

Stock Manipulation Detection using artificial intelligence models in the Iranian capital market

Hamed Hamedinia

Ph.D. in Financial Engineering, Department of Finance, Faculty of Management,
University of Tehran, Tehran, Iran. (Corresponding Author)

hamedinia.hamed@ut.ac.ir

Reza Raei

Ph.D. in Financial Management, Professor, Department of Finance,
Faculty of Management, University of Tehran, Tehran, Iran.

raei@ut.ac.ir

Ali Amirshahi

Ph.D. Candidate in Financial Engineering, Department of Finance and Banking, Faculty
of Management and Accounting, Allameh Tabataba'i University, Tehran, Iran.

ali.amirshahi.isu.ac@gmail.com

Stock manipulation poses a major challenge in capital markets, threatening efficiency and investor confidence. This study aims to identify price manipulation in stocks listed on the Iranian capital market using artificial intelligence models. The dataset includes daily information for 69 stocks across 19 industries from 2016 to 2020. Due to the lack of transparent identification of manipulated stocks in Iran, synthetic data were generated by injecting random patterns into non-suspicious stocks, supported by expert judgment. Key variables examined include daily returns, trading volume, and the average buy and sell activities of individual and institutional investors. The research adopts an applied, empirical, and descriptive-analytical approach, utilizing AI models such as logistic regression, decision trees, and multilayer neural networks. Findings show that manipulation periods are associated with significant increases in returns, trading volume, and investor activity. Among the models, the decision tree achieved the best performance, with 68% accuracy based on the F2-measure. It also identified the most influential indicators of manipulation, notably increased trading volume on and before the manipulation day, along with abnormal returns. Finally, the study provides practical, step-by-step guidelines to help regulators detect manipulated stocks more effectively.

JEL Classification: G14, C45, G17.

Keywords: Stock Manipulation, Deep Learning, Artificial Intelligence (AI).

شناسایی دستکاری سهام با استفاده از مدل‌های هوش مصنوعی در بازار سرمایه ایران

حامد حامدی‌نیا

دکتری مهندسی مالی، گروه مالی، دانشکدگان مدیریت، دانشگاه تهران، تهران، ایران (نویسنده مسئول).
hamedinia.hamed@ut.ac.ir

رضا راعی

دکتری مدیریت مالی، استاد، گروه مالی، دانشکدگان مدیریت، دانشگاه تهران، تهران، ایران.
raei@ut.ac.ir

علی امیرشاهی

دانشجوی دکتری مهندسی مالی، گروه مالی و بانکداری، دانشکده مدیریت و حسابداری،
دانشگاه علامه طباطبائی (ره)، تهران، ایران.
ali.amirshahi.isu.ac@gmail.com

دستکاری سهام از مهم‌ترین چالش‌های بازار سرمایه به‌شمار می‌رود که می‌تواند کارایی بازار و اعتماد سرمایه‌گذاران را تضعیف کند. این پژوهش با هدف شناسایی دستکاری قیمتی در سهام پذیرفته‌شده در بازار سرمایه ایران و با استفاده از مدل‌های هوش مصنوعی انجام شده است. جامعه آماری شامل داده‌های روزانه ۶۹ سهم از ۱۹ صنعت در بازه زمانی ۱۳۹۵ تا ۱۳۹۹ است. با توجه به نبود شفافیت در معرفی سهام دستکاری‌شده در ایران، برای آموزش مدل‌ها، داده‌های مصنوعی از طریق تزریق الگوهای تصادفی به سهام غیرمشکوک و با اتکا به نظر خبرگان تولید شد. متغیرهای مورد بررسی شامل بازده روزانه، حجم معاملات، و میانگین خرید و فروش سرمایه‌گذاران حقیقی و حقوقی است. روش تحقیق از نوع کاربردی-تجربی با رویکرد توصیفی-تحلیلی بوده و تحلیل داده‌ها با استفاده از مدل‌های رگرسیون لجستیک، درخت تصمیم و شبکه عصبی چندلایه انجام شده است. نتایج نشان می‌دهد در دوره‌های دستکاری، بازده و حجم معاملات به‌طور معناداری افزایش می‌یابد و فعالیت معاملاتی سرمایه‌گذاران نیز رشد قابل توجهی دارد. در میان مدل‌ها، درخت تصمیم با دقت ۶۸ درصد (بر اساس معیار F2) بهترین عملکرد را داشته است. همچنین، افزایش حجم معاملات در روز دستکاری و روز قبل، همراه با بازده غیرعادی، مهم‌ترین شاخص‌های شناسایی دستکاری هستند. در نهایت، راهکارهای عملی برای نهاد ناظر ارائه شده است.

طبقه‌بندی JEL: G14, C45, G17

واژگان کلیدی: دستکاری سهام، یادگیری عمیق، هوش مصنوعی.

۱. مقدمه

بازار سرمایه مکانی برای خرید و فروش اوراق بهادار بوده که تغییر مالکیت سهام پذیرش شده در این بازار لازم است با قیمت منصفانه صورت پذیرد. اگر معاملات به دور از تقلب و با رعایت قوانین انجام گیرد مشکلی پیش نخواهد آمد، اما متأسفانه بازیگرانی وجود دارند که در تلاش هستند با انجام اقدامات فریبکارانه، سایر بازیگران و معامله‌گران را به گمراهی کشیده و از این محل کسب در آمد نمایند. به طور کلی اقداماتی که منجر به گمراهی فعالان بازار گردد، دستکاری بازار نامیده شده و در اکثر موارد اقدامی غیرقانونی بوده، اما کشف آن به شدت دشوار است (لینگارن^۱ و همکاران، ۲۰۱۸).

سهولت در دستکاری قیمت و عدم توانایی در کشف آن، موضوعی است که می‌تواند به کارایی بازار صدمات جبران ناپذیری وارد نماید. از همین رو قانون‌گذاران اوراق بهادار عموماً از دستکاری بازار پیشگیری می‌کنند؛ چرا که دستکاری، به عدم توازن قیمت اوراق بهادار منجر شده و فرایند کشف قیمت را تحت تأثیر قرار می‌دهد. در بازارهای نوظهور، سهام برخی شرکت‌ها که عمق کمتری دارند، برای دستکاری قیمت مستعدتر اند (ندیری و همکاران، ۲۰۱۸).

اگرچه شناسایی دستکاری بازار برای بورس‌ها حائز اهمیت است، مطالعات تجربی اندکی در زمینه شناسایی آن انجام شده است؛ چرا که در بسیاری از موارد اثبات اینکه سهام دستکاری شده یا خیر، به سختی امکان‌پذیر است. در کشور ایران سهام دستکاری شده

1. Leangarun

توسط نهاد ناظر افشا نمی‌گردد و در صورتی که تلاش برای شناسایی دستکاری بازار صورت نپذیرد، می‌تواند صدمات جبران‌ناپذیری به بازار سرمایه وارد شود.

اگرچه نهاد ناظر همواره در تلاش است تا راه‌های دستکاری سهام را شناسایی و اقدام به حذف آن نماید، متأسفانه شناسایی آن به سادگی امکان‌پذیر نمی‌باشد. کشف دستکاری با ایجاد برنامه‌های کامپیوتری جدید و الگوریتم‌های معاملاتی پیچیده، سخت‌تر از قبل شده است. همچنین با گسترش بازارهای مالی و افزایش تعداد شرکت‌های بورسی و حجم معاملات، نظارت بر اقدامات متقلبانه و دستکاری سهام توسط صرفاً نیروی انسانی تقریباً ناممکن است. از این رو نهاد ناظر به برنامه‌های کامپیوتری سریعی نیاز دارد تا معاملات و روند قیمتی سهام را تحت نظر قرار داده و هشدارهای لازم را در زمان دستکاری ارائه نماید (لینگارن و همکاران، ۲۰۱۸).

تشخیص سریع و مناسب دستکاری قیمتی کمک می‌کند تا بازار سرمایه سلامت و کارایی خود را حفظ کرده و با جلوگیری از رفتار زیان‌بار سودجویان، به سهامداران خرد کمک شود که در بازی ناعادلانه گرفتار نشوند. برای این منظور سخت‌گیری‌های بیش از حد متعارف جهت شناسایی دستکاری سهام و ایجاد رویه‌های بازدارنده گسترده، می‌تواند منجر به دلسردی فعالان بازار باشد. بنابراین باید با استفاده از ابزارهای جدید مانند هوش مصنوعی و یادگیری عمیق در تلاش بود تا تشخیص سهام در حال دستکاری با سرعت زیاد و بدون تأخیر انجام شده و اقدامات جلوگیری‌کننده صورت پذیرد. لذا با توجه به اهمیت شناسایی دستکاری سهام و لزوم تشخیص صحیح و به موقع آن و فعال کردن الگوریتم‌های پیشگیرانه، در این پژوهش به تشخیص دستکاری قیمتی سهام با استفاده از روش‌های

داده‌کاوی می‌پردازیم. بنابر این هدف غایی این پژوهش ایجاد مدلی برای شناسایی دستکاری سهام در بازار سرمایه ایران بوده و الگوریتمی طراحی می‌شود که به وسیله آن از یک طرف از اقدامات متقلبانه و انحراف قیمتی سهام جلوگیری شده و از طرف دیگر با بستن طولانی مدت نماد سهم در بازار سرمایه، فعالان بازار دلسرد نگردند.

در ادامه پژوهش به ارائه مبانی نظری، پیشینه و روش‌شناسی پژوهش، ارائه مدل و در نهایت جمع‌بندی می‌پردازیم.

۲. مبانی نظری

واژه دستکاری بازار، دامنه گسترده‌ای از انواع مختلف استراتژی دستکاری را شامل می‌شود. طبقه‌بندی ارائه شده در ارتباط بین استراتژی‌های مختلف دستکاری را در یک نمای کلی نمایش می‌دهد همان‌طور که مشخص است در سطح اول، دستکاری به چهار دسته کلی تقسیم‌بندی می‌شود: معامله سریع سهام^۱، قرارداد/ شاخص محور^۲، اغواکننده/ سفارش محور^۳ و تکنیک‌های قدرت بازار^۴ (پوتینس، ۲۰۲۰).

در دسته اول یا معامله سریع سهام، دستکاری‌کننده ابتدا موقعیت خرید/ فروش در سهم گرفته و سپس با ترغیب دیگران نسبت به افزایش/ کاهش قیمت سهام اقدام کرده و در نهایت موقعیت معکوس در قیمت‌های بهتر می‌گیرد. اگرچه این نوع دستکاری اکثراً در بازار سرمایه اتفاق می‌افتد اما در عمل می‌تواند در هر بازار مالی دیگر نیز به وقوع پیوندد. اگر دستکاری‌کننده

-
1. Runs
 2. Contract-based / Benchmark Manipulation
 3. Spoofing / Order-based
 4. Market Power Techniques

ابتدا موقعیت خرید گرفته و باعث افزایش قیمت سهم شده، سپس اقدام به فروش ناگهانی در قیمت‌های بالاتر کند، افزایش قیمت و خالی کردن^۱ اتفاق می‌افتد.

در صورتی که اگر دستکاری کننده ابتدا به صورت ناگهانی فروشنده سهم بوده و سپس با ترغیب دیگران نسبت به کاهش قیمت سهم اقدام نماید و در نهایت در قیمت‌های پایین‌تر مجدداً سهم را خریداری کند، استراتژی کاهش قیمت و خرید مجدد^۲ پدیدار می‌شود. استراتژی افزایش قیمت و خالی کردن و کاهش قیمت و خرید مجدد، می‌تواند در بازه زمانی بسیار کوتاه مدت (مثلاً چند ثانیه) و یا بسیار بلندمدت (چند سال) با استفاده از انواع تکنیک‌ها اتفاق بیفتد.

یکی از ویژگی‌های این نوع دستکاری این است که دستکاری کنندگان، مستقیماً از سایر سرمایه‌گذارانی که در قیمت‌های بالاتر سهم خریده و یا در قیمت‌های پایین‌تر سهم فروخته‌اند، کسب درآمد می‌نمایند. بنابراین چالش اصلی این نوع دستکاری، ترغیب و اغوای سایر سرمایه‌گذاران به خرید و یا فروش سهام دستکاری شده می‌باشد.

دسته دوم، دستکاری بر مبنای قرارداد و یا شاخص می‌باشد. در این روش، دستکاری کنندگان با دستکاری دارایی خاصی، از قرارداد، شاخص و یا مرجع خاصی کسب درآمد می‌نمایند. به عنوان مثال فرض کنید دستکاری کننده‌ای موقعیت باز در یکی از قراردادهای ابزار مشتقه داشته و سپس با دستکاری دارایی پایه، از موقعیت خود در ابزار مشتقه منتفع می‌گردد. به عنوان مثالی دیگر فرض کنید دستکاری کنندگان، در اوراقی سرمایه‌گذاری کرده باشند که جریان نقدی و یا قیمت اوراق مذکور، به وسیله یکی از

-
1. Pump and Dump
 2. Bear raid

شاخص‌های مالی مانند نرخ شناور وام‌دهی^۱، نرخ سواپ^۲، قیمت قرارداد آتی و غیره تعیین شود، در آن صورت دستکاری‌کنندگان با دستکاری نمودن شاخص، از اوراق در اختیار کسب درآمد نمایند. تفاوت مهمی بین دسته اول و دوم وجود دارد و آن اینکه در دسته دوم، دستکاری‌کنندگان نیازی به اغوای سایر سرمایه‌گذاران برای خرید یا فروش سهم ندارند.

دسته سوم، شامل سفارشات اغواکننده و سایر تکنیک‌های مبتنی بر سفارش‌گذاری می‌باشد. به صورت کلی، تکنیک‌های مبتنی بر سفارش‌گذاری به این صورت است که سفارش در سیستم معاملات با این هدف وارد می‌شود که انجام نشده و بتوان نسبت به لغو آن قبل از اجرا اقدام نمود. سفارش‌های اولیه موجود در بازار نقش اصلی و تعیین‌کننده‌ای در این نوع دستکاری دارند و معمولاً نیاز به همراهی سایر معامله‌گران نیز می‌باشد.

اگرچه سفارشات اغواکننده می‌تواند به صورت دستی وارد شود، اما با توجه به اینکه در این استراتژی، نیاز به اقدام فوری برای سفارش‌گذاری، اصلاح و لغو سفارش وجود دارد، در اکثر موارد این نوع دستکاری‌ها به وسیله کامپیوتر انجام می‌گیرد. خودکارسازی استراتژی کمک می‌کند تا در تعداد دفعات زیاد این کار انجام گیرد. اگرچه سودآوری این نوع دستکاری در هر بار تکرار اندک می‌باشد، با تکرار آن در دفعات زیاد، سود قابل توجهی پدیدار می‌گردد.

با توجه به رشد معاملات الگوریتمی و با تکرار بالا، استراتژی دستکاری سفارشات اغواکننده، در سال‌های اخیر مورد توجه واقع شده است. به تبع آن نهادهای ناظر، چندین راهکار مقابله با این نوع دستکاری را در نظر گرفته است. صاحبان کد معاملاتی در صورت

-
1. Floating Rate Loans
 2. Swap

انجام این نوع تخلف مورد پیگیری حقوقی قرار می‌گیرند و الگوریتم‌های شناسایی زیادی در نظر گرفته شده که نسبت به شناسایی این نوع تخلفات اقدام نماید.

دسته چهارم دستکاری، شامل مواردی می‌شود که در آن دستکاری کنندگان، با در دست گرفتن قدرت بازاری، سعی در کنترل عرضه و تقاضای سهام می‌نمایند.

با توجه به چهار دسته‌بندی کلی، تکنیک‌های دستکاری می‌توانند در گام بعدی با توجه به مکانیزم اجرایی به پنج دسته تقسیم‌بندی شوند. آلن و گیل^۱ (۱۹۹۲) با توجه به مکانیزم اجرایی، دستکاری سهام را به سه دسته معامله‌محور^۲، اطلاعات‌محور^۳ و اقدام‌محور^۴ تقسیم نمودند. پوتینس (۲۰۲۰) این دسته‌بندی را با اضافه کردن دو دسته دیگر به نام‌های سفارش‌محور^۵ و تابع‌محور^۶ ارتقاء داد. در دستکاری معامله‌محور، دستکاری کنندگان با انجام معامله بر قیمت دارایی پایه تأثیر می‌گذارند. در دستکاری اطلاعات‌محور، دستکاری کنندگان با انتشار اطلاعات غلط یا شایعات بر قیمت شرکت تأثیر گذاشته و از اطلاعات گمراه‌کننده در جهت کاهش یا افزایش قیمت دارایی مذکور استفاده می‌کنند. در دستکاری اقدام‌محور اقداماتی غیر از عرضه و تقاضا که می‌تواند بر قیمت سهم تأثیر گذارد. به عنوان مثال هیات مدیره شرکت، خط تولید شرکت را غیرفعال کند تا قیمت سهم کاهش یابد. در دستکاری سفارش‌محور آن دسته از دستکاری را شامل می‌شود که دستکاری کنندگان از طریق ارسال، اصلاح و حذف سفارش اغواکننده باعث گمراهی بازار می‌شوند. این سفارشات اغواکننده

-
1. Allen & Gale
 2. Trade-based
 3. Information-based
 4. Action-based
 5. Order-based
 6. Submission-based

به نحوی در سیستم معاملات وارد می‌شوند که معامله صورت نپذیرد. همچنین در دستکاری تابع محور دستکاری کنندگان در اجزاء تشکیل دهنده شاخص‌های مالی تغییر و دستکاری انجام می‌دهند به نحوی که از دستکاری انجام شده در شاخص (به طور غیرمستقیم) کسب سود نمایند. علاوه بر قوانین و مقرراتی که در قوانین اوراق بهادار اغلب کشورها به منظور جلوگیری از دستکاری اوراق بهادار گنجانده شده است، برخی سازوکارهای ضد دستکاری اوراق بهادار نیز برای جلوگیری از دستکاری اوراق بهادار تعبیه شده که به عنوان مکملی در شناسایی و جلوگیری از دستکاری اوراق بهادار عمل کند. برخی از سازوکارهای مذکور به ترتیب شامل موارد ذیل است (فلاح‌شمس و تیموری، ۲۰۰۵):

تحت نظر قرار دادن و بررسی بازار که هدف از آن ایجاد سازوکارهایی به منظور تحت نظر قرار دادن و بررسی بازار، درک شرایط حاکم بر بازار و به تبع آن شناسایی اقدامات نامطلوب و تلاش برای ایجاد ابزارهایی جهت جلوگیری از اختلال و گسستگی در بازار می‌باشد. سازوکار بعدی آخرین قیمت است در این خصوص امکان دستکاری آخرین قیمت حتی با انجام معاملات اندک نیز وجود دارد. بنابراین در بعضی از کشورها از جمله ایران از میانگین موزون قیمت‌ها به عنوان قیمت مرجع و تحت عنوان قیمت پایانی استفاده می‌شود. قوانین و مقرراتی که منجر به الزام افشاگری در سطح بازارهای اوراق بهادار می‌شوند، از جمله قوانین و مقرراتی هستند که برای پیشگیری از رفتار فریب کارانه با هدف دستکاری قیمت در قوانین اوراق بهادار اغلب کشورها وجود دارد. با توجه به مبانی نظری و طبقه‌بندی‌های ارائه‌شده، متغیرهای کلیدی همچون بازده سهام، حجم معاملات، خرید و فروش افراد حقیقی و حقوقی انتخاب و در روش‌شناسی تحقیق به عنوان

ورودی مدل‌ها به کار گرفته شده‌اند. بدین ترتیب ارتباط مستقیم مبانی نظری با طراحی مدل‌های پژوهش برقرار گردیده است.

۳. مطالعات تجربی

۳-۱. مطالعات خارجی

زانگ و همکاران (۲۰۲۵) با استفاده از شبکه‌های مولد تخصصی (GANs) و یادگیری انتقالی، مدلی برای شناسایی دستکاری قیمت در بازارهای نوظهور توسعه دادند. نتایج نشان داد که این مدل توانایی بالایی در تفکیک رفتارهای مشکوک از نوسانات عادی بازار دارد و می‌تواند به عنوان ابزاری مکمل برای نهادهای ناظر مورد استفاده قرار گیرد. در این پژوهش از داده روزانه شرکت‌های منفرد S&P ۵۰۰ طی ۵۰ سال (از ۲ ژانویه ۱۹۶۲ تا ۲۲ نوامبر ۲۰۱۶) استفاده شده است.

المطیری و همکاران (۲۰۲۴) به بررسی دستکاری مبتنی بر سفارش در بورس کویت پرداختند. آن‌ها با بهره‌گیری از شبکه‌های عصبی عمیق (Deep Neural Networks) نشان دادند که دستکاری سفارشات به‌ویژه در سهام با نقدشوندگی پایین رخ می‌دهد و مدل پیشنهادی آن‌ها توانست با دقت بیش از ۹۰ درصد چنین الگوهایی را شناسایی نماید. داده‌های مورد استفاده در این مطالعه از وبسایت‌های بورس اوراق بهادار کویت و بانک مرکزی کویت و قیمت‌های نفت از OECD (۲۰۱۹) گرفته شده است. دوره نمونه شامل داده‌های ماهانه برای دوره ۲۰۰۵-۲۰۱۸ است.

یوسف (۲۰۲۰) در پژوهشی به شناسایی دستکاری قیمت با استفاده از روش‌های یادگیری عمیق پرداخت. نویسنده ابتدا با به کارگیری دگرگونی موجک پیوسته،

مشخصه‌های اصلی و تأثیر را شناسایی کرده و با استفاده از تحلیل مؤلفه اصلی (PCA) و تحلیل عاملی (FA)، ابعاد داده‌ها را کاهش داد. سپس داده‌های آماده شده را با شبکه‌های KNN، XGBoost و SVM بررسی و توانایی مدل‌ها در شناسایی دستکاری قیمت‌ها به وسیله پژوهش‌گر ارزیابی گردید. نتایج نشان می‌دهد که استفاده از دگرگونی موجک پیوسته باعث بهبود ارزیابی عملکرد می‌شود. به کارگیری PCA باعث کاهش زمان لازم برای آموزش شده اما اندکی عملکرد شبکه را ضعیف‌تر می‌نماید. از بین سه مدل استفاده شده، XGBoost و KNN عملکرد مناسب‌تری داشتند.

کامینگ و همکاران (۲۰۲۰) در پژوهشی تحت عنوان دستکاری بازار و نوآوری به بررسی این موضوع پرداختند که دستکاری قیمت در انتهای روز چگونه بر نوآوری شرکت تأثیر می‌گذارد. محققان دریافتند که دستکاری قیمت با هدف کوتاه‌مدت، آسیب بلندمدتی بر ارزش شرکت وارد کرده و انگیزه مدیران شرکت را برای نوآوری کاهش می‌دهد. آن‌ها با بررسی داده سهام مشکوک به دستکاری در ۹ کشور به مدت ۸ سال نتیجه گرفتند که دستکاری با نوآوری رابطه معکوس دارد.

ارجن و همکاران (۲۰۲۰) به بررسی دستکاری بازار در کشور در حال توسعه ترکیه با استفاده از داده‌های دستکاری معامله‌محور در دوره زمانی ۲۰۰۵ تا ۲۰۱۳ که به وسیله هیأت بازار سرمایه ترکیه مشخص شده است، پرداختند. یکی از سؤالات اصلی پژوهش‌گران این بود که دستکاری‌کنندگان چگونه سهم مورد نظر برای دستکاری را انتخاب کرده و آیا دستکاری قیمت روی کیفیت و کارایی بازار مؤثر است. نتایج نشان می‌دهد که دستکاری‌کنندگان سهامی با نقدشوندگی پایین، ضعیف از نظر عملکرد و با نوسان کمتر را برای دستکاری در بازارهای در حال توسعه انتخاب می‌کنند. همچنین مشاهده کردند که

در اکثر موارد نقدشوندگی، بازده و نوسان طی دوره دستکاری افزایش یافته و پس از دوره دستکاری کاهش می‌یابد.

کلوس و کاشف (۲۰۲۰) در پژوهشی تحت عنوان ترکیب مدل سیستم ایمنی مصنوعی و تحلیل خوشه‌بندی به کشف ناهنجاری در بازار سرمایه اقدام کردند. داده‌های استفاده شده مربوط به شرکت‌های بزرگی مانند گوگل، آمازون و ... بوده که با توجه به اندازه شرکت و حجم معاملات احتمال دستکاری در آن‌ها نزدیک به صفر است. به همین دلیل در اقدامی مشابه با پژوهش گلمحمدی به ایجاد داده تصادفی البته با استفاده از ابزار متفاوت پرداختند. نتایج مدل ترکیبی بسط داده شده به وسیله محققان قابل توجه و اغواکننده است. شاهرین و همکاران (۲۰۱۹) در مطالعه‌ای به بررسی دستکاری قیمت در بازارهای نوظهور و در حال توسعه شرق آسیا با استفاده از داده‌های سال ۲۰۰۱ الی ۲۰۱۷ و با جمع‌آوری دستی ۲۴۴ سهم دستکاری شده پرداختند. ابزار مورد استفاده پژوهش‌گران رگرسیون لجستیک بوده و نتایج برخلاف انتظار نشان می‌دهد که شرکت‌های بزرگ و نقدشونده با احتمال بیشتری مورد دستکاری واقع می‌شوند.

ماریانی و همکاران (۲۰۱۹) سعی کردند با استفاده از شبکه مولد تخصصی نسبت به بهینه‌سازی سبد اوراق بهادار اقدام نمایند. در مدل آن‌ها ابتدا روند قیمت سهام به وسیله شبکه مولد تخصصی آموزش دیده و سپس با بیشینه‌سازی بازده و کمینه‌سازی ریسک، پرتفوی بهینه تشکیل می‌شود.

تاکاهاشی و همکاران (۲۰۱۹) در پژوهشی به مدل‌سازی سری زمانی قیمت سهام با استفاده از مدل مولد تخصصی پرداختند. نتایج نشان می‌دهد که سری زمانی پیش‌بینی شده

به وسیله مدل مولد تخصصی مشخصه‌های اصلی سری زمانی سهام مانند داشتن دم پهن، عدم تقارن سود و زیان و غیره را در بر دارد.

ژنگ و همکاران (۲۰۱۹) در پژوهشی به پیش‌بینی قیمت سهام با استفاده از مدل مولد تخصصی پرداختند. پژوهش‌گران با استفاده از داده روزانه سهام در S&P 500، شامل اولین، بالاترین، پایین‌ترین، آخرین قیمت، حجم معاملات و میانگین قیمت و بازده ۵ روزه، سری زمانی قیمت سهام را پیش‌بینی نمودند. نتایج نشان می‌دهد که مدل ارائه شده می‌تواند با دقت مناسبی، قیمت پایانی سهام را شبیه‌سازی نماید.

لینگارن و همکاران (۲۰۱۸) با استفاده از شبکه مولد تخصصی ساده، ساختاری طراحی کردند که به وسیله آن امکان شناسایی دستکاری قیمت در بازار سرمایه فراهم می‌شود. در مدل آن‌ها ابتدا شبکه مولد تخصصی با داده نرمال آموزش دیده و سپس شبکه آموزش دیده برای تفکیک داده دستکاری شده و نشده (داده‌های تست) به کار گرفته می‌شود. با توجه به اینکه در مدل مذکور از روش ساده شده مولد تخصصی استفاده شده است، نمی‌توان از متغیرهای ورودی زیادی در مدل استفاده نمود. از طرفی عدم استفاده از نویز، کارایی مدل و امکان تعمیم به بازارهای دیگر را کاهش می‌دهد. مطابق با نتایج پژوهش، دقت مدل حدود ۶۸٪ برآورد گردیده است.

ژنگ و همکاران (۲۰۱۸) در پژوهشی به بررسی انتقال وجه در شبکه بانکی و کلاهبرداری اتفاق افتاده در چین پرداختند. آن‌ها با استفاده از انواع شبکه مولد تخصصی مدلی طراحی کردند که با استناد به آن می‌توان انتقال وجه مشکوک در شبکه بانکی را شناسایی کرد. طبق ادعای نویسندگان اگر تعداد نمونه دستکاری شده بسیار کم باشد، مدل‌های مرسوم یادگیری عمیق توانایی یادگیری مؤثر را نخواهند داشت. به همین جهت

مدل طراحی شده به وسیله پژوهش‌گران این نقیصه را بر طرف کرده و یادگیری به صورت مؤثر انجام خواهد پذیرفت.

سرینگ و همکاران (۲۰۱۷) در پژوهشی به دسته‌بندی انواع دستکاری و ویژگی انواع دستکاری پرداختند و شرایطی را تعریف کردند که طبق آن می‌توان هر یک از دستکاری‌های انجام شده را به یکی از انواع دستکاری نسبت داد. در مطالعات انجام شده روی داده‌های واقعی، نویسندگان نشان دادند که ساختار طراحی شده چگونه می‌تواند به سیستم نظارتی در تشخیص دستکاری قیمت کمک نماید.

لی و همکاران (۲۰۱۷) با استفاده از روش‌های یادگیری عمیق نظارت یافته به بررسی دستکاری قیمت در بورس چین پرداختند. آن‌ها به صورت دستی ۸۲ مورد از اطلاعیه‌های دستکاری بازار سهام را در حکم مجازات اداری صادر شده توسط CSRC که از سال ۲۰۱۴ تا ۲۰۱۶ رخ داده است، شامل ۲۷۴ سهام فهرست شده، جمع‌آوری کردند. آن‌ها نتیجه گرفتند که عملکرد مدل‌های یادگیری عمیق با استفاده از داده‌های روزانه بسیار خوب و با استفاده از داده‌های معاملات بین روز ضعیف بوده است.

احمد و چادهری (۲۰۱۷) در پژوهشی تحت عنوان شناسایی ناهنجاری در بازار مالی، انواع روش‌های هوش مصنوعی و روش‌های آماری را برای شناسایی ناهنجاری در بازار بورس استرالیا با استفاده از داده‌های سال ۲۰۰۹ تا ۲۰۱۳ به کار گرفتند. نتایج نشان می‌دهد که مدل LOF و CMGOS عملکرد بهتری در شناسایی داده‌های ناهنجار داشتند.

نئوپان و همکاران (۲۰۱۶) در پژوهشی تحت عنوان دستکاری معامله‌محور، فراتر از پیگرد قانونی، به بررسی شرکت‌هایی پرداختند که به تازگی عرضه اولیه شده و به وسیله

سندیکایی از معامله گران بزرگ، با حجم قابل توجه و به شیوه معامله محور مورد دستکاری قرار گرفته‌اند. آن‌ها به بررسی مجموعه داده‌های کلی مورد استفاده شامل ۲۳۵ عرضه اولیه عمومی (شامل ۷ شرکت مورد بررسی) که در بورس اوراق بهادار بمبئی (BSE) و بورس ملی (NSE) در بازه زمانی ژانویه ۲۰۰۶ تا دسامبر ۲۰۱۱ فهرست شده‌اند، پرداخته‌اند. بر این اساس به این نتیجه رسیدند که در اکثر عرضه اولیه‌هایی که در آن‌ها دستکاری اتفاق افتاده، سندیکای تشکیل شده برای تبانی و بالا بردن قیمت افراد تقریباً یکسانی بوده‌اند که هیچ‌گاه با محکومیت قضایی همراه نشده‌اند. هم‌چنین در دوره دستکاری، حجم معاملات و قیمت افزایش یافته و پس از خروج دستکاری کنندگان، قیمت با کاهش همراه بوده است. آیتکن و ژانگ (۲۰۱۵) در پژوهشی تحت عنوان معاملات با فراوانی بالا و شامل ۲۲ بورس اوراق بهادار و تغییر قیمت انتهای روز نشان دادند که وجود معاملات با فراوانی بالا بطور قابل ملاحظه‌ای، فراوانی و شدت تغییر قیمت انتهای روز را کاهش داده است. بعلاوه، تأثیر معاملات با فراوانی بالا در مختصر نمودن فراوانی و شدت تغییر قیمت پایان روز قابل توجه‌تر از نقش قوانین معاملاتی، نظارت و شرایط قانونی و فشار است.

گلمحمدی و دیاز (۲۰۱۵) با استفاده از داده‌های جمع‌آوری شده در مقاله دیاز و همکاران (۲۰۱۱) به بررسی انواع روش‌های نظارت یافته هوش مصنوعی برای شناسایی دستکاری قیمتی پرداخته و مدل‌ها را با یکدیگر مقایسه کردند. برخی از ابزارهای مورد استفاده شامل درخت تصمیم، جنگل تصادفی، هوش مصنوعی، بیز ساده، k نزدیک‌ترین همسایه و ماشین بردار پشتیبان بوده است. مدل بیز ساده بهترین عملکرد را از نظر معیار عملکردی $F2$ برابر با ۵۳٪ بهترین عملکرد را در شناسایی دستکاری قیمتی داشته است.

گراس و همکاران (۲۰۱۴) در پژوهشی به بررسی تأثیر دستکاری قیمت بر کارایی بازار در بازار سهام هنگ کنگ پرداختند. داده‌های آن‌ها شامل ۴۰ سهم دستکاری شده طی سال‌های ۱۹۹۶ تا ۲۰۰۹ بوده که از سوی سازمان بورس و اوراق بهادار هنگ کنگ در دادگاه محکوم به دستکاری شده بودند. آن‌ها به این نتیجه رسیدند که دستکاری بر معیارهای کارایی بازار مانند شکاف عرضه و تقاضا و نوسان اثر منفی دارد. بازارها اگر کارا نباشد، دستکاری کنندگان می‌توانند با دستکاری قیمت‌ها کسب سود نمایند و از بازار خارج شوند.

هانگ و چنگ (۲۰۱۳) در مطالعه‌ای به بررسی دستکاری قیمت سهام در بازار سهام تایوان پرداختند. مجموعه داده‌ها شامل ۴۰ مورد دستکاری بازار از سال ۱۹۹۶ تا ۲۰۰۹ است که توسط کمیسیون اوراق بهادار و معاملات آتی هنگ کنگ تحت پیگرد قانونی قرار گرفته‌اند. آن‌ها با مجموعه داده‌های جمع‌آوری شده فوق، به بررسی الگوهای سهام دستکاری شده و اثرات آن‌ها بر بازار پرداختند. نتایج آن‌ها نشان‌دهنده این بود که شرکت‌های دستکاری شده دارای اندازه کوچک بوده و از حاکمیت شرکتهای ضعیفی برخوردار هستند. اکثر موارد دستکاری در این پژوهش با استراتژی معاملاتی افزایش قیمت و خالی کردن در ارتباط بودند. دستکاری به روش افزایش قیمت و خالی کردن منجر به افزایش نوسان، افزایش حجم معاملاتی، بازگشت قیمتی بلندمدت طی دوره دستکاری می‌شود. این دستکاری‌ها تأثیر مهمی بر کارایی بازار خواهند داشت.

گلمحمدی و زایان (۲۰۱۲) در پژوهشی تحت عنوان کاربرد هوش مصنوعی در شناسایی دستکاری در بازار سرمایه به بررسی مروری پژوهش‌های پیشین در این زمینه پرداختند. آن‌ها مطالعات شناسایی دستکاری به وسیله هوش مصنوعی را به پنج دسته کلی

شامل شناسایی الگوی دستکاری، شناسایی داده‌های پرت، استخراج قوانین ضد دستکاری، تحلیل شبکه‌های اجتماعی در زمینه دستکاری و شناسایی دستکاری از طریق نمودار و تصویرسازی تقسیم کرده و داده‌های مورد نیاز برای هر نوع پژوهش را ذکر کردند.

کیم و سان (۲۰۱۲) در مقاله‌ای تحت عنوان شناسایی دستکاری بازار با استفاده از تحلیل گروهی همسان (PGA)، مدلی از یادگیری عمیق نظارت نیافته، برای شناسایی الگوهای مشکوک به دستکاری در بورس کشور کره طراحی نمودند. روش PGA داده‌هایی با رفتار غیرنرمال را در مقایسه با سایر هم‌گروه‌ها بررسی نموده و با توجه به میزان انحراف از گروه همسان، آن را در دسته همسان یا ناهمسان قرار می‌دهد. همچنین روشی برای بهبود مدل PGA برای شناسایی دقیق‌تر رفتارهای غیرنرمال ارائه نمودند.

دiaz و همکاران (۲۰۱۱) در پژوهشی به بررسی چالش‌های به کارگیری روش‌های هوش مصنوعی برای شناسایی دستکاری بازار پرداخته و با استفاده از اطلاعات بازاری سهام دستکاری معامله‌محور را بررسی نمودند. آن‌ها با تشکیل سبدي از دارایی مشابه با سهام دستکاری شده، اختلاف بین بازده سهام دستکاری شده و بازده سبد مشابه را به عنوان یکی از متغیرهای (ویژگی‌های) اصلی در نظر گرفتند. متغیرهای استفاده شده شامل اختلاف بازدهی سهام دستکاری شده با سبد مرجع، بازدهی غیرنرمال سهام، نقدشوندگی و نوسان سهم می‌باشد. در نهایت پژوهش‌گران با استفاده از درخت تصمیم به بررسی سهام دستکاری شده پرداخته و الگوریتمی برای شناسایی دستکاری به نهاد ناظر پیشنهاد دادند.

کامینگ و همکاران (۲۰۱۰) در پژوهشی تحت عنوان قوانین معاملات بورسی به بررسی ارتباط بین قوانین ضد دستکاری قیمت و معاملات مبتنی بر اطلاعات نهانی برای ۴۲ بورس در سرتاسر دنیا پرداختند. برخی بورس‌ها دارای قوانین با جزئیات زیاد بوده که به

وضوح اقدامات دستکاری‌کننده مشخصی را ممنوع اعلام نموده و برخی دیگر از قوانین گسترده و کمتر دقیق استفاده می‌کردند. پژوهش‌گران همچنین بر اساس قوانین معاملاتی کشورها، شاخصی برای شناسایی دستکاری بازار طراحی نمودند.

اوگت و همکاران (۲۰۰۹) به شناسایی دستکاری قیمت سهام در بازار ترکیه پرداختند. آن‌ها از متغیرهایی مانند تفاوت بین متوسط بازدهی روزانه شاخص و سهام دستکاری‌شده، متوسط نوسان روزانه و متوسط تغییر روزانه حجم معامله، استفاده نمودند. همچنین پژوهش‌گران دوره سهام دستکاری را صرفاً زمانی در نظر گرفتند که دستکاری‌کنندگان سهام را خریداری و پس از طی دوره دستکاری فروخته است؛ به عبارتی دوره پیش از دستکاری و پس از فروش دستکاری‌کنندگان به عنوان دوره دستکاری لحاظ نشده است. پژوهش‌گران با آزمون‌های مختلفی به تحلیل اطلاعات و داده‌ها پرداخته و به این نتیجه رسیدند که روش‌های داده‌کاوی (نظیر ماشین بردار پشتیبان و شبکه عصبی مصنوعی) در شناسایی دستکاری قیمت بهتر از روش‌های آماری چندمتغیره عمل می‌کنند.

۲-۳. مطالعات داخلی

حبیب زاده و همکاران (۱۴۰۳) با هدف شناسایی دستکاری سهام در بورس اوراق بهادار تهران، داده‌های مربوط به ۷۳ سهم از ۱۹ صنعت طی سال‌های ۱۳۹۸ تا ۱۴۰۲ (حدود ۷۱۳۰۰ روز معاملاتی) مورد بررسی قرار گرفت. پژوهش‌گران برای شناسایی داده‌های دستکاری‌شده، علاوه بر آزمون‌های آماری همچون بازدهی غیرنرمال، از داده‌های تصادفی شبیه‌سازی‌شده و نظر خبرگان نیز بهره گرفتند. سپس الگوریتم ترکیبی خودرمزگذار متغیر و حافظه کوتاه‌مدت طولانی (VAE-LSTM) طراحی و عملکرد آن با مدل‌های یادگیری

ماشین از قبیل درخت تصمیم، جنگل تصادفی، رگرسیون لجستیک، ماشین بردار پشتیبان و شبکه عصبی چندلایه مقایسه شد. نتایج نشان داد که براساس شاخص ارزیابی عملکرد F2، مدل VAE-LSTM با دقت حدود ۷۲ درصد بهترین عملکرد را در شناسایی سهام دستکاری شده داشته و پس از آن مدل‌های درخت تصمیم و جنگل تصادفی قرار گرفتند. همچنین یافته‌ها نشان داد که احتمال وقوع دستکاری در بازارهای صعودی بیشتر از بازارهای متعادل و نزولی است.

حسن زاده و همکاران (۱۴۰۲) در پژوهشی با رویکرد توصیفی - تحلیلی به بررسی حکم فقهی دستکاری قیمت در معاملات سهام عادی در بورس اوراق بهادار پرداختند. نویسندگان با استناد به مفهوم «نجش» در فقه اسلامی یعنی ورود به معامله و پیشنهاد قیمت بالاتر بدون قصد خرید به منظور فریب خریدار - این پرسش را مطرح کردند که آیا دستکاری قیمت در بورس می‌تواند از مصادیق نجش تلقی گردد یا خیر. نتایج نشان داد که از نظر مشهور فقها، نجش حرام است، اما اگر نجشی واقع شود و معامله سهام انجام گیرد، عقد بیع صحیح خواهد بود. همچنین در خصوص اینکه «منجوش علیه» در صورت وقوع نجش حق فسخ (خیار) دارد یا خیر، دیدگاه‌های متفاوتی ارائه شده است.

یکه‌زارع (۱۳۹۸) در پایان‌نامه‌ای تحت عنوان دستکاری قیمتی در معاملات حق تقدم در بورس تهران، با استفاده از داده‌های افزایش سرمایه، قیمت و همچنین مالکیت بنگاه‌های بازار سرمایه ایران، پدیده دستکاری قیمتی هنگام انتشار حق تقدم را بررسی نمودند. نتایج پژوهش نشان می‌دهد که سهامداران عمده با فروش سهام هنگام انجام معاملات حق تقدم، اقدام به کاهش قیمت سهام و سپس خرید حق تقدم در قیمت‌های پایین می‌نمایند.

کاظمی تبار و شهباززاده (۱۳۹۸)، با استفاده از کاربرد نامساوی چیشف، روشی برای شناسایی افرادی که از اطلاعات نهانی، استفاده شخصی کرده و در مدت کوتاهی سود کلانی کسب کرده‌اند، ارائه دادند. برای استفاده از روش مذکور، دو فیلتر شامل تراکنش‌های بزرگ و افرادی که بیشترین سود حاصل از خرید و فروش سهام در مدل زمان اندک (سه روز) به دست آورده‌اند، به وسیله پژوهش‌گران در نظر گرفته شد. با تغییر فیلترها از سخت به آسان می‌توان افرادی که احتمالاً از اطلاعات نهانی استفاده کرده‌اند را شناسایی نمود.

توحیدی و موسویان (۱۳۹۷) بررسی فقهی بورس‌بازی مبتنی بر دستکاری قیمت در بازار اوراق بهادار را مورد مطالعه قرار دادند. طبق ادعای نویسندگان، بورس‌بازان با توجه به اینکه به دنبال کسب سود سریع ناشی از تغییرات و نوسانات مقطعی قیمت دارایی در افق زمانی کوتاه‌مدت هستند، اغلب متهم به دستکاری قیمت‌ها به روش‌های فریبده و گمراه‌کننده هستند. به همین دلیل پژوهش‌گران به بررسی حکم فقهی بورس‌بازی همراه با روش‌های مختلف دستکاری پرداخته و به این نتیجه رسیدند اگر بورس‌بازی همراه با دستکاری قیمت‌ها به روش‌های فریبده و گمراه‌کننده باشد، از نظر شرعی محل اشکال است. در پژوهش مذکور، ضوابط مختلف فقهی شامل ممنوعیت تدلیس، غرور، نجش، غبن، ضرر و ضرار، تبانی و معامله صوری با روش‌های مختلف دستکاری تطبیق داده شده و حکم فقهی هر یک تبیین گردید.

ریعی و همکاران (۱۳۹۷) در پژوهشی تحت عنوان بررسی و تحلیل تأثیر برخی عوامل مؤثر بر دستکاری قیمت در بازار سهام ایران، به بررسی شرکت‌های مستعد دستکاری پرداختند. پژوهش‌گران با استفاده از دو دوره سه ماهه (یک دوره صعودی شاخص و یک

دوره نزولی)، دستکاری به روش ورود سفارش اغواکننده را بررسی نمودند. نتایج مطالعات نشان می‌دهد که شرکت‌های کوچک با حجم معاملات بالا، شفافیت اطلاعاتی اندک، نوسان بازدهی بالا و با سابقه دستکاری در گذشته، برای دستکاری قیمت مستعدتر هستند. همچنین دستکاری قیمت با تغییرات شاخص بازار رابطه معکوس دارد.

ریعی و همکاران (۱۳۹۷) در مقاله‌ای به بررسی تأثیر دستکاری قیمت بر کارایی بازار در بورس اوراق بهادار تهران پرداختند. آن‌ها نمونه‌ای شامل ۲۸۸ شرکت را در دوره سه ماهه منتهی به زمستان ۱۳۹۴ گردآوری و بررسی نموده که از آن تعداد ۱۴۴ شرکت به روش ارسال سفارش اغواکننده دچار دستکاری شده بودند. پژوهش‌گران طی دوره مذکور با استفاده رگرسیون داده‌های پنل به بررسی تأثیر دستکاری قیمت بر متغیرهای شکاف عرضه و تقاضا و حجم معاملات به عنوان متغیرهای اندازه‌گیرنده کارایی بازار پرداختند. نتایج مطالعات نشان می‌دهد که پیش از وقوع دستکاری قیمت، شکاف عرضه و تقاضا افزایش و با وقوع دستکاری، کاهش می‌یابد. همچنین سهام با حجم معاملات بالا برای دستکاری قیمت مستعدتر می‌باشند.

فلاح‌زاده و همکاران (۱۳۹۴) در پایان‌نامه‌ای تحت عنوان تشخیص دستکاری قیمت در سهام با استفاده از تکنیک‌های داده‌کاوی و به طور خاص درخت تصمیم، به بررسی دستکاری در بازار سرمایه ایران پرداخته‌اند. آن‌ها بازده روزانه ۱۸۷ شرکت پذیرفته شده در بورس اوراق بهادار تهران را در بازه زمانی سال‌های ۱۳۸۹ تا ۱۳۹۳ جمع‌آوری کرده و سپس با به کارگیری آزمون‌های تسلسل، ضریب کشیدگی و چولگی، سهام را به دو گروه دستکاری شده و نشده تقسیم کردند. سپس با بررسی نمودار روند بازدهی و حجم معاملات، تاریخ شروع دستکاری را تعیین کردند. در نهایت با استفاده از متغیرهای رتبه

نقدشوندگی سهم، نسبت P/E، وضعیت شفافیت اطلاعات و ترکیب سهامداری شرکت، به توسعه مدل‌هایی مبتنی بر انواع درخت تصمیم جهت پیش‌بینی دستکاری سهام پرداختند. نتایج نشان می‌دهد که مدل درخت تصمیم ۵C توانایی بهتری در پیش‌بینی، نسبت به دیگر مدل‌های درخت تصمیم دارد.

فلاح شمس لیالستانی و همکاران (۱۳۹۴)، ضمن بررسی و تبیین مفاهیم مربوط به دستکاری قیمت و به خصوص دستکاری قیمت پایانی، مدلی برای شناسایی احتمال وقوع دستکاری قیمت پایانی سهام در بورس اوراق بهادار تهران ارائه دادند. در پژوهش آن‌ها بر خلاف مقالات پیشین، برای تقسیم‌بندی شرکت‌ها به دو گروه دستکاری شده و نشده آزمون‌های run test و sign test به کار گرفته شده است. همچنین از متغیرهایی شامل بازدهی سهام، دفعات معامله، قیمت پیشنهادی خرید و فروش، حجم معاملات و سرعت گردش معاملات سهام نیز استفاده شده است. نتایج نشان می‌دهد مدل رگرسیون لجستیک ارائه شده در پژوهش مذکور توانایی شناسایی دستکاری قیمتی در بازار را دارد.

شمس و عطایی (۱۳۹۳)، شناسایی دستکاری قیمت سهام از طریق مدل ترکیبی الگوریتم ژنتیک-شبکه عصبی مصنوعی (ANN-GA) و مدل تابع تفکیکی درجه دو تعدیل شده (SQDF) را با استفاده از داده‌های مربوط به سال ۱۳۸۹ الی ۱۳۹۲ شامل ۳۱۶ شرکت، مورد بررسی قرار دادند. نتایج نشان داد که مدل ترکیبی ANN-GA عملکرد بهتری نسبت به مدل SQDF دارد.

پوست‌فروش و همکاران (۱۳۹۳)، سنجش دستکاری قیمت‌ها با استفاده از مدل‌های ترکیبی تحلیل ممیزی درجه دوم و الگوریتم ژنتیک بر مبنای شبکه عصبی مصنوعی را

بررسی کردند. آن‌ها ابتدا با روش غربال‌گری، نمونه‌ای به حجم ۳۴۵ شرکت پذیرفته شده در بورس اوراق بهادار تهران را در بازده زمانی ۱۳۸۷ الی ۱۳۹۱ انتخاب نموده و اطاعات مربوط به شاخص‌های قیمت و بازده نقدی، قیمت پایانی، نوسان قیمت پایانی و حجم معاملات را گردآوری کردند. سپس با روشی مشابه با مطالعات پیشین، یعنی بررسی نمودار روند تغییرات شاخص قیمت و بازده نقدی و حجم معاملات، تاریخ شروع دستکاری را تعیین کرده و با اطلاعات مربوط به یک‌سال گذشته از زمان دستکاری شدن سهم، مدل مذکور را برای شناسایی دستکاری توسعه دادند. نتایج نشان می‌دهد مدل تحلیل ممیزی درجه دوم نسبت به مدل الگوریتم ژنتیک بر مبنای شبکه عصبی مصنوعی، توانایی بهتری در دسته‌بندی سهام دستکاری شده و نشده دارد.

رشنو و همکاران (۱۳۹۰) در مقاله‌ای تحت عنوان بررسی دستکاری قیمت‌ها در بورس اوراق بهادار تهران با استفاده از مدل ماشین‌بردار پشتیبان، توانایی مدل مذکور را در دسته‌بندی شرکت‌ها به دو گروه دستکاری شده و نشده ارزیابی نمودند. آن‌ها طی دوره مطالعه ۳۷۹ شرکت را با استفاده از آزمون دیرش به دو گروه دستکاری شده (۳۳۴ شرکت) و دستکاری نشده (۹۵ شرکت) تقسیم‌بندی کردند. نتایج پژوهش نشان می‌دهد، مدل ماشین‌بردار پشتیبان می‌تواند با دقت ۸۱٪ در دسته‌بندی شرکت‌ها موفق عمل نماید.

فلاح‌شمس و کردلوئی (۱۳۹۰) مدلی برای تخمین دستکاری قیمت در بورس اوراق بهادار تهران ارائه نمودند. برای این کار ابتدا به روش غربال‌گری نمونه‌ای به حجم ۳۹۷ از شرکت پذیرفته شده در بورس اوراق بهادار تهران انتخاب کرده و اطلاعات مربوط به قیمت و حجم معاملات آن‌ها را طی سال‌های ۱۳۸۰ تا ۱۳۸۸ گردآوری نمودند. سپس با استفاده از آزمون‌های تسلسل، کشیدگی و آزمون وابستگی دیرش شرکت‌های منتخب را به دو

دسته دستکاری شده و دستکاری نشده تقسیم کردند. سپس با استفاده از آزمون‌های لاجیت و شبکه عصبی مصنوعی و با در نظر گرفتن اندازه شرکت، شفافیت اطلاعات، نسبت P/E و نقدشوندگی سهام، مدلی برای پیش‌بینی دستکاری قیمت سهام شرکت‌ها در بورس اوراق بهادار طراحی کردند. نتایج نشان داد که قدرت پیش‌بینی مدل لاجیت و شبکه‌های عصبی مصنوعی به ترتیب ۹۲/۱٪ و ۹۴/۱٪ بوده است.

پژوهش حاضر از جنبه‌های مختلف دارای نوآوری می‌باشد. نخست اینکه مجموعه متغیرهایی که برای شناسایی دستکاری قیمتی انتخاب شده‌اند، از جامعیت بالایی برخوردار بوده و ترکیبی از شاخص‌های تکنیکال و بنیادین را شامل می‌شود. با توجه به ساختار مدل طراحی‌شده، نگرانی از بابت ورود متغیرهای کم‌اهمیت وجود ندارد، که همین موضوع امکان انتخاب گسترده‌تری از پارامترها را برای پژوهشگران فراهم می‌سازد. همچنین دوره زمانی مطالعه و تعداد سهام انتخاب شده برای بررسی به حدی زیاد بود که دوره‌های مختلف صعود و نزول بازار سرمایه و کارایی مدل‌ها در دوره‌های مختلف بررسی شود تا نتایج برآورد شده خطایی نداشته باشند. دوم اینکه برای اولین بار در ایران با استفاده از داده‌های واقعی و برچسب‌گذاری آن‌ها بر اساس آزمون‌های آماری (تسلسل، کشیدگی و چولگی و ...) و با بهره‌گیری از رگرسیون لجستیک و داده‌های پنل نشان داده شد که در زمان دستکاری سهام، حجم معاملات افزایش قابل توجه داشته و بازدهی سهام و میانگین خرید و فروش اشخاص حقیقی و حقوقی به طرز محسوسی نسبت به میانگین افزایش می‌یابد. این نتایج با مطالعات خارجی پیشین نیز تطابق دارد. سوم آنکه برای اولین بار (تا حد اطلاعات نویسندگان) از مدل‌های هوش مصنوعی شامل درخت تصمیم، شبکه عصبی چند لایه و

رگرسیون لجستیک برای شناسایی دستکاری و رتبه بندی مدل‌ها با استفاده از معیار F2 استفاده شده است. در نهایت برای اعتبارسنجی مدل از روش‌های اعتبارسنجی متقابل ۱۰ برابر استفاده شده است که در مطالعات پیشین داخلی از این روش استفاده نشده است.

۴. روش شناسی پژوهش

پژوهش حاضر از بعد کیفی و کمی، مطالعه کمی بوده و از منظر هدف، پژوهشی کاربردی و تجربی می‌باشد. از حیث روش جمع‌آوری داده‌های مورد نیاز یا به عبارتی طرح پژوهش نیز جزء پژوهش‌های توصیفی تحلیلی است. روش مورد استفاده جهت تجزیه و تحلیل داده‌ها، انواع مدل‌های یادگیری عمیق مانند رگرسیون لجستیک^۱، درخت تصمیم^۲ و شبکه عصبی چند لایه^۳ می‌باشد.

دامنه زمانی این پژوهش، از ابتدای اولین روز کاری سال ۱۳۹۵ تا انتهای آخرین روز کاری سال ۱۳۹۹ به مدت ۵ سال و به صورت دوره‌های روزانه می‌باشد. طی این مدت بازار سرمایه حالت‌های مختلف شامل انواع روندهای صعودی و نزولی طولانی‌مدت و تعادل بلندمدت را تجربه کرده است و این مورد کمک می‌کند که داده‌ها از تنوع کافی برخوردار باشند. بازار سرمایه ایران از ابتدای ۱۳۹۵ تا انتهای ۱۳۹۶ تقریباً شرایط تعادل را پشت سر گذاشته است. از ابتدای ۱۳۹۷ تا اواسط سال ۱۳۹۹ یک روند بلندمدت صعودی را تجربه کرده و از مرداد ۱۳۹۹ تا انتهای ۱۳۹۹ در یک روند نسبتاً طولانی نزولی قرار گرفته است.

-
1. Logistic Regression
 2. Decision Tree
 3. Multilayer Perceptron

برای اینکه بتوان از روش‌های داده‌کاوی و یادگیری عمیق برای شناسایی دستکاری سهام استفاده نمود، ابتدا باید اطمینان حاصل شود که چه سهامی مورد دستکاری واقع شده و زمان دقیق دستکاری آن در چه دوره‌ای بوده است. در بازار سرمایه کشورهای توسعه یافته، معمولاً شرکت‌های دستکاری شده، توسط نهاد ناظر و دادگاه‌های ذیصلاح اعلام می‌شود. علی‌رغم اینکه در بسیاری از موارد سهام مورد دستکاری توسط نهاد ناظر شناسایی و بررسی نشده و از همین رو شاید قابلیت اطمینان صد درصدی نداشته باشد، به هر ترتیب یکی از ابزارهای اصلی محققان برای آماده‌سازی داده، افشای سهام دستکاری شده به وسیله نهاد ناظر می‌باشد.

متأسفانه در کشور ایران، سازمان بورس و اوراق بهادار سهام دستکاری شده را مشخص نمی‌نماید. بنابراین در این پژوهش لازم است ابتدا نسبت به تشکیل داده‌هایی شامل سهام دستکاری شده و نشده و تاریخ دقیق دستکاری سهام دستکاری شده آن اقدام نماییم. برای این منظور می‌توان از روش ذیل برای ایجاد داده استفاده شده است: با استفاده از نظرسنجی خبرگان بازار، ابتدا سهامی که از نظر نقدشوندگی و اندازه بازار شرايطی را دارند که امکان دستکاری قیمتی در این سهام وجود ندارد را انتخاب کرده و عموماً در برخی سهام و در زمان‌های خاص، داده‌هایی تصادفی به مدل تزریق می‌شود که شبیه‌ساز دستکاری قیمتی سهام باشند. در این صوت می‌توان اطمینان داشت که کدام سهام و در چه محدوده زمانی با اطمینان صد درصد دستکاری شده‌اند. لازم به ذکر است مدل طراحی شده برای شناسایی دستکاری قیمتی کاملاً مستقل از مدلی است که داده‌های تصادفی را به مدل تزریق می‌کند (کائو و همکاران، ۲۰۱۲). برای تکمیل نهایی داده‌ها، باید مشخص کنیم که در دوره

دستکاری، چه زمان‌هایی دستکاری اتفاق افتاده است. طبق پژوهش اگارول و وو (۲۰۰۶) در فرایند دستکاری سهم، چهار مرحله اتفاق می‌افتد:

۱. مرحله قبل از دستکاری.

۲. مرحله ورود دستکاری کنندگان: سفته‌بازان با افزایش تقاضا سعی در خرید سهم و ارسال سیگنال مثبت به بازار هستند.

۳. دستکاری کنندگان با تبلیغات مستمر سعی در ارسال سیگنال مثبت به بازار نموده و جست و کنندگان اطلاعات، با افزایش تقاضا قیمت سهم را بالا می‌برند، در این زمان سفته‌بازان سهام خود را فروخته و خارج می‌شوند.

۴. در مرحله چهارم سهم در یک اصلاح زمانی معمولاً با کاهش قیمت و حجم معاملات مواجه می‌شود. مرحله دوم و سوم تحت عنوان دستکاری شناخته می‌شود. از این رو در پژوهش حاضر، متغیر دستکاری، تنها در مرحله دوم و سوم مقدار یک گرفته و در سایر موارد مقدار صفر می‌گیرد.

در ادامه به توضیح نحوه ایجاد پایگاه داده و برچسب‌گذاری آن طی دو سناریو می‌پردازیم.

در این پژوهش به بررسی اطلاعات ۶۹ سهم از ۱۹ صنعت مختلف بین سال‌های ۱۳۹۵ الی ۱۳۹۹ پرداخته شده است. در مدت مذکور سهام انتخاب شده صرفاً در بازار اول و دوم بورس تهران و فرابورس ایران معامله می‌شدند و طی این دوره نیز هیچکدام از سهام مزبور عرضه اولیه نشده بودند. همچنین لازم به ذکر است در مدت مورد بررسی نماد هیچکدام از سهام بیش از سه ماه متوالی بسته و متوقف نبودند چراکه بسته بودن طولانی مدت متواند نتایج مدل را تحت تأثیر خود قرار دهد.

برچسب‌گذاری با استفاده از روش‌های آماری و سایر روش‌های بدون نظارت نیز تا حدودی می‌تواند راه‌گشا باشد اما اطمینان صد درصدی به این روش وجود نداشته و احتمال دارد در برچسب‌گذاری خطا وجود داشته باشد. در این پژوهش برای ایجاد داده به روش تزریق تصادفی از روش ارائه شده توسط گلمحمدی و همکاران (۲۰۱۵) استفاده شده است.

طی این روش ابتدا سهامی که به احتمال بسیار زیاد دچار دستکاری نشده‌اند انتخاب می‌شود. سهام مذکور دارای ویژگی‌هایی مانند حجم معاملات و ارزش بازار بالا، نقدشوندگی زیاد و عدم وجود ابهام قابل ملاحظه می‌باشند. برای اطمینان از انتخاب درست سهام دستکاری نشده، طی پرسش‌نامه‌ای نظر فعالان بازار سرمایه در مورد احتمال دستکاری شدن سهام انتخابی گرفته شده و سهامی که کمترین احتمال در دستکاری را داشت به عنوان سهام دستکاری نشده برگزیده شد.

سپس با استفاده از تابع توزیع داده‌ها در دوره زمانی مشخص (مثلاً دوره سه ماهه، شش ماهه و یک ساله) و همچنین میانگین و انحراف معیار داده‌ها در دوره مذکور، داده‌های تکین (پرت) که شبیه‌ساز دستکاری قیمتی سهام بوده به مدل تزریق شده است. لازم به ذکر است که روش شناسایی دستکاری به وسیله مدل‌های یادگیری عمیق و مدل پیشنهادی این پژوهش، کاملاً مستقل از نحوه تولید داده تصادفی می‌باشد.

به منظور مقایسه مدل ارائه شده در مقاله حاضر با سایر مدل‌های یادگیری عمیق، از انواع روش‌های یادگیری عمیق مانند درخت تصمیم، شبکه عصبی چندلایه و رگرسیون لجستیک استفاده شده که در ادامه به صورت خلاصه به معرفی هر یک پرداخته و ساختار

کلی شبکه استفاده شده در این پژوهش به همراه توابع فعال‌سازی، تابع خطا و موارد دیگر شرح داده می‌شود.

رگرسیون لجستیک از مدل‌های دسته‌بندی محسوب می‌شود. در این مدل‌ها، خروجی به صورت احتمالی از متغیر دو وضعیتی (مثلاً صفر و یک، مرد و زن و ...) می‌باشد. به عنوان مثال مدل رگرسیون لجستیک مشخص می‌کند که مثلاً با احتمال ۳۰٪ این ایمیل اسپم و با احتمال ۷۰٪ اسپم نیست. برای تبدیل احتمال محاسبه شده به دسته، فرض می‌شود که اگر احتمال بیشتر از ۵۰٪ باشد، در دسته‌ای که برچسب یک خورده و اگر زیر ۵۰٪ باشد، در دسته‌ای که برچسب صفر خورده قرار می‌گیرد. در مثال ایمیل، داده مذکور در دسته غیراسپم قرار می‌گیرد. لازم به ذکر است به دلیل اینکه متغیر وابسته در تحقیق بصورت صفر و یک است، رگرسیون لجستیک مدل مناسبی برای مدلسازی می‌باشد. به عبارتی زمانی که متغیر وابسته صفر و یک است رگرسیون‌های خطی مناسب نیستند. استفاده از رگرسیون لجستیک (Logistic Regression) است که متغیر وابسته دوحالتی (دستکاری شده = ۱، دستکاری نشده = ۰) را امکانپذیر می‌کند.

اگر از رگرسیون معمولی در برآورد استفاده شود، مقادیر پیش‌بینی شده ممکن است خارج از بازه [۰, ۱] قرار گیرد و سبب میشود که فرض نرمال بودن خطاها نقض گردد. رگرسیون لجستیک با تابع لجستیک، احتمال رخداد یک وضعیت (مثلاً دستکاری) را بین ۰ و ۱ برآورد می‌کند. مدل رگرسیون لجستیک نشان می‌دهد که هر متغیر مستقل چقدر به توضیح تفاوت بین گروه‌ها (دستکاری شده و نشده) کمک می‌کند. به جای پیش‌بینی مقدار دقیق متغیر وابسته، احتمال تعلق یک مشاهده به دسته (۱) (دستکاری) را برآورد می‌کند.

در رگرسیون لجستیک معمولاً از تابع سیگموید استفاده می‌شود چرا که خروجی تابع سیگموید بین صفر و یک بوده و می‌توان خروجی آن را به عنوان احتمال در نظر گرفت. در مدل حاضر از تابع بهینه‌یابی lbfgs استفاده شده و همچنین تابع هزینه binary_crossentropy به کار گرفته شده است.

مدل‌های مبتنی بر درخت تصمیم شبیه به ماشین بردار پشتیبان، قابلیت استفاده برای حل مسائل رگرسیونی و دسته‌بندی را دارد. درخت تصمیم‌گیری تولید شده در مدل‌های درخت تصمیم را می‌توان به صورت گرافیکی مشاهده نموده و بر اساس آن تصمیم‌گیری کرد. همچنین این امکان وجود دارد که متغیرهای مهم‌تر و تأثیرگذار در دسته‌بندی شبکه را شناسایی کرده و بر اساس آن‌ها الگوریتم مناسب برای تصمیم‌گیری را اتخاذ نمود.

شبکه عصبی، مجموعه‌ای از نورون‌هاست که با قرار گرفتن در لایه‌های مختلف، معماری خاصی را بر مبنای ارتباطات بین نورون‌ها در لایه‌های مختلف تشکیل می‌دهند. نورون می‌تواند یک تابع ریاضی غیرخطی باشد، در نتیجه یک شبکه عصبی که از اجتماع این نورون‌ها تشکیل می‌شود نیز می‌تواند یک سامانه کاملاً پیچیده و غیرخطی باشد. در شبکه عصبی هر نورون به‌طور مستقل عمل می‌کند و رفتار کلی شبکه، برآیند رفتار نورون‌های متعدد است. به عبارت دیگر، نورون‌ها در یک روند همکاری، یکدیگر را تصحیح می‌کنند.

شبکه عصبی جزء اولین مدل‌های یادگیری عمیق بوده که به مرور با ظهور شبکه‌های قدرتمندتر کمتر در جامعه علمی از آن استفاده می‌شد. اما در سال ۲۰۱۱ زمانی که دن گیرسان موفق شد دسته‌بندی تصاویر را با به کارگیری شبکه عصبی برنده شود، توجه

جامعه آکادمیک مجدداً به شبکه عصبی چندلایه معطوف گردید. در سال ۲۰۱۲ با ابداع شبکه عصبی چندلایه شرطی، این مدل تبدیل به یکی از مدل‌های پیشرو در حوزه یادگیری ماشین گردید. در پژوهش حاضر از مدل شبکه عصبی با دو لایه پنهان، تابع فعال‌سازی رلو و سیگموید، تابع بهینه‌سازی آدام به عنوان بازار اندازه‌گیری عملکرد استفاده شده است. برای صحت سنجی و پایایی مدل‌های یادگیری عمیق روش‌های مختلفی مانند جدا کردن داده آموزش از تست، اعتبار سنجی متقابل k برابر، اعتبار سنجی یک طرفه، اعتبار سنجی متقابل تو در تو استفاده می‌شود که در این پژوهش از جداسازی داده آموزش از تست و روش اعتبار سنجی متقابل ۱۰ برابر استفاده شده است.

۵. تجزیه و تحلیل داده‌ها و یافته‌های پژوهش

قبل از اجرای مدل‌های یادگیری عمیق، ابتدا لازم است بررسی نماییم که داده‌های مذکور چقدر هم‌راستا با مطالعات پیشین می‌باشند. مطابق با ادبیات نظری، زمانی که دستکاری در بازار سرمایه اتفاق می‌افتد، اثر آن بر برخی از متغیرها مشهود است. طی دوره دستکاری، معمولاً بازدهی سهام، نقدشوندگی (یا به عبارتی حجم معاملات) و نوسان‌پذیری افزایش می‌یابد (آگراوال و وو، ۲۰۰۶؛ دیاز و همکاران، ۲۰۱۱). برای آزمون دقیق‌تر این موضوع، معمولاً از مدل‌های رگرسیونی و رگرسیون لجستیک استفاده می‌شود. همان‌طور که از رابطه زیر مشخص است، متغیرهای مورد بررسی (Indicator) مانند بازدهی سهام، میانگین حجم معاملات و غیره، طی دوره دستکاری به وسیله متغیر مجازی (Manipulated) آزمون می‌شود.

همان‌طور که از رابطه ۱ مشخص است، متغیرهای مورد بررسی (Indicator) مانند بازدهی سهام، میانگین حجم معاملات و غیره، طی دوره دستکاری به وسیله متغیر مجازی (manipulated) آزمون می‌شود. لازم به ذکر است با توجه به اینکه هر یک از سهام دارای ویژگی‌های منحصر به فردی هستند باید از داده‌های پانل برای برآورد استفاده نمود. همچنین برای کاهش خطای مدل، غیر از متغیر بازدهی سهام، از لگاریتم سایر متغیرها استفاده شده است.

اگر اثرات ثابت باشد $Indicator_{it} = \alpha_0 + \alpha_1 * Manipulated_{it} + \mu_i + \varepsilon_{it}$

اگر اثرات تصادفی باشد $Indicator_{it} = \alpha_0 + \alpha_1 * Manipulated_{it} + u_i + \varepsilon_{it}$ „
 $u_i \sim IID(0, \sigma_u^2), \varepsilon_{it} \sim IID(0, \sigma_\varepsilon^2)$

رابطه ۱. آزمون متغیرها در صورت ثبات یا تصادفی بودن اثرات (دیاز و همکاران، ۲۰۱۱)

در رابطه فوق، متغیر مجازی در زمان وقوع دستکاری، مقدار یک و در زمان‌های دیگر مقدار صفر می‌گیرد. در صورتی که ضریب α_1 معنی‌دار باشد بدین معنی است که در دوره دستکاری مقدار متغیر مورد بررسی (Indicator) به میزان قابل توجهی نسبت به سایر دوره‌ها متفاوت است. برای بررسی نتایج آزمون‌های مازاد اثرات ثابت و هاسمن نیز به منظور بررسی پانل، اثرات ثابت و یا تصادفی نیز انجام شده است.

به طور معکوس نیز این مورد تست می‌شود که آیا با استفاده از متغیرهای مرتبط با سهام (بازده، حجم معاملات، نوسان‌پذیری و غیره)، می‌توان بین زمان دستکاری و عدم دستکاری در سهام تمایز قائل شد. برای این منظور مطابق با روابط زیر از رگرسیون لجستیک استفاده


می‌شود که در آن هر یک از انواع متغیر مورد آزمون به عنوان متغیر مستقل و متغیر مجازی به عنوان متغیر وابسته ایفای نقش می‌کند.

$$Manipulated = \beta_0 + \beta_1 * Indicator_1 + \dots + \beta_n * Indicator_n + \varepsilon$$

$$f(z) = \frac{1}{1 + e^{Manipulated}}$$

رابطه ۲. تست معکوس متغیرها (یافته‌های پژوهش)

در روابط ۱ و ۲، متغیر مجازی در زمان وقوع دستکاری مقدار یک و در زمان‌های دیگر مقدار صفر می‌گیرد. مطالعات مختلف نشان داده‌اند که در طول دستکاری، متغیرهای تأثیرگذار بر سهام ثابت نبوده و افزایش پیدا می‌کنند. لذا تلاش شده است با استفاده از تحلیل رگرسیونی و یا در نوع پیشرفته‌تر آن با استفاده از روش‌های هوش مصنوعی و با استفاده از متغیرهای مختلف، زمان وقوع دستکاری سهام شناسایی شود (آگراوال و وو، ۲۰۰۶؛ دیاز و همکاران ۲۰۱۱؛ گلمحمدی و همکاران، ۲۰۱۵).



شکل ۱. تغییر متغیرهای مربوط به سهام طی دوره دستکار

ماخذ: دیاز و همکاران، ۲۰۱۱

شکل زیر نمونه‌ای از تغییر متغیرها در زمان دستکاری، قبل و بعد از دوره دستکاری را نمایش می‌دهد. همان‌طور که ملاحظه می‌شود تغییر قابل توجهی در متغیرها طی دوره دستکاری ایجاد می‌شود.

برای این منظور رگرسیون ذکر شده در روابط فوق را برآورد می‌نماییم. نتایج در جداول بعد ارائه گردیده است. با توجه به ویژگی خاص احتمالی هر سهم، در گام اول به بررسی این موضوع می‌پردازیم که آیا لازم است داده‌ها به صورت پانل باشد یا می‌توان از داده‌های تجمیع شده (Pooled) استفاده نمود. برای این منظور در جدول زیر مقدار P مربوط به آزمون امکان جمع‌شوندگی داده‌ها ذکر شده است.

جدول ۱. بررسی رگرسیون خطی

میانگین فروش حقیقی	میانگین خرید حقیقی	میانگین فروش حقوقی	میانگین خرید حقوقی	حجم معاملات	بازده	رگرسیون خطی Indicator $= \alpha_0 + \alpha_1 * Manip. + \varepsilon$
۰/۰۰۰۰	۰/۰۰۰۰	۰/۰۰۰۰	۰/۰۰۰۰	۰/۰۰۰۰	۰/۰۱۶۱	P-value

مأخذ: یافته‌های پژوهش

همان‌طور که مشاهده می‌شود در تمامی رگرسیون‌ها لازم است داده‌ها به صورت پانل مورد آزمون قرار گیرد. در ادامه نتایج مربوط به رگرسیون ذکر شده در رابطه فوق و آزمون هاسمن مربوطه نیز ذکر شده است. لازم به ذکر است تطبیق داده‌ها با مطالعات پیشین هدف اصلی پژوهش نبوده و مقایسه مدل‌های شناسایی دستکاری قیمتی سهام با استفاده از روش‌های مختلف هوش مصنوعی و تعیین عملکرد آن‌ها ملاک بوده است. ولی به هر

ترتیب آزمون‌های اولیه مفروضات کلاسیک شامل نرمال بودن باقی‌مانده‌ها، نداشتن همخطی و موارد دیگر در این قسمت نیز آزمون شده است و اکثر مفروضات رعایت شده است. با توجه به معنادار بودن قابل توجه متغیرها و همچنین لازم بودن مقدار عددی ضرایب هدف بوده است، تخمین (α_1) حتی با فرض نقض برخی فروض کلاسیک بدون تورش می‌باشد.

جدول ۲. بررسی رگرسیون خطی

میانگین فروش حقیقی	میانگین خرید حقیقی	میانگین فروش حقوقی	میانگین خرید حقوقی	حجم معاملات	بازده	رگرسیون خطی $\text{Indicator} = \alpha_0 + \alpha_1 * \text{Manip.} + \varepsilon$
۰/۸۰۸۵	۰/۴۴۷۷	۰/۲۵۶۳	۰/۰۶۷۰	۰/۶۷۴۰	۰/۷۱۳۵	P-value Huasman
اثر تصادفی	اثر تصادفی	اثر تصادفی	اثر تصادفی	اثر تصادفی	اثر تصادفی	اثر ثابت / تصادفی
-۰/۱۲۶۹	۰/۱۰۱۸	۰/۵۵۱۰	۰/۳۰۷۱	۰/۰۷۶۱	۰/۰۱۳۸	α_1
(۰/۰۲۴۱)	(۰/۰۲۸۵)	(۰/۰۶۲۰)	(۰/۰۵۴۲)	(۰/۰۰۳۷)	(۰/۰۰۰۸)	انحراف معیار
۰/۰۰۰۰	۰/۰۰۰۴	۰/۰۰۰۰	۰/۰۰۰۰	۰/۰۰۰۰	۰/۰۰۰۰	P-value

مأخذ: یافته‌های پژوهش

* تمامی متغیرها در سطح ۹۹٪ معنی دار هستند.

همان‌طور که از جدول فوق مشخص است با توجه به ویژگی‌های مربوط به هر سهم، تمامی رگسیون‌ها داده‌های پانلی با اثرات تصادفی می‌باشند. همچنین درمی‌یابیم که بازده و حجم معاملات (که به نوعی نشان‌دهنده نقدشوندگی سهام می‌باشد) در زمان دستکاری افزایش یافته که با مطالعات دیاز و همکاران (۲۰۱۱) و آگراوال و همکاران (۲۰۰۶) هم‌خوانی دارد. همان‌طور که انتظار می‌رفت در زمان دستکاری، افزایش در میانگین خرید و فروش شرکت‌های حقوقی و خرید حقیقی نیز اتفاق افتاده است.

تنها نکته در ظاهر عجیب، منفی بودن ضریب متغیر میانگین فروش حقیقی می‌باشد که دلیل آن را باید در اتفاقات دوره دستکاری جست و جو کرد. معمولاً در نیمه اول دوره دستکاری، افراد حقیقی طی چندین روز اقدام به خرید سهام با حجم بالا نموده و در نیمه دوم دوره دستکاری که کمتر از نیمه اول به طول می‌انجامد، به سرعت سهام دستکاری شده را می‌فروشند. خرید افراد حقیقی در نیمه اول دوره دستکاری بسیار آرام صورت می‌پذیرد به نحوی است که سایر سرمایه‌گذاران قبل از تکمیل خرید دستکاری‌کنندگان دچار هیجان نشوند. در این مرحله تعداد زیادی از افراد حقیقی خرد شروع به فروش سهام در حجم‌های اندک می‌نمایند. این مورد سبب می‌شود که در اول دوره دستکاری میانگین فروش حقیقی کاهش یابد. اگرچه در نیمه دوم دستکاری، درست زمانی که دستکاری‌کنندگان سهام را می‌فروشند، میانگین فروش حقیقی افزایش می‌یابد، تأثیر این افزایش از کاهش ابتدای دوره کمتر می‌باشد. این امر سبب می‌شود که میانگین فروش حقیقی در دوره دستکاری کاهش یابد.

اکنون لازم است با استفاده از روابط فوق بررسی نماییم که آیا متغیرهای مذکور می‌توانند نمونه را به دو دسته سهام دستکاری شده و نشده تفکیک کنند. نتایج در جدول زیر ارائه گردیده است. همان‌طور که از نتایج مشخص است تمامی متغیرها در سطح ۹۵٪

معنی‌دار بوده و می‌تواند بین داده‌های دستکاری شده و نشده تمایز قائل شوند. با توجه به توضیحی که در مورد میانگین فروش حقیقی در قسمت قبل ارائه شد، این متغیر در رگرسیون لجستیک برآورد شده، حذف گردید. به نظر می‌رسد با هماهنگی ایجاد شده بین دستکاری‌کنندگان حقیقی و مدیران شرکت‌های حقوقی طی دوره دستکاری، مدیران شرکت‌های حقوقی کمتر به عرضه سهام مورد دستکاری پرداخته و این موضوع ضریب منفی متغیر میانگین فروش حقوقی را توضیح می‌دهد. تنها نکته عجیب، ضریب منفی متغیر میانگین خرید حقوقی طی دوره دستکاری است که ممکن است در صورت استفاده از متغیرهای کنترل این مشکل برطرف شود. به صورت کلی می‌توان گفت که داده‌ها هم‌راستا با نتایج تحقیقات پیشین می‌باشد.

جدول ۳. نتایج رگرسیون لجستیک

متغیرها	ضرایب	مقدار ضرایب	انحراف معیار	آماره Z	p-value
ثابت	β_0	-۷/۴۹۶	۰/۲۲۱	-۳۳/۹۳۱	۰/۰۰۰
بازده	β_1	۲۷/۷۰۳	۲/۴۷۹	۱۱/۱۷۷	۰/۰۰۰
حجم	β_2	۸/۷۲۷	۰/۳۰۵	۲۸/۵۸۲	۰/۰۰۰
میانگین خرید حقیقی	β_3	۰/۶۶۱*	۰/۲۷۶	۲/۳۹۶	۰/۰۱۷
میانگین خرید حقوقی	β_4	-۲/۰۷۹	۰/۲۷۴	-۷/۵۸۲	۰/۰۰۰
میانگین فروش حقوقی	β_5	-۵/۳۱۴	۰/۳۱۲	-۱۷/۰۵۳	۰/۰۰۰

مأخذ: یافته‌های پژوهش

*ضریب میانگین خرید حقیقی در سطح اطمینان ۹۵٪ و ضریب سایر متغیرها در سطح اطمینان ۹۹٪ معنی‌دار می‌باشد.

حال که تطبیق داده‌ها با مطالعات پیشین انجام شد و صحت داده‌ها با پژوهش‌های قبلی مورد بررسی قرار گرفت، لازم است با استفاده از مدل‌های هوش مصنوعی به بررسی توانایی هر مدل در شناسایی دستکاری می‌پردازیم.

برای بررسی عملکرد شبکه‌های یادگیری عمیق نیاز به شاخص‌هایی کمی می‌باشد. برای تعریف شاخص‌های عملکردی نیاز است ابتدا چندین متغیر استفاده شده در مدل‌های یادگیری عمیق شرح داده شوند. در خروجی هر مدل یادگیری عمیق یکی از حالات ذیل اتفاق می‌افتد.

- **به درستی مثبت (True Positive):** سهام واقعاً دستکاری شده باشد و شبکه آن را دستکاری شده تشخیص دهد.
- **به اشتباه مثبت (False Positive):** سهام واقعاً دستکاری نشده باشد و شبکه آن را دستکاری شده تشخیص دهد.
- **به درستی منفی (True Negative):** سهام واقعاً دستکاری نشده باشد و شبکه آن را دستکاری شده تشخیص ندهد.
- **به اشتباه منفی (False Negative):** سهام واقعاً دستکاری شده باشد و شبکه آن را دستکاری شده تشخیص ندهد.

	Predicted 0	Predicted 1
Actual 0	TN	FP
Actual 1	FN	TP

شکل ۲. ماتریس درهم‌ریختگی در مدل‌های یادگیری عمیق

طبیعتاً مدل هوش مصنوعی هر چه تلاش کند که TP و TN را افزایش داده و FP و FN را کاهش دهد، عملکرد بهتری خواهد داشت. برای اینکه بتوان بین مدل‌ها و داده‌های مختلف مقایسه انجام داد، معیارهای ارزیابی عملکرد بر پایه چهار متغیر ذکر شده طراحی شده است.

دقت (Precision) اولین معیار ارزیابی می‌باشد که از طریق فرمول $P = \frac{TP}{TP+FP}$ محاسبه می‌شود. بازخوانی (Recall) از طریق فرمول $R = \frac{TP}{TP+FN}$ به دست می‌آید. این دو متغیر به صورت جداگانه و بر حسب درصد محاسبه شده و هر چه مقدار این دو متغیر بیشتر باشد، نشان‌دهنده عملکرد بهتر مدل می‌باشد. برای ترکیب این دو شاخص عملکردی و تبدیل آن به یک عدد واحد، از میانگین هارمونیک شاخص استفاده می‌شود.

$$F_{\beta} = \frac{(1 + \beta^2) * P * R}{(\beta^2 * P) + R} = \frac{(1 + \beta^2) * TP}{(1 + \beta^2) * TP + (\beta^2 * FN) + FP}$$

رابطه ۳. محاسبه معیار F بتا (ماخذ: پوا، ۲۰۰۵)


در رابطه ۳، β ضریب اهمیت معیار ارزیابی عملکرد بازخوانی در مقابل دقت می‌باشد. اگر دقت و بازخوانی اهمیت یکسانی داشته باشند، β برابر با یک و شاخص ارزیابی $F1$ ایجاد می‌گردد. در بازار سرمایه اشتباه در دسته‌بندی سهام دستکاری شده و نشده، هزینه متقارن ندارند. بدین معنی که اگر سهم واقعاً دستکاری شده باشد و به اشتباه آن را دستکاری نشده در نظر بگیریم (FN)، به مراتب هزینه بیشتری نسبت به حالتی که سهم دستکاری نشده باشد و به اشتباه دستکاری شده در نظر بگیریم (FP)، به سیستم تحمیل می‌شود چرا که در

حالت دوم فقط انرژی نهاد ناظر برای بررسی گرفته می‌شود اما در حالت اول ممکن است سهامداران از دستکاری انجام شده و تشخیص داده نشده آسیب ببینند (پوا، ۲۰۰۵). بنابراین در این پژوهش از شاخص‌های ارزیابی دقت، بازخوانی، $F1$ و $F2$ (در حالتی که بتا معادل با ۲ باشد) استفاده شده و برای رتبه‌بندی مدل‌ها از شاخص ارزیابی عملکردی $F2$ استفاده شده است.

در نهایت با استفاده از داده‌های ایجاد شده به آموزش مدل‌ها و تست عملکردی هر مدل پرداخته شده است. نتایج در جدول زیر نشان داده شده است.

جدول ۴. مقایسه عملکرد مدل‌های هوش مصنوعی

مدل	دقت (P)	بازخوانی (R)	اندازه $F1$	اندازه $F2$
Tree Decision	٪۶۶/۶۵	٪۶۹/۰۶	٪۶۷/۸۳	٪۶۸/۵۶
MLP	٪۸۳/۳۳	٪۳۶/۵۳	٪۵۰/۷۹	٪۴۱/۱۵
Regression Logistic	٪۶۶/۶۷	٪۲۲/۲۲	٪۳۳/۳۳	٪۲۵/۶۴



نمودار ۱. مقایسه عملکرد مدل‌های هوش مصنوعی

ماخذ: یافته‌های پژوهش

شاید بهتر باشد به بررسی این موضوع بپردازیم که نتایج تا چه اندازه با مطالعات قبلی هم‌راستا می‌باشد. مدل‌های یادگیری از منظر کارایی به دو دسته تولیدی^۱ و تمایزدهنده^۲ تقسیم می‌شوند. مدل‌هایی بر مبنای مدل مولد تخصصی در دسته تولیدی قرار می‌گیرند؛ بدین معنی که ابتدا تابع توزیع داده‌های ورودی را شناسایی کرده و سپس بر اساس توزیع داده‌ها، دسته‌بندی را انجام می‌دهند.


از آنجا که متغیرهای تأثیرگذار در بازار سرمایه بسیار گسترده بوده و تغییر اندکی در آن‌ها می‌تواند مدل‌های تمایز محور را گمراه سازد، به نظر می‌رسد مدل‌های تولیدی در بازار سرمایه و در شناسایی دستکاری قیمتی سهام بهتر عمل می‌کنند. در مطالعه گل‌محمدی و همکاران (۲۰۱۵) که با استفاده از روش‌های نظارت شده، کارایی چندین مدل یادگیری عمیق بررسی شد نیز نتیجه تا حدودی مشابه این پژوهش بوده است. آن‌ها در مطالعه خود مدل‌هایی مانند درخت تصمیم C0/5، درخت تصمیم CART، درخت تصمیم CTree، شبکه عصبی چندلایه، جنگل تصادفی و بیز ساده را بررسی نمودند که بیز ساده عملکرد بهتری نسبت به سایر مدل‌های مورد بررسی داشت. لازم به توضیح است که بیز ساده در دسته مدل‌های تولیدی قرار داشته و سایر روش‌های نام‌برده در دسته مدل‌های تمایزدهنده جای می‌گیرند. به هر ترتیب شاید باید مطالعات بیشتری در این زمینه صورت گیرد تا نتیجه‌گیری انجام شده قابلیت اتکا داشته باشد.

همان‌طور که در روش شناسی توضیح داده شد تعداد کل روزهای معاملاتی مورد بررسی حدود ۷۱،۲۰۰ روز می‌باشد. برای اطمینان از پایایی و مانایی مدل از روش

-
1. Generative
 2. Discriminative


اعتبارسنجی متقابل ۱۰ برابر استفاده شده است. بدین ترتیب که کل داده‌ها به ۱۰ قسمت برابر تقسیم شده و هر بار ۹ قسمت برای آموزش و یک قسمت برای تست در نظر گرفته شده و در نهایت میانگین شاخص‌های ارزیابی عملکرد به عنوان خروجی گزارش شده است.

همان‌طور که در قسمت قبل بحث شد مدل‌های مبتنی بر درخت تصمیم، دسته‌بندی مناسبی جهت تصمیم‌گیری در اختیار استفاده‌کنندگان از مدل قرار می‌دهند. با استفاده از خروجی درخت تصمیم حتی می‌توان سیاست‌ها و قواعد مناسبی برای شناسایی دستکاری پیشنهاد داد. این مدل‌ها همچنین می‌توانند متغیرهای تأثیرگذار را بر اساس اهمیت طبقه‌بندی نمایند. اگرچه همانند سایر قسمت‌های مقاله، برنامه‌نویسی مربوط به خروجی درخت تصمیم نیز با استفاده از نرم افزار پایتون و کتابخانه `sklearn.tree` امکان‌پذیر بود، با توجه به خروجی‌های با کیفیت و گرافیکی نرم‌افزار کلمنتاین ۱۲، از نرم‌افزار مذکور استفاده شده است. اشکال زیر خروجی درخت تصمیم و متغیرهای با اهمیت مربوطه را نمایش می‌دهد.




ادامه در صفحه بعد

ادامه از صفحه قبل



نمودار ۲. متغیرهای تأثیرگذار بر شناسایی دستکاری سهام در بازار سرمایه بر اساس مدل درخت تصمیم

ماخذ: یافته‌های پژوهش



نمودار ۳. سطح بندی اهمیت متغیرها

ماخذ: یافته‌های پژوهش

همان‌طور که قبلاً در روش شناسی و در قسمت داده‌ها شرح داده شد، داده‌ها با روش نرمال استاندارد با میانگین و انحراف معیار ۹۰ روز معاملاتی قبل، استاندارد شده‌اند. با بررسی اشکال فوق نتایج جالبی حاصل می‌شود. همان‌طور که ملاحظه می‌شود متغیر حجم در همان روز دستکاری (vol0) و متغیر حجم در یک روز معاملاتی قبل از دستکاری (vol1) بیشترین اهمیت را در شناسایی دستکاری سهام دارند. حتی حجم یک روز معاملاتی قبل اهمیت بالاتری دارد چرا که معمولاً اگر دو روز متوالی حجم معاملات بالا باشد، احتمال دستکاری افزایش می‌یابد.

بازدهی دو روز گذشته سهم (ret2) در رتبه بعدی اهمیت قرار می‌گیرد. ممکن است سهم دو روز مثبت باشد و متعادل شود، ولی نتایج حاضر نشان می‌دهد که اگر سهم سه روز متوالی بازدهی بالایی ثبت کرد لازم است از نقطه نظر دستکاری بررسی شود. میانگین خرید حقیقی در همان روز (ARB0) و میانگین فروش حقیقی در یک روز قبل (ARS1) و

بازدهی در همان روز (ret_0) در درجات بعدی اهمیت قرار دارند. شاید توضیح اهمیت فروش حقیقی در یک روز قبل از دستکاری در این باشد که دستکاری کنندگان در روز قبل از دستکاری به آرامی شروع به جمع کردن سهم از بازار کرده و برخی از سهامداران بزرگ حقیقی که در جریان بازی دستکاری قرار ندارند فرصت مناسبی برای فروش سهم خود پیدا کنند. به هر ترتیب با کاوش بیشتر در درخت تصمیم، سازمان بورس و اوراق بهادار می‌تواند استراتژی‌های خاصی تبیین کرده که با احتمال مناسبی زنگ خطر قبل از دستکاری سهم به صدا درآید. به عنوان مثال در اولین گره درخت تصمیم اگر حجم در یک روز معاملاتی قبل از روز مشکوک به دستکاری در حالت استاندارد شده (نرمال با میانگین و انحراف معیار) کمتر از دو باشد با احتمال $99/93\%$ دستکاری در سهام انجام نمی‌شود. لذا این مقدار کم تا حدودی قابل اغماض است. حال اگر معیار مذکور بیش از سه باشد، احتمال دستکاری بسیار زیاد بوده و نیاز به بررسی می‌باشد. حال اگر مقدار مذکور بین دو و سه باشد، تنها در صورتی بررسی بیشتر صورت می‌گیرد که حجم در روز معاملاتی مشکوک به دستکاری مقداری بیش از دو بگیرد چرا که در شرایطی که در روز مشکوک نیز مقدار زیر دو باشد، احتمال اینکه سهم در حال دستکاری باشد، بسیار ناچیز می‌باشد. لذا با در نظر گرفتن این موضوع می‌توان استراتژی‌های مختلفی را نهاد ناظر تدارک ببیند تا نسبت به شناسایی سهام دستکاری شده با رویه مشخصی اقدام نماید.

۶. خلاصه و نتیجه گیری

هدف اصلی این پژوهش طراحی مدل‌های جدید یادگیری عمیق جهت شناسایی دستکاری سهام در بازار سرمایه ایران بوده است. برای این منظور به بررسی پیشینه پژوهش، جمع‌آوری

و آماده‌سازی داده‌های مورد نیاز و تشریح روش تحلیل داده‌ها پرداخته و بر اساس نتایج، مدل بهینه یادگیری عمیق برای شناسایی دستکاری سهام تعیین شد. در کنار هدف اصلی پژوهش، برخی اهداف فرعی مانند مقایسه انواع روش‌های یادگیری عمیق در شناسایی دستکاری سهام، چگونگی احتمال دستکاری در دوران رونق، رکود و تعادل بازار سرمایه ایران و نحوه استخراج استراتژی شناسایی دستکاری سهام با استفاده از مدل درخت تصمیم بررسی گردید.

دستکاری سهام از دیرباز وجود داشته و قدمت آن تقریباً به زمان تأسیس بازارهای مالی باز می‌گردد. بازار سرمایه زمانی به معنی واقعی کلمه می‌تواند نقش خودش را به درستی ایفا نماید که اولاً مشارکت‌کنندگان و فعالان نسبتاً زیادی در این بازار نقش داشته و ثانیاً بازار سرمایه از مقبولیت بین آن‌ها برخوردار باشد. حال اگر به هر نحو اعتماد مشارکت‌کنندگان به بازار از دست برود، دیگر نمی‌توان امیدی به شکوفایی و توسعه بیشتر بازار سرمایه داشت. یکی از خطرناک‌ترین مواردی که می‌تواند منجر به عدم کارایی بازار در ایفای وظایف خطیرش شود، دستکاری سهام به وسیله عده‌قلیلی با هدف کسب منفعت از طریق اقدامات فریبکارانه است.

در راستای حفظ منافع فعالان بازار و به منظور صیانت از اهداف و کارایی بازار، همواره نهاد ناظر به عنوان متولی بازار تلاش کرده است که این اقدامات فریبکارانه را شناسایی و با متخلفان برخورد نماید. لذا در این راستا قوانین متعددی وضع شده که منجر به کاهش دستکاری سهام می‌شود. در بازارهای در حال توسعه که قوانین محدودکننده کمتری برای برخورد با دستکاری وجود دارد، شناسایی دستکاری اهمیت دوچندان می‌یابد.

با افزایش حجم معاملات و تعمیق هر چه بیشتر بازارها، شناسایی دستکاری حتی سخت‌تر از گذشته شده و این امر باعث می‌شود که روش‌های نوینی برای شناسایی دستکاری لازم باشد. با ظهور الگوریتم‌های پیشرفته و استفاده از کامپیوترهای قدرتمند برای انجام معاملات، امکان سو استفاده بیشتر برای دستکاری کنندگان فراهم شده است. بنابراین نهاد ناظر برای مقابله با دستکاری کنندگان، ناچار است از کامپیوتر و روش‌های نوین شناسایی دستکاری مانند مدل‌های یادگیری عمیق بهره گیرد. محققان بسیاری تلاش نموده‌اند تا با به کارگیری روش‌های یادگیری عمیق، دستکاری بازار را شناسایی کنند. طبیعتاً روز به روز روش‌ها و مدل‌های جدیدی برای انجام دستکاری ظهور می‌نماید و در طرف مقابل نیاز است روش‌های جدید یادگیری عمیق نیز برای مقابله استفاده شود.

برای این منظور در پژوهش حاضر به بررسی عملکرد مدل‌های هوش مصنوعی در شناسایی دستکاری در بازار سرمایه پرداخته شد و نشان داده شد که مدل مبتنی بر درخت تصمیم نسبت به مدل‌های شبکه عصبی چندلایه و رگرسیون لجستیک عملکرد بهتری در شاخص ارزیابی عملکردی F_2 دارد. این شاخص وزن بیشتری به شاخص بازخوانی (Recall) در مقابل شاخص دقت (Precision) می‌دهد چرا که در بازار اگر سهامی دستکاری نشده باشد و مدل به اشتباه اعلام دستکاری نماید، آسیب چندانی به سیستم وارد نشده و صرفاً وقت و هزینه بررسی بیشتری توسط نهاد ناظر صرف خواهد داشت. اما اگر سهامی دستکاری شده باشد و مدل به اشتباه اعلام دستکاری نماید، کارایی بازار به خطر افتاده و به مرور باعث کاهش اعتماد فعالان بازار می‌شود.

برای آموزش و بررسی مدل پیشنهادی و سایر مدل‌های یادگیری عمیق، نیاز به وجود پایگاه داده‌ای شامل سهام دستکاری شده و نشده می‌باشد. در بازارهای به نسبت پیشرفته

این مهم به وسیله نهاد ناظر افشا می‌شود که البته مطابق با مطالعات انجام شده حتی در بازارهای پیشرفته هم تعداد کمی از سهام دستکاری شده به وسیله نهاد ناظر کشف می‌شود (فورد و پوتنیس، ۲۰۱۴). در کشور ایران سهام دستکاری شده مورد پیگرد حقوقی قرار نگرفته و یا افشا نمی‌شود. همین امر سبب شده است که بر اساس روش‌های عملی و بر پایه مطالعات پیشین، دو نوع پایگاه داده‌ای متفاوت از سهام دستکاری شده و نشده به وسیله محققان ایجاد شود.

در پایگاه داده‌ای اول پژوهش‌گران با استفاده از آزمون‌های آماری شامل تسلسل، چولگی، کشیدگی و روش‌های بدون نظارت مانند شناسایی ناهنجاری متنی (CAD) و همچنین با استفاده از بررسی بصری و نموداری، روزهای معاملاتی که سهام دستکاری شده است را شناسایی کرده و از آن برای آموزش و تست مدل‌ها استفاده می‌نمایند. در روش دوم سهامی که نظر به مشخصات خاص آن‌ها مانند نقدشوندگی و شفافیت بالا، با احتمال خیلی کمی مورد دستکاری قرار می‌گیرند، انتخاب شده و متغیرهای تصادفی مطابق با الگوی دستکاری قیمت (مانند الگوی افزایش قیمت و خالی کردن)، به داده‌های نرمال تزریق شده است. در نهایت داده‌های تزریق شده در روز معاملاتی مشخص، به عنوان سهام دستکاری شده و سایر سهام به عنوان سهام دستکاری نشده در نظر گرفته شده است. برای این کار از اطلاعات ۶۹ سهام پذیرش و درج شده در بورس اوراق بهادار تهران در فاصله زمانی ۱۳۹۵ الی ۱۳۹۹ استفاده شده است. تعداد کل روزهای معاملاتی حدود ۷۱،۲۰۰ بوده که از این بین در ۵۰۰ روز معاملاتی دستکاری رخ داده و در سایر روزها دستکاری اتفاق نیفتاده است.

پس از اجرای مدل‌های پیشنهادی پژوهش و سایر مدل‌های یادگیری عمیق، بر اساس شاخص ارزیابی عملکردی F_2 ، به ترتیب مدل‌های درخت تصمیم، شبکه عصبی چندلایه و رگرسیون لجستیک عملکردی بهتری داشتند. مقدار حدودی شاخص ارزیابی عملکردی F_2 مدل‌های مذکور به ترتیب عبارتند از: ۰/۶۸، ۰/۴۵ و ۰/۲۶.

ذکر این نکته ضروری است که مدل شبکه عصبی چندلایه در این پژوهش عملکرد مناسبی در شاخص ارزیابی دقت با مقدار ۰/۸۳ در مقایسه با ۰/۶۶ درخت تصمیم داشته است، اما متأسفانه از نظر شاخص عملکردی بازخوانی که اتفاقاً مهم‌تر می‌باشد، عملکرد ضعیفی داشته است. به نظر می‌رسد با بررسی‌های آماری و احتمال‌شناسایی هر یک از مدل‌ها، می‌توان استراتژی‌های مختلفی با استفاده از ترکیب نتایج مدل‌های یادگیری عمیق طراحی نمود که در شناسایی دستکاری سهام، کارا تر باشد. بررسی این موضوع به پژوهش‌های آتی واگذار می‌گردد.

در نهایت باید عنوان داشت که با استفاده از مدل مبتنی بر درخت تصمیم، سازوکاری پیشنهاد گردید که با استفاده از آن شناسایی دستکاری قیمتی در بازار سرمایه با استفاده از پارامترهای مشخصی توسط نهاد ناظر امکانپذیر بوده و می‌تواند مزایای بسیاری مانند عدم بستن طولانی مدت سهام و جلوگیری از دستکاری قیمتی را داشته باشد.

برخی از پیشنهادات ناشی از پژوهش به شرح موارد ذیل می‌باشد:

- با توجه به اینکه کنترل و جلوگیری از دستکاری سهام در بازار سرمایه به عهده نهاد ناظر می‌باشد، نتایج پژوهش حاضر برای متولیان نظارتی بازار سرمایه قابل استفاده می‌باشد. مطابق با ساختار ارائه شده در فصل اول و نتایج فصل چهارم،

نهادهای نظارتی می‌توانند ساختاری برای مقابله با دستکاری سهام در بازار سرمایه تدارک ببینند.

- مدیران سرمایه‌گذاری شرکت‌های بزرگ و صندوق‌های سرمایه‌گذاری، همواره از خرید سهامی که از سوی سودجویان مورد دستکاری قرار می‌گیرد، خودداری می‌نمایند؛ اما متأسفانه راهکار عملی و علمی برای شناسایی اینکه سهم تا چه میزان مورد دستکاری قرار می‌گیرد در اختیار ندارند. این پژوهش کمک می‌کند که مدیران سرمایه‌گذاری با اطمینان بیشتری سهامی که در حال دستکاری شدن است را شناسایی نموده و از خرید آن خودداری نمایند.
 - افراد حقیقی بازار سرمایه با سرمایه خرد، معمولاً هدف اصلی دستکاری‌کنندگان و سودجویان بازار سرمایه می‌باشد و از بی‌اطلاعی این افراد در جهت رسیدن به اهداف دستکاری سهام بهره می‌برند. با گسترش شناسایی دستکاری قیمتی با استفاده از روش‌های یادگیری عمیق و انتشار آن، به افراد مذکور اطلاع‌رسانی لازم صورت می‌پذیرد که از این رهگذر در دام سودجویان قرار نگیرند.
- در نهایت پیشنهاد می‌شود از سایر روش‌های هوش مصنوعی و یادگیری عمیق در شناسایی دستکاری سهام استفاده شده و نتایج با پژوهش حاضر مقایسه شود.

منابع

- اردبیلی، محمدعلی (۱۳۸۲). حقوق جزای عمومی. جلد اول، میزان.
- امینی، مهدی؛ عیسیای تفرشی، محمد و مرتضی شهبازی نیا (۱۳۹۳). «دستکاری بازار اوراق بهادار: مفهوم، مبانی و روش‌ها (مطالعه تطبیقی در حقوق ایران و آمریکا)». پژوهش‌های حقوق تطبیقی، ۱۹، ۱-۲۶.
- پوست فروش، محمد حسین؛ ناصر صدرآبادی، علیرضا و محمود معین‌الدین (۱۳۹۳). «سنجش دستکاری قیمت‌ها با استفاده از مدل‌های تحلیل ممیزی درجه دوم و الگوریتم ژنتیک بر مبنای شبکه عصبی مصنوعی». دانش مالی تحلیل اوراق بهادار، ۱۴۳-۱۱۹.
- توحیدی، محمد و سیدعباس موسویان (۱۳۹۷). «بررسی و تحلیل فقهی بورس‌بازی مبتنی بر دستکاری قیمت در بازار اوراق بهادار». فصلنامه بورس اوراق بهادار، ۱۱ (۴۴)، ۷۹-۱۱۳.
- ربیعی، ریحانه؛ ندیری، محمد؛ پیمانی، مسلم و علی جابری‌زاده (۱۳۹۷). «بررسی تأثیر دستکاری قیمت بر کارایی بازار در بورس اوراق بهادار تهران». فصلنامه بورس اوراق بهادار، ۱۱ (۴۳)، ۱۱۳-۱۳۱.
- شمس، شهاب‌الدین و بهروز عطایی (۱۳۹۵). «شناسایی دستکاری قیمت سهام از طریق مدل ترکیبی الگوریتم ژنتیک-شبکه عصبی مصنوعی و مدل SQDF». راهبرد مدیریت مالی، ۴ (۳)، ۱۷۱-۱۴۹.
- شمس، شهاب‌الدین و مرضیه ناجی‌زواره (۱۳۹۴). «بررسی مقایسه‌ای بین مدل ترکیبی سیستم ژنتیک فازی عصبی خودسازمانده و مدل خطی در پیش‌بینی قیمت توافقی قراردادهای آتی سکه طلا». تحقیقات مالی، تهران.
- فلاح‌زاده، حدیث (۱۳۹۷). تشخیص دستکاری در سهام با استفاده از تکنیک‌های داده‌کاوی. دانشگاه علم و هنر وابسته به جهاد دانشگاهی. تهران.

- فلاح شمس، میرفیض و علی تیموری شندی (۱۳۸۴). «طراحی الگوی پیشبینی دستکاری قیمت در بورس اوراق بهادار تهران». فصلنامه پژوهشی دانشگاه امام صادق (ع). ۲۷.
- فلاح شمس، میرفیض و حمیدرضا کردلویی (۱۳۹۰). «آزمون مدل‌های لاجیت و شبکه عصبی مصنوعی جهت پیش بینی دستکاری قیمت در بورس اوراق بهادار تهران». مهندسی مالی و مدیریت اوراق بهادار، تهران.
- فلاح شمس، میرفیض؛ کردلویی، حمیدرضا و مهدی رشنو (۱۳۹۱). «بررسی دستکاری قیمت‌ها در بورس اوراق بهادار تهران با استفاده از مدل ماشین بردار پشتیبان». تحقیقات مالی، ۱۴(۱)، ۸۴-۶۹.
- فلاح شمس لیالستانی، میرفیض؛ بادپا، ایوب و اسماعیل بادپا (۱۳۹۴). «طراحی مدلی برای شناسایی احتمال وقوع دستکاری قیمت پایانی در بورس اوراق بهادار تهران». مهندسی مالی و مدیریت اوراق بهادار، ۶، ۱۵۲-۱۳۵.
- قربانی، مجید و عباس باقری (۱۳۸۷). «دستکاری بازار اوراق بهادار». پژوهش حقوق عمومی، ۱۲، ۳۲۶-۳۰۱.
- کاظمی تبار، سیدجواد و مجید شهباززاده (۱۳۹۸). «کشف تقلب در بازار بورس اوراق بهادار با استفاده از کاربرد نامساوی چیشف». فصلنامه پردازش علائم و داده‌ها. تهران.
- ندیری، محمد؛ علوی نسب، سید محمد؛ پیمانی، مسلم و ریحانه ربیعی (۱۳۹۷). «بررسی و تحلیل تأثیر برخی عوامل مؤثر بر دستکاری قیمت در بازار سهام ایران». تحقیقات مالی، تهران.
- یکه زارع، محمد مهدی (۱۳۹۸). «دستکاری قیمتی در معاملات حق تقدم در بورس تهران». پایان نامه کارشناسی ارشد، دانشگاه صنعتی شریف.
- حسن‌زاده سروستانی، علی؛ سیدنورانی، سید محمدرضا و فتح‌اله تاری (۱۴۰۳). «دستکاری قیمت در معاملات سهام عادی و تحلیل ممنوعیت نجش در برخی از مصادیق آن». تحقیقات مالی اسلامی.

- Aggarwal R.K. and G. Wu** (2006). "Stock market manipulations". *The Journal of Business*. 79(4): p. 1915-1953.
- Ahmed M., Choudhury N. & S. Uddin** (2017). "Anomaly detection on big data in financial markets". in 2017 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM). 2017. IEEE.
- Al-Thani H.A.** (2017). *Detecting market manipulation in stock market data*.
- Allen F. & D. Gale** (1992). "The Review of Financial Studies". *Stock-price manipulation*. 5(3): p. 503-529.
- Ben-David I. et al.** (2013). "Do hedge funds manipulate stock prices?", *The Journal of Finance*. 68(6): p. 2383-2434.
- Bhagwat R., Abdollahnejad M. & M. Moocarme** (2019). *Applied deep learning with keras: Solve complex real-life problems with the simplicity of keras*. Packt Publishing Ltd. Applied deep learning with keras: Solve complex real-life problems with the simplicity of keras
- Boynton W., Oppenheimer H.R. & S.F. Reid** (2009). "Japanese day-of-the-week return patterns: New results". *Global Finance Journal*. 20(1): p. 1-12.
- Brownlee J.** (2016). "Deep learning with Python: develop deep learning models on Theano and TensorFlow using Keras". *Machine Learning Mastery*.
- Cao Y. et al.** (2014). Detecting price manipulation in the financial market. in 2014 IEEE Conference on Computational Intelligence for Financial Engineering & Economics (CIFER). 2014. IEEE.
- Carhart M.M. et al.** (2002). Leaning for the tape: Evidence of gaming behavior in equity mutual funds. *The Journal of Finance*. 57(2): p. 661-693.
- Cherian J. & V. Kuriyan** (1995). Informationless manipulation in a market maker-type economy. Available at SSRN 6501.
- Cherian J.A. & R.A. Jarrow** (1995). *Market manipulation*. Handbooks in Operations Research and Management Science. 9: p. 611-630.
- Chollet F.** (2017). *Deep learning with Python*. 2017: Simon and Schuster.
- Comerton-Forde, C., Putniņš, T.J.,** (2011). "Measuring closing price manipulation". *Journal of Financial Intermediation*. 20(2): p. 135-158.
- Comerton-Forde C. & T.J. Putniņš** (2014). "Stock price manipulation: Prevalence and determinants". *Review of Finance*. 18(1), 23-66.
- Cumming D., Johan S., D. Li** (2011). "Exchange trading rules and stock market liquidity". *Journal of Financial Economics*. 99(3): p. 651-671.

- Cumming D. et al.** (2020). "Market manipulation and innovation". *Journal of Banking & Finance*. 120, 105957.
- Diaz D., Theodoulidis B. & P. Sampaio** (2011). "Analysis of stock market manipulations using knowledge discovery techniques applied to intraday trade prices". *Expert Systems with Applications*. 38(10), 12757-12771.
- Drakeford C.** (2020). *Market manipulation: definition approaches*, Haeward Law School.
- Durston G. J. & A. McKeon** (2020). *The little book of market manipulation: an essential guide to the law*, Waterside Press.
- Egginton J.F., Van Ness B.F. & R.A. Van Ness** (2016). "Quote stuffing". *Financial Management*. 45(3), 583-608.
- Ergün H.O. et al.** (2020). "Stock market manipulation in an emerging market of Turkey: how do market participants select stocks for manipulation?". *Applied Economics Letters*. 1-5.
- Felixson K. & A. Pelli** (1999). "Day end returns stock price manipulation". *Journal of Multinational Financial Management*. 9(2), 95-127.
- Ferdousi Z. & A. Maeda** (2006). *Anomaly Detection Using Unsupervised Profiling Method in Time Series Data*. in ADBIS Research Communications.
- Fischel D.R. & D.J. Ross** (1991). "Should the Law Prohibit Manipulation in Financial Markets?", *Harvard Law Review*. 105(2), 503-553.
- Géron A.** (2019). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. O'Reilly Media. Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems
- Golmohammadi K., Zaiane O.R. & D. Díaz** (2014). *Detecting stock market manipulation using supervised learning algorithms*. in 2014 International Conference on Data Science and Advanced Analytics (DSAA). 2014. IEEE.
- Golmohammadi K. & Zaiane** (2015). *O.R. Time series contextual anomaly detection for detecting market manipulation in stock market*. in 2015 IEEE International Conference on Data Science and Advanced Analytics (DSAA). 2015. IEEE.

- Goodfellow I.J. et al.** (2014). Generative adversarial networks. arXiv preprint arXiv:1406.2661. Generative adversarial networks
- Griffin J.M. & A. Shams** (2018). "Manipulation in the VIX?". *The Review of Financial Studies*. 31(4), 1377-1417.
- Hamann H.E.** (1982). "Merrill Lynch, Pierce, Fenner and Smith, Inc. v. Curran: Establishing an Implied Private Right of Action under the Commodity Exchange Act". *Pepp. L. Rev.* 10, 815.
- Hart O.D.** (1977). "On the profitability of speculation". *The Quarterly Journal of Economics*, 579-597.
- Hillion P. & M. Suominen** (2004). "The manipulation of closing prices". *Journal of Financial Markets*. 7(4), 351-375.
- Jarrow R.A.** (1992). "Market manipulation, bubbles, corners, and short squeezes". *Journal of financial and Quantitative Analysis*, 311-336.
- Kim Y. & S.Y. Sohn** (2012). "Stock fraud detection using peer group analysis". *Expert Systems with Applications*. 39(10), 8986-8992.
- Langr J. & V. Bok** (2019). *GANs in action: deep learning with generative adversarial networks*. Manning Publications.
- Leangarun T., Tangamchit P. & S. Thajchayapong** (2018). Stock Price Manipulation Detection using Generative Adversarial Networks in 2018 IEEE.
- Lee E.J., Eom K.S. & K.S. Park** (2013). "Microstructure-based manipulation: Strategic behavior and performance of spoofing traders". *Journal of Financial Markets*. 16(2). 227-252.
- Li A., Wu J. & Z. Liu** (2017). "Market manipulation detection based on classification methods". *Procedia Computer Science*. 122, 788-795.
- Mariani G. et al.** (2019). Pagan: Portfolio analysis with generative adversarial networks. arXiv preprint arXiv:1909.10578.
- Markham J.W.** (2002). A Financial History of the United States: From Christopher Columbus to the Robber Barons (1492-1900). Vol. 1. 2002: ME Sharpe.
- Markham J.W.** (2013). Law enforcement and the history of financial market manipulation. 2013: ME Sharpe.
- Neupane S. et al.** (2017). "Trade-based manipulation: Beyond the prosecuted cases". *Journal of corporate finance*. 42, 115-130.
- Öğüt H., Doğanay M.M. & R. Aktaş** (2009). "Detecting stock-price manipulation in an emerging market: The case of Turkey". *Expert Systems with Applications*. 36(9), 11944-11949.

- Phua C. et al.** (2010). A comprehensive survey of data mining-based fraud detection research. arXiv preprint arXiv:1009.6119.
- Prakash A., l'agriculture O.d.N.U.p.l.a.e.** (2011). Safeguarding food security in volatile global markets. 2011: Food and Agriculture Organization of the United Nations Rome.
- Putnins T.** (2020). *An Overview of Market Manipulation. Corruption and Fraud in Financial Markets Malpractice, Misconduct and Manipulation*. An Overview of Market Manipulation
- Roodposhti F.R., Shams M.F. & H. Kordlouie** (2011). "Forecasting stock price manipulation in capital market". *International Journal of Economics and Management Engineering*. 5(8), 957-967.
- Shah S., Ismail I. & A. Shahrin** (2019). "Stock market manipulation: A comparative analysis of East Asian emerging and developed financial markets". *Management Science Letters*. 9(1), 183-192.
- Siering M. et al.** (2017). "A taxonomy of financial market manipulations: establishing trust and market integrity in the financialized economy through automated fraud detection". *Journal of Information Technology*. 32(3), 251-269.
- Smith M.V.** (1980). Preventing the Manipulation of Commodity Futures Markets: To Deliver or Not to Deliver. *Hastings LJ*, 32, 1569.
- Takahashi S., Chen Y. & K. Tanaka-Ishii** (2019). "Modeling financial time-series with generative adversarial networks". *Physica A: Statistical Mechanics and its Applications*. 527, 121261.
- Tang T. W. et al.** (2020). "Anomaly detection neural network with dual auto-encoders GAN and its industrial inspection applications". *Sensors*, (12)20, 3336.
- Westphal C. & T. Blaxton** (1998). *Data mining solutions: methods and tools for solving real-world problems*. John Wiley & Sons, Inc.
- Zhang K. et al.** (2019). "Stock market prediction based on generative adversarial network". *Procedia computer science*. 147, 400-406.
- Zheng Y. J. et al.** (2018). "Generative adversarial network based telecom fraud detection at the receiving bank". *Neural Networks*. 102, 78-86.