داده های زمانی این متغیر را با دقت بیشتری کشف کنند. به ویژه مدل LSTM، با ترکیب دقت بالا و خطای کم، گزینه ای ایده آل برای تحلیل این متغیر به شمار می رود.



تمایل به نگهداری یا فروش:

نتایج حاصل از بررسی عملکرد مدل‌های شبکه عصبی مصنوعی برای متغیر تمایل به نگهداری یا فروش به شرح جدول ۱۰ می‌باشد:

جدول ۱۰- نتایج مدل‌سازی متغیر تمایل به نگهداری یا فروش

Table 10- Modeling Results for the Variable of Holding or Selling Tendency

مدل	Accuracy
ANN	٪۷۵/۸
DNN	٪۷۵/۸
RNN	٪۷۵/۸
LSTM	٪۷۵/۸

منبع: یافته‌های پژوهشگر

در این متغیر هر چهار مدل به‌طور دقیقاً برابر به‌دقت ٪۷۵/۸ دست یافتند. با توجه به‌دقت یکسان در میان تمام مدل‌ها می‌توان گفت که الگوهای موجود در داده‌ها به‌صورت واضح و پایداری قابل تشخیص بودند. به عبارتی داده‌ها از ساختار منظم و مشخصی برخوردار بوده‌اند که حتی مدل‌های کم‌عمق نیز توانسته‌اند به‌خوبی آن‌ها را بیاموزند. از طرفی با توجه به اینکه مدل‌های RNN و LSTM برای داده‌های متوالی و دارای وابستگی زمانی طراحی شده‌اند، عملکرد یکسان آن‌ها با مدل‌های ANN و DNN نشان می‌دهد که احتمالاً متغیر تمایل به نگهداری یا فروش از ماهیت زمانی پیچیده‌ای برخوردار نیست یا دست‌کم در طراحی داده و ورودی‌ها از ساختار ترتیبی استفاده نشده است. دستیابی هم‌زمان تمام مدل‌ها به دقتی حدود ٪۷۵.۸ می‌تواند حاکی از آن باشد که داده‌های فعلی به یک سقف یادگیری رسیده باشند. این موضوع بدان معناست که بدون انجام بهبودهایی نظیر مهندسی ویژگی، انتخاب ویژگی یا استفاده از الگوریتم‌های ترکیبی مانند XGBoost یا Random Forest، افزایش دقت پیش‌بینی دشوار خواهد بود.

تصمیمات سرمایه‌گذاری (ورود یا خروج از بازار):

نتایج حاصل از بررسی عملکرد مدل‌های شبکه عصبی مصنوعی برای متغیر تصمیمات سرمایه‌گذاری به شرح جدول ۱۱ می‌باشد:

جدول ۱۱- نتایج مدل سازی متغیر تصمیمات سرمایه گذاری

Table 11- Modeling Results for the Variable of Investment Decisions

مدل	Accuracy
ANN	٪۷۷
DNN	٪۸۶
RNN	٪۵۱
LSTM	٪۷۳/۹۵

منبع: یافته‌های پژوهشگر

نتایج فوق نشان می‌دهد که مدل DNN بهترین عملکرد را در پیش‌بینی تصمیمات ورود یا خروج از بازار داشته است. این مدل توانسته است با دقت ۸۶ درصد، ساختارهای غیرخطی موجود در داده‌ها را به خوبی یاد بگیرد و تصمیم‌گیری درستی در مورد طبقه‌بندی انجام دهد. در مقابل، عملکرد مدل RNN با دقت ۵۱ درصد بسیار ضعیف بوده و تقریباً در حد یک پیش‌بینی تصادفی عمل کرده است. این ضعف ممکن است به دلیل نامناسب بودن ساختار ساده RNN برای یادگیری وابستگی‌های پیچیده در داده‌های باینری باشد. مدل ANN با دقت ۷۷ درصد و مدل LSTM با دقت ۷۳/۹۵ درصد عملکرد نسبتاً خوبی داشته‌اند، اگرچه دقت آن‌ها نسبت به DNN پایین‌تر است. مدل LSTM با وجود ساختار پیشرفته‌تر در مدل‌سازی وابستگی‌های زمانی، نتوانسته به اندازه DNN در این متغیر خاص موفق عمل کند که ممکن است به دلیل عدم وجود توالی قوی یا ساختار زمانی معنادار در متغیر تصمیم ورود یا خروج باشد. در مجموع، این نتایج نشان می‌دهد که برای متغیرهای تصمیم‌گیری باینری مانند ورود یا خروج از بازار، مدل‌های عمیق ولی غیر زمانی مانند DNN، نسبت به مدل‌های ترتیبی مانند RNN و LSTM، عملکرد دقیق‌تری از خود نشان می‌دهند؛ بنابراین، استفاده از مدل DNN برای تحلیل این نوع متغیر توصیه می‌شود.

#### الگوهای معاملاتی (بلندمدت یا کوتاه‌مدت):

نتایج حاصل از بررسی عملکرد مدل‌های شبکه عصبی مصنوعی برای متغیر الگوهای معاملاتی به شرح جدول ۱۲ می‌باشد:

جدول ۱۲- نتایج مدل‌سازی متغیر الگوهای معاملاتی

Table 12- Modeling Results for the Variable of Trading Patterns

مدل	Accuracy
ANN	٪۹۰/۶۵
DNN	٪۹۷/۳۳
RNN	٪۹۱/۴۱
LSTM	٪۹۰/۶۵

منبع: یافته‌های پژوهشگر

نتایج حاصل نشان می‌دهد که مدل DNN با دقت بسیار بالای ۹۷/۳۳ درصد عملکرد چشمگیری در تشخیص الگوهای معاملاتی داشته است. این موضوع بیانگر توانایی بالای این مدل در یادگیری ویژگی‌های پیچیده و غیرخطی موجود در داده‌های مربوط به الگوهای معامله است. در رتبه‌های بعدی، مدل RNN با دقت ۹۱/۴۱ درصد، مدل ANN و مدل LSTM هر دو با دقت ۹۰/۶۵ درصد عملکرد مناسبی از خود نشان داده‌اند. این نزدیکی عملکرد بین مدل‌های ANN، LSTM و RNN حاکی از این است که الگوهای معاملاتی در این داده‌ها از ویژگی‌های قابل پیش‌بینی مشخصی برخوردار بوده‌اند که توسط مدل‌های مختلف به خوبی قابل شناسایی بوده‌اند. با این حال، برتری واضح مدل DNN نسبت به سایر مدل‌ها قابل توجه است. به نظر می‌رسد که ساختار عمیق و چندلایه این مدل به آن کمک کرده تا روابط پیچیده‌تری را میان ویژگی‌ها و الگوهای معاملاتی استخراج کند. در مجموع، می‌توان نتیجه گرفت که برای پیش‌بینی صحیح و دقیق الگوهای معاملاتی در بازار، مدل‌های شبکه عصبی عمیق مانند DNN بهترین گزینه هستند و دقت بالایی را ارائه می‌دهند.

بحث و نتیجه‌گیری:

این مطالعه با هدف مدل‌سازی و پیش‌بینی شش متغیر کلیدی تأثیرگذار بر رفتار سرمایه‌گذاران در بازار سرمایه با استفاده از رویکردهای متنوع هوش مصنوعی انجام گرفت. برای این منظور، چهار مدل پرکاربرد شامل ANN، DNN، RNN و LSTM بر روی هر متغیر پیاده‌سازی شدند و عملکرد آن‌ها با استفاده از معیارهای دقت، MAE و MSE مورد مقایسه قرار گرفت. در این مطالعه، متغیرها به دو دسته متغیرهای پیوسته و متغیر باینری تقسیم شدند.

در متغیرهای پیوسته شامل حجم خرید و فروش، تغییرات قیمت سهام و بازدهی کل سرمایه‌گذاری، مدل‌های سری زمانی (RNN و LSTM) عملکرد بهتری نسبت به مدل‌های معمولی (ANN و DNN)،

## مدل سازی تأثیر متغیرهای کمی بر روی رفتار سرمایه گذاران.../عباسی کارچگان، مینویی و ممبینی

داشتند. به طور خاص، در پیش بینی حجم خرید و فروش، مدل LSTM با  $MSE = 0/0045$  و  $MAE = 0/0388$  بهترین نتایج را ارائه کرد. همچنین در پیش بینی بازدهی سرمایه، مدل RNN با  $MAE = 0/0067$  و  $MSE = 0/00172$  کمترین خطا را داشت. این موضوع بیانگر آن است که استفاده از مدل های با حافظه بلندمدت و وابستگی های زمانی، در بهبود پیش بینی متغیرهای مالی پیوسته بسیار مؤثر است؛ این موضوع در مطالعات متعددی مورد تأکید قرار گرفته است. نبی پور و همکاران در مطالعه خود به مقایسه ۹ مدل یادگیری ماشین به منظور کاهش قابل توجه خطای پیش بینی در بورس اوراق بهادار تهران پرداختند. بر اساس نتایج این مطالعه روش های RNN و LSTM با تفاوت قابل توجهی به نسبت سایر روش ها بیشترین میزان دقت را در پیش بینی داشتند (نبی پور و همکاران ۲۰۲۰). ویکراما (۲۰۱۷)، نیکو (۲۰۱۹)، نبی پور (۲۰۲۰) و سهرابی (۲۰۲۳) نیز در مطالعه خود، به نتایج مشابهی دست یافتند.

در متغیرهای باینری شامل تمایل به نگهداری یا فروش، تصمیمات سرمایه گذاری و الگوهای معاملاتی، نتایج متفاوت تری به دست آمد. برای متغیر چهارم، یعنی «تمایل به نگهداری یا فروش»، هر چهار مدل عملکرد نسبتاً یکسانی داشتند (۷۵/۸ درصد) که ممکن است نشان دهنده ضعف نسبی ویژگی های ورودی در تمایز دادن این تصمیم باشد؛ اما در متغیر پنجم (ورود یا خروج از بازار)، مدل DNN با دقت ۸۶ درصد عملکرد به مراتب بهتری نسبت به سایر مدل ها، به ویژه مدل RNN (با دقت ۵۱ درصد) داشت. این نتیجه نشان می دهد که برای برخی متغیرهای باینری، استفاده از مدل های عمیق اما غیرترتیبی (مثل DNN) ممکن است مؤثرتر از مدل های مبتنی بر توالی باشد، به ویژه زمانی که داده های مورد استفاده فاقد ترتیب زمانی قوی یا وابستگی دنباله ای هستند. در نهایت، متغیر ششم (الگوهای معاملاتی: بلندمدت یا کوتاه مدت) نیز یک متغیر باینری بود، اما برخلاف متغیر چهارم، مدل DNN با دقت بسیار بالا (۹۷/۳۳ درصد) بهترین عملکرد را نشان داد. این موضوع می تواند نشان دهنده قابلیت بالای مدل DNN در استخراج الگوهای پیچیده غیردیجیتالی و چندبعدی باشد. همچنین تفاوت محیط پیاده سازی (PyTorch) در این متغیر به دلیل نیاز به کنترل بیشتر روی معماری مدل و پیاده سازی دقیق تر لایه های سفارشی بوده است.

نتایج نشان داد که مدل های ساده تر (ANN) تنها در متغیرهایی با ساختار ساده یا حجم داده کمتر عملکرد قابل قبولی داشتند. در مقابل، مدل های عمیق تر (DNN) در متغیرهای باینری پیچیده و مدل های بازگشتی (RNN و LSTM) در متغیرهای پیوسته عملکرد بهتری داشتند. در مقایسه با سایر مطالعات مشابه انجام شده در حوزه پیش بینی بازار، این پژوهش از این جهت نوآوری دارد که شش متغیر

## فصلنامه مهندسی مالی و مدیریت اوراق بهادار / دوره ۱۶ / شماره ۶۵ / زمستان ۱۴۰۴

رفتاری مستقل را به صورت جداگانه و در چارچوب‌های مختلف مدل‌سازی کرده است، در حالی که بسیاری از مطالعات پیشین تنها روی یک یا دو متغیر مانند قیمت یا بازده تمرکز داشته‌اند. به طور کلی، مشخص شد که هیچ مدل واحدی برای همه متغیرها بهینه نیست، بلکه انتخاب مدل باید بر اساس ماهیت متغیر (پیوسته یا باینری)، ساختار زمانی داده‌ها و ویژگی‌های رفتاری سرمایه‌گذاران تنظیم شود.

در این مطالعه، تمرکز اصلی بر روی متغیرهای کمی مرتبط با رفتار سرمایه‌گذاران بوده است؛ متغیرهایی که امکان کدگذاری عددی و مدل‌سازی مستقیم با روش‌های یادگیری ماشین و یادگیری عمیق را فراهم می‌کردند. این رویکرد به دلیل دسترسی پذیری بهتر داده‌های کمی و سهولت پردازش آن‌ها اتخاذ شد. با این حال، نمی‌توان از نقش کلیدی متغیرهای کیفی نظیر احساسات سرمایه‌گذار، اعتماد به بازار، تجربه شخصی، یا ادراک از ریسک چشم‌پوشی کرد؛ عواملی که در تصمیم‌گیری‌های واقعی سرمایه‌گذاری نقشی غیرقابل‌انکار دارند. بر همین اساس، پیشنهاد می‌شود که در مطالعات آتی ترکیبی از متغیرهای کمی و کیفی در مدل‌سازی رفتار سرمایه‌گذاران مورد استفاده قرار گیرد تا نتایج دقیق‌تری حاصل شود.

منابع

- 1) Apple, Gerald ., (1985). The moving average convergence-divergence trading method: advanced version: Scientific Investment Systems.##
- 2) Atsalakis, George S ., Valavanis., (2009). Surveying stock market forecasting techniques–Part II: Soft computing methods. Expert Systems with applications. 36(3): 5932-5941, <https://doi.org/10.1016/j.eswa.2008.07.006> ##
- 3) Barber, Barad.M., Odean., (2013). The behavior of individual investors. Handbook of the Economics of Finance, 2 Pages . 1533-1570-  
<https://doi.org/10.1016/B978-0-44-459406-8.00022-6> ##
- 4) Doulo, Maryam., Heydari., Taktam, (2017). Stock index prediction using a combination of artificial neural networks and meta-heuristic models of harmony search and genetic algorithm. Financial economics, 11(40): 1-24. <https://civilica.com/doc/1820899> ##
- 5) Faeson, Wayne E .,Harvey ., (1991). The variation of economic risk premiums. Journal of political economy. 99(2): 415-385. <https://doi.org/10.1086/261755> ##
- 6) Fama, Eugene F., (1970). Efficient capital markets: A Review of Theory and Empirical Work. Journal of finance. 25(2): 417-383. <https://doi.org/10.2307/2325486>##
- 7) Fischer, Thomas., Krauss., (2018). Deep learning with long short-term memory networks for financial market predictions. European journal of operational research. 2 (270): 654-669. <https://doi.org/10.1016/j.ejor.2017.11.054> ##
- 8) Gu, Shihao ., Kelly., Xiu., (2020). Empirical asset pricing via machine learning. The Review of Financial Studies. 33(5): 2223-2273. <https://doi.org/10.1093/rfs/hhaa009> ##
- 9) Heaton, J. B., Polson, N. G., & Witte, J. H., (2016). Deep learning in finance. arXiv preprint arXiv: 1602.06561. <https://doi.org/10.48550/arXiv.1602.06561> ##
- 10) Hochreiter, Sepp & Schmidhuber, Jürgen (1997). Long short-term memory. Neural Computation. 9(8): 1735-1780. 10.1162/neco.1997.9.8.1735 ##
- 11) Leung, Mark T., Daouk., Chen., (2000). Forecasting stock indices: a comparison of classification and level estimation models. International Journal of forecasting, 2 (16): 90-173. [https://doi.org/10.1016/S0169-2070\(99\)00048-5](https://doi.org/10.1016/S0169-2070(99)00048-5) ##
- 12) Milana, Carlo., Ashta., (2021). Artificial intelligence techniques in finance and financial markets: a survey of the literature. Strategic Change, 3(30): 189-209. <https://doi.org/10.1002/jsc.2403> ##
- 13) Malkiel, Burton G ., (2003). The efficient market hypothesis and its critics. Journal of economic perspectives. 17 (1):82-95. DOI: 10.1257/089533003321164958##

- 14) Nabipour, Mojtaba ., Nayyeri., Jabani., Mosavi ., (2020). Predicting stock market trends using machine learning and deep learning algorithms via continuous and binary data; a comparative analysis. Ieee Access : 150199 – 150212. DOI: 10.1109/ACCESS.2020.3015966##
- 15) Nabipour, Morteza., Nayyeri., Jabani., Mosavi., Salwana., (2020). Deep Learning for Stock Market Prediction. Entropy, 22(8): 840. <https://doi.org/10.3390/e22080840> ##
- 16) Nikou, Mahla., Mansourfar, Gholamreza & Bagherzadeh, Jamshid, (2019). Stock price prediction using DEEP learning algorithm and its comparison with machine learning algorithms. Intelligent Systems in Accounting, Finance and Management, 26(4): 164-174. <https://doi.org/10.1002/isaf.1459> ##
- 17) Sezer, Omer Berat., Gudelek., Ozbayoglu., (2020). Financial time series forecasting with deep learning : A systematic literature review: 2005–2019. Applied soft computing. 90, 106181. <https://doi.org/10.1016/j.asoc.2020.106181> ##
- 18) Sinai, Hassanali., Mortazavi., Saeedollah & Teymouri Asl., Yaser, (2005). Predicting Tehran Stock Exchange Index Using Artificial Neural Networks. Accounting and auditing reviews, 41(12): 59-83. 20.1001.1.26458020.1384.12.3.5.6 ##
- 19) Sohrabi, Maryam., Mirbargkar., Seyyed Mozaffar, Chirani., Ebrahim & Kheradyar., Sina (2023). Comparison of different machine learning models in stock market index prediction. Financial engineering and securities management. 56(14): 19-36. <https://sanad.iau.ir/Journal/fej/Article/1078642> ##
- 20) Tehrani, Reza., Rahnama Felavarjani., Roohollah (2014). Predicting the Investment Behavior of Tehran Stock Exchange Companies Using Neural Networks. Asset Management and Financing. 2 (3): 63-80. 20.1001.1.23831170.1393.2.3.6.3 ##
- 21) wickrama, Samara ., Fernando., editors., (2017). A recurrent neural network approach in predicting daily stock prices an application to the Sri Lankan stock market. 2017 IEEE International Conference on Industrial and Information Systems (ICIIS). DOI: 10.1109/ICIINFS.2017.8300345 ##
- 22) Wilder, Welles ., (1978). New concepts in technical trading systems: Greensboro, NC.

- 1 Gross Domestic Product (GDP)
- 2 Artificial neural networks (ANN)
- 3 Deep Learning
- 4 <https://www.tsetmc.com/>
- 5 <https://www.tse.ir>
- 6 <https://rdis.seo.ir/fa>
- 7 <https://cbi.ir/>
- 8 <https://amar.org.ir>
- 9 <https://www.tgju.org/>
- 10 Moving average (MA)
- 11 relative strength index (RSI)
- 12 MACD
- 13 Average True Range(ATR)
- 14 On-Balance volume (OBV)
- 15 Wilder, J. Welles
- 16 Hyperparameter Tuning



Modeling the Impact of Quantitative Variables on Individual Investor Behavior Using Artificial Neural Networks in the Tehran Stock Exchange

Mehran Abbasi karchegan<sup>1</sup>

Receipt: 08/07/2025 Acceptance: 23/08/2025

Mehrzad Minouei<sup>2</sup>

Hossein Mombeini<sup>3</sup>

**Abstract**

Today, individual investors play a key role in the dynamics of financial markets, and their decisions significantly affect price volatility, market liquidity, and overall efficiency. The behavior of this group is typically influenced by various factors, including macroeconomic indicators, market conditions, and behavioral finance components. A proper understanding of these behaviors can contribute to the enhancement of trading strategies and the development of more accurate predictive models. Accordingly, the present study aims to model the impact of quantitative variables on the behavior of individual investors and to forecast the behavior of retail investors in Iran's capital market using artificial and deep neural networks. In this regard, six dependent variables were selected: buy and sell volumes, stock price fluctuations, total investment returns, the tendency to hold or sell, market entry or exit decisions, and trading patterns (long-term or short-term). These were modeled using four learning approaches—ANN, DNN, RNN, and LSTM—trained on real market data, including market information, technical indicators, and economic indices. The results revealed that recurrent models, especially LSTM, achieved higher accuracy in predicting time-series and continuous variables compared to other models. Furthermore, in binary (classified) variables, the DNN model outperformed others in certain cases, such as investment decisions and trading patterns. However, the findings also suggest that the mere use of more complex architectures does not necessarily lead to improved performance. As this study focused on quantitative variables, it is recommended that future research incorporate qualitative factors into the modeling process to gain a more comprehensive understanding of investor behavior.

**Keywords:**

Forecasting, Individual Investors, ANN, DNN, RNN, LSTM, Artificial Neural Network

1-Department of Financial Management, Central Tehran Branch, Islamic Azad University, Tehran, Iran. m.abbasikarchegan@iau.ac.ir

2-Department of Financial Management, Central Tehran Branch, Islamic Azad University, Tehran, Iran. (Corresponding Author) 2200077025@iau.ac.ir

3-Department of Financial Management, Central Tehran Branch, Islamic Azad University, Tehran, Iran. hos.mombeini@iauctb.ac.ir

## Extended abstract

### Intoduction

Stock market investment plays a fundamental role in the dynamism of the economy, and individual investor behavior is a key determinant of price volatility, liquidity, and market efficiency. This behavior is shaped by macroeconomic conditions, market variables, and psychological factors, and its proper understanding can enhance trading strategies and improve predictive models. In recent years, artificial intelligence (AI), with its capability to identify complex patterns and nonlinear relationships, has emerged as a robust alternative to traditional econometric models. Neural networks, by learning hidden patterns in financial data, enable more accurate forecasting and simultaneous analysis of both quantitative and qualitative information.

In the Iranian capital market, characterized by high complexity and volatility, AI applications have become particularly valuable. Factors such as interest rates, inflation, exchange rates, GDP, and stock market indices influence investor decision-making. This study employs Artificial Neural Networks (ANN), Deep Neural Networks (DNN), Recurrent Neural Networks (RNN), and Long Short-Term Memory (LSTM) models to identify and predict investor behavior in the Tehran Stock Exchange. Selecting the appropriate model is critical: RNN and LSTM demonstrate superior performance in time-series analysis and capturing long-term dependencies, whereas ANN and DNN are more effective in extracting complex inter-variable features.

Individual investor behavior significantly affects market volatility and liquidity, and is influenced by both economic and psychological factors. Modeling such behavior using quantitative data, including macroeconomic indicators and trading records, enables more accurate market trend forecasting. The application of artificial neural networks and deep learning facilitates the identification of complex and nonlinear patterns in financial data, outperforming traditional methods. The findings of this study provide a deeper understanding of investor behavior and offer practical insights for market participants, analysts, and policymakers.

### Methods

In this study, variables were categorized into independent and dependent groups, and data were collected over the period 2014–2024 (Iranian calendar 1393–1403). Independent variables included market information (trading volume, closing price, highest and lowest prices, and the overall index), economic indicators (GDP, exchange rate, gold price, interest rate, and inflation), and stock market technical indicators (moving averages, RSI, MACD, ATR, and On-Balance Volume).

Annual and daily economic data were completed using statistical methods, and technical indicators were calculated based on established financial standards.

Dependent variables comprised trading volume, returns, stock price changes, investment decisions, holding or selling tendencies, and short- and long-term trading patterns. To analyze investor behavior, Artificial Neural Networks (ANN), Deep Neural Networks (DNN), Recurrent Neural Networks (RNN), and Long Short-Term Memory (LSTM) models were employed. The data were split into training, validation, and prediction sets, and network architectures were optimized by adjusting the number of neurons, dropout rates, and activation functions according to the nature of the data. Model performance was evaluated using Mean Squared Error (MSE), Mean Absolute Error (MAE), and Accuracy. Recurrent models were particularly applied for predicting investor decisions and multi-layer trading patterns due to their capability to capture time-series dependencies and complex temporal relationships. All modeling and simulations were conducted using Python with the PyTorch framework, ensuring greater flexibility and accuracy in model design.

### **Results**

The findings indicate that the type of neural network model plays a critical role in the accuracy of stock market variable predictions. For the “trading volume” variable, recurrent models, particularly LSTM, achieved the lowest MAE and MSE, effectively capturing temporal dependencies in the data and outperforming ANN and DNN models. This highlights the importance of long-term memory in analyzing market volume data.

For the “stock price changes” variable, all models performed reasonably well; however, LSTM and RNN models, due to their ability to capture temporal dependencies, provided higher accuracy in extracting price patterns. These results suggest the presence of distinct temporal patterns in price fluctuations that are better identified by memory-based models. Regarding “total investment returns,” the DNN model exhibited the weakest performance, while LSTM and RNN accurately predicted hidden relationships with minimal error. ANN also performed adequately, indicating the informative value of return variables even without temporal sequence analysis. For the “holding or selling tendency” variable, all models achieved similar accuracy (~75.8%), reflecting a well-structured and easily recognizable pattern without complex temporal dependencies. In predicting “investment decisions (entry or exit),” DNN achieved the highest accuracy (86%), whereas RNN showed weaker performance. This suggests that for binary, non-sequential variables, deep non-recurrent models are more suitable. For “trading patterns” prediction, DNN significantly outperformed other models with an

accuracy of 97.33%, demonstrating its capability to identify complex nonlinear relationships among features and trading patterns. Overall, the results indicate that memory-based models excel in predicting variables with temporal patterns, while deep non-sequential models perform better for structured binary and nonlinear variables.

### **Discussion and Conclusion**

This study aimed to model and predict six key investor behavior variables in the capital market using four artificial intelligence models: ANN, DNN, RNN, and LSTM. The results demonstrated that for continuous variables such as trading volume, price changes, and investment returns, recurrent models (RNN and LSTM) performed better due to their ability to capture temporal dependencies; specifically, LSTM showed the lowest error in predicting trading volume, while RNN excelled in forecasting investment returns.

Conversely, for binary variables such as holding or selling decisions and trading patterns, the DNN model often outperformed others, highlighting its capability to extract complex non-temporal patterns, whereas ANN exhibited limited performance. The findings also indicate that no single model is optimal for all variables, and model selection should consider variable type, temporal structure of the data, and specific behavioral characteristics of investors.

This research is innovative in simultaneously examining six independent variables and emphasizing the differential performance of models based on variable characteristics. Despite focusing on quantitative variables, future studies are recommended to incorporate a combination of quantitative and qualitative data, such as investor sentiment and risk perception, to enhance the accuracy and comprehensiveness of predictions.