مروری بر کاربرد مدل‌های بزرگ زبانی در پردازش متن و سری‌های زمانی در تحلیل رفتار سرمایه‌گذاران و پیش‌بینی بازارهای مالی

سعیده انبائی فریمانی[۱]، راهله قوچان‌نژاد نورنیا[۲] و مجید وفایی جهان[۳]*

دانش‌آموختهٔ دکترای گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران[۱]

پسادکتری گروه انفورماتیک پزشکی، دانشکدهٔ پزشکی، دانشگاه علوم پزشکی مشهد، مشهد، ایران[۲]

دانشیار گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران[۳*]

چکیده

استفادهٔ گسترده از شبکه‌های اجتماعی و انتشار اخبار در رسانه‌ها، حجم عظیمی از داده‌های متنی و سری‌های زمانی را تولید کرده‌است که بر رفتار سرمایه‌گذاران در بازارهای مالی تأثیر مستقیم می‌گذارد؛ در این میان، مدل‌های بزرگ زبانی و فناوری‌های پیشرفتهٔ پردازش سری‌های زمانی و زبان طبیعی نقشی کلیدی در جمع‌آوری، تحلیل و استخراج الگوهای پنهان از این داده‌ها ایفا می‌کنند. این مقالهٔ مروری، به بررسی بیش از دویست مرجع منتشرشده از سال ۲۰۰۶ تا ۲۰۲۴ می‌پردازد که به برهم‌کنش بازارهای مالی و وقایع خبری منتشرشده در وب با رویکرد متن‌کاوی متمرکزند. در این مطالعه، انواع منابع اطلاعاتی، روش‌های بازنمایی متن، تحلیل احساسات و مدل‌های پیش‌گو مورد بررسی قرار گرفته‌اند؛ همچنین، کاربرد مدل‌های بزرگ زبانی در پردازش سری‌های زمانی و تحلیل داده‌های بلادرنگ، به‌عنوان یکی از نوآوری‌های اخیر در این حوزه مورد توجه قرار گرفته است. هدف از این پژوهش، شناسایی مرز دانش در حوزهٔ تحلیل کلان‌داده‌ها و ارائهٔ مسیرهای آیندهٔ پژوهشی در زمینهٔ روش‌های متن‌کاوی، هوش مصنوعی و یادگیری عمیق برای توسعهٔ سامانه‌های پیش‌بینی، توصیه‌گر و تحلیل هم‌بستگی در بازارهای مالی نظیر بورس و فارکس است.

واژگان کلیدی: مدل‌های بزرگ زبانی، متن‌کاوی، تحلیل احساس، پیش‌بینی بازارهای مالی، اخبار، شبکه‌های اجتماعی.

Review on Large Language Models in Finance: Text and Time Series Analysis for Investor Behavior and Market Prediction

Saeede Anbaee Farimani[1], Raheleh Ghouchan Nezhad Noor Nia[2], Majid Vafaei Jahan[3*]

PhD Graduate, Department of Computer Software Engineering, Islamic Azad University, Mashhad Branch, Mashhad, Iran[1]

PostDoc, Department of Medical Informatics, Faculty of Medicine, Mashhad University of Medical Sciences, Mashhad, Iran[2]

Associate Professor, Department of Computer Software Engineering, Islamic Azad University, Mashhad Branch, Mashhad, Iran[3]

Abstract

The onset of social media venues, online news media, and digital content allowed a vast volume of text and time series data to be generated which plays significant role in investors' decision-making and financial market volatility. Data extracted from these platforms provide information on public sentiments, immediate reactions to news, and informal analyses, which, if processed appropriately, can be very useful indicators in forecasting financial market trends. Billions of dollars are invested and lost, depending on correct forecasting. However, advances in deep learning, especially in large language models (LLMs) and novel time series analysis algorithms, have opened new windows to processing and analyzing this complex data. The advanced language models identify hidden patterns and nonlinear dependencies, always taking into account the context and semantic details of the text between news,

* نویسندهٔ عهده‌دار مکاتبات

* Corresponding author

• تاریخ ارسال مقاله: ۱۴۰۰/۴/۲۷ • تاریخ پذیرش: ۱۴۰۴/۴/۲۹ • تاریخ انتشار: ۱۴۰۴/۶/۲۲ • نوع مطالعه: ترویجی

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-03]

[DOI: 10.61882/jsdp.22.2.109]

market sentiments, and price fluctuations, as well as utilizing them via intelligent market analysis systems. This review analyzes the existing research trends on the relationship of text data available on websites and social networks with the behavior of financial markets, having reviewed more than 200 scientific papers published between 2006 and 2024 in a systematic manner. This study focuses on identifying advanced methods within text representation, sentiment analysis, predictive modeling, and language model applications for analyzing real-time and unstructured data. More than one information source has to be taken into consideration: (Twitter, news agencies, blogs, and specialized forums) from a perspective of credibility, data structure, and influence-on market decisions. Given the complexity of financial markets, such as stocks and forex, there is an ever-increasing demand for hybrid models capable of carrying out analyses across time-series and text data simultaneously. This paper aims to analyze the current research accomplishments, identify gaps in the research, and ultimately put forward future directions for the fields of text mining, AI, and deep learning. These directions can open up the path for the next generation of real-time and adaptive recommender, predictor, and correlation analyzer systems in the financial markets.

Keywords: Large Language Models, Text Mining, Sentiment Analysis, Financial Market Prediction, News, Social Media.

۱-مقدمه

انقلاب مدل‌های زبانی بین سال‌های ۲۰۲۰ تا ۲۰۲۵، تحولی چشمگیر در پردازش متن و کاربردهای آن در حوزهٔ مالی ایجاد کرده‌است[۱, ۲]. مدل‌هایی مانند GPT-3 [۳] و-GPT 4با توانایی درک عمیق زبان و تحلیل داده‌های متنی به ابزارهای ضروری برای تحلیل احساسات بازار، استخراج اطلاعات از گزارش‌های مالی و تشخیص الگوهای غیرمعمول تبدیل شدند؛ از سوی دیگر، تحلیل داده‌های معاملاتی با هدف شناسایی رفتارهای غیرعادی، مانند سوءاستفاده از اطلاعات نهانی، نقشی کلیدی در افزایش شفافیت بازار و اعتماد سرمایه‌گذاران ایفا می‌کند[۴]. این فناوری به مؤسسات مالی کمک می‌کند تا فرایندهایی مانند مدیریت ریسک، پیش‌بینی روندهای اقتصادی و تعامل با مشتریان را بهینه‌سازی کنند؛ همچنین امکان خلاصه‌سازی خودکار اخبار اقتصادی و تولید گزارش‌های دقیق، کارایی بیشتری را به ارمغان آورد. دسترسی گسترده‌تر به این فناوری از طریق APIها و ابزارهای کاربرپسند، فرصت‌های جدیدی را برای شرکت‌های مالی و سرمایه‌گذاران فراهم خواهد کرد. این مدل‌ها به بخشی اساسی از زیرساخت‌های دیجیتال در صنعت مالی تبدیل خواهند شدند و نحوهٔ تحلیل داده‌ها و تصمیم‌گیری‌های مالی را دگرگون می‌کند.

معماری ترانسفورمرها یکی از انقلابی‌ترین پیشرفت‌های در حوزهٔ پردازش زبان طبیعی (NLP) شناخته می‌شود و نقش محوری در تحول سامانه‌های هوش مصنوعی برای درک و تحلیل متون ایفا می‌کند. این معماری با معرفی سازوکار توجه [۵] و قابلیت موازی‌سازی بالا، امکان آموزش مدل‌های بزرگ و دقیق‌تری را فراهم می‌کند که قادرند الگوهای پیچیده در داده‌های متنی را شناسایی کنند؛ همچنین، تحلیل آماری محتوای فایل‌ها با استفاده از مدل n-gram و ویژگی‌هایی مانند آنتروپی و خودهم‌بستگی نشان داده‌است که این روش‌ها در شناسایی ساختار داده‌ها و تحلیل محتواهای متنی و غیرمتنی نیز مؤثرند[۶]. در حوزهٔ تحلیل اخبار و رسانه‌ها در بازارهای مالی، این پیشرفت‌ها کاربرد گسترده‌ای پیدا کرده‌اند. در کاربردهای تحلیل بازارهای مالی، از روش‌های پردازش متن مبتنی بر ترانسفورمرها استفاده می‌شود تا اخبار مالی، گزارش‌های شرکتی و حتی توییت‌های تأثیرگذار به‌صورت خودکار تحلیل شوند[۷-۹] و احساسات بازار [۱۰-۱۲]، رویدادهای مهم و روندهای نوظهور [۱۳-۱۵] شناسایی شوند. این توانایی به تحلیل‌گران و سرمایه‌گذاران کمک می‌کند تا تصمیمات سریع‌تر و دقیق‌تری بگیرند، از فرصت‌های سرمایه‌گذاری استفاده کنند و از ریسک‌های بالقوه جلوگیری کنند؛ بنابراین، معماری ترانسفورمرها نه‌تنها در پردازش متن انقلابی ایجاد کرده، بلکه درک عمیق‌تری از داده‌های متنی در حوزه‌های حساس مانند بازارهای مالی فراهم می‌کند[۱, ۲, ۱۶].

در مرور انجام‌شده بیش از دویست مرجع[۱] از سال ۲۰۰۶ تا پایان ۲۰۲۴[۲] بررسی شده‌است. با گسترش استفاده از مدل‌های مبدل در پردازش متن، دستهٔ بزرگی از روش‌ها در حوزهٔ اقتصاد رفتاری از بازنمایی برداری مبتنی بر مدل‌های بزرگ زبانی برای بررسی تأثیر اخبار بر بازار استفاده کرده‌اند[۵، ۱۷، ۱۸]. دسته‌ای از روش‌ها در این حوزه به بهسازی[۳] مدل‌های پیش‌آموزش‌دیده برای کاربرد تحلیل احساس اخبار اقتصادی پرداخته‌اند[۱۹-۲۱]. دستهٔ دیگری از روش‌ها از ترانسفورمرها برای تحلیل احساس اسناد خبری و

[۱] جهت بررسی دویست مرجع مورد بررسی در این مقاله به فایل متنی بارگذاری‌شده در پیوند مراجعه فرمایید:
https://drive.google.com/file/d/1nL9ZYil68-4sUwJjOY0SKVQRRxJnHptA/view?usp=sharing

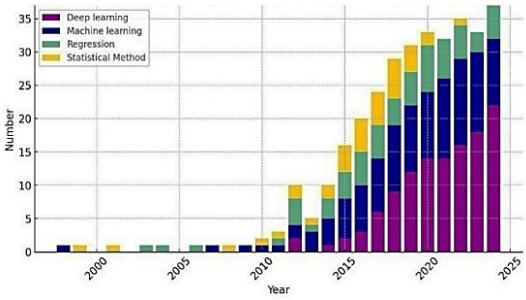
[۲] جهت مطالعه دویست مقاله مورد بررسی در این مقاله، به فایل اکسل بارگذاری‌شده در پیوند مراجعه فرمایید:
https://docs.google.com/spreadsheets/d/1LFCjCdT-TjwJh-qsb56I0PBstyTrnwYd/edit?usp=sharing&ouid=105052381409857963471&rtpof=true&sd=true

[3] finetune

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-03]

[DOI: 10.61882/jsdp.22.2.109]

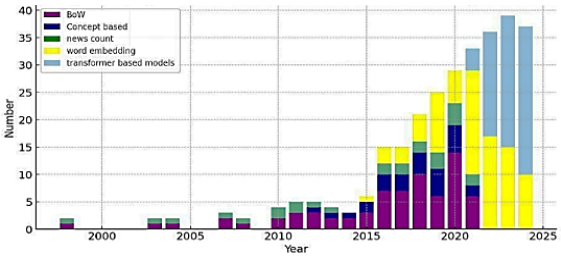
پیش‌بینی بازارهای مالی استفاده کرده‌اند[۱۰، ۲۲]. دستهٔ دیگری از روش‌ها از مدل‌های بزرگ زبانی برای پیش‌بینی بازارهای مالی استفاده کرده‌اند؛ همچنین دسته‌ای از روش‌ها با استفاده از مدل‌های زبانی بزرگ در پردازش سری‌های زمانی، به پیش‌بینی و تحلیل سرمایه‌های مختلف پرداخته‌اند. (شکل-۱): پراکندگی روش‌های پیش‌گوی مورد استفاده در مقالات مرورشده را نشان می‌دهد. روند روبه‌رشد پژوهش‌های مبتنی بر روش‌های یادگیری عمیق به خوبی نشان‌دهندهٔ این مطلب است.



(شکل-۱): پراکندگی روش‌های پیش‌گوی مورد استفاده در مقالات مرورشده

(Figure-1): Distribution of predictive models used in the reviewed paper

تاریخچهٔ نخستین پژوهش‌ها در حوزهٔ تحلیل بازارهای مالی به روش پیشنهادی کوتلر[1] در سال ۱۹۸۸ بر می‌گردد که می‌توان آن را از نخستین پژوهش‌ها با رویکرد تحلیل فنی در بررسی تأثیر اخبار بر بازار بورس دانست[۲۳]. این پژوهش با رویکرد تحلیل فنی به بررسی میزان تغییر در بازگشت سهام[2] تحت تأثیر انتشار اخبار با موضوع‌های مختلف پرداخته است. تا پیش از ارائهٔ معماری ترانسفورمر، در تحلیل‌ها بیشتر از تعداد اخبار، گزارش‌های دارای ساختار منابع بین‌المللی نظیر بانک جهانی استفاده می‌شد و یا تحلیل اخبار توسط یک خبرهٔ انسانی انجام می‌گرفت[۲۷-۲۴]؛ درحالی‌که با تحول مدل‌های مبتنی بر ترانسفورمر، تحلیل‌های بنیادین جدید بر استفاده از روش‌های یادگیری عمیق و مدل‌های زبانی بزرگ در پردازش متن و پردازش سری‌های زمانی متکی هستند.



(شکل-۲): نمودار پراکندگی روش‌های سازمان‌دهی به متن و سری‌های زمانی در منابع مرورشده

(Figure-2): Distributiotext and time series representation methods used in the reviewed paper

[1] David M. Cutler
[2] Stock Return

همچنین روند روبه‌رشد استفاده از مدل‌های زبانی مبتنی بر ترانسفورمر در بازنمایی متن و تحلیل سری‌های زمانی و پردازش متن در نمودار (شکل-۲) قابل مشاهده است.

بنیان این مرور در بخش دوم بر بررسی منابع داده‌ای مورد استفاده در مراجع مرورشده استوار است؛ سپس، در بخش سوم به معرفی روش‌های استخراج اطلاعات از این منابع داده‌ای نظیر تحلیل احساس، مدل‌های پیش‌گو و روش‌های تحلیل رفتار سرمایه‌گذاران پرداخته است. بخش چهارم با هدف آشنایی خواننده با کاربردهای مدل‌های زبانی بزرگ در اقتصاد رفتاری به معرفی مدل‌های بزرگ زبانی در دو حوزهٔ پردازش متن و پردازش سری‌های زمانی مالی اختصاص یافته است. نتیجه‌گیری و زمینه‌های باز پژوهشی پیش‌رو در بخش پنجم بیان شده‌است.

۲- منابع داده‌ای

مرور انواع داده‌هایی که پژوهشگران برای آموزش و ارزیابی مدل‌های زبانی در تحلیل رفتار سرمایه‌گذاران و پیش‌بینی بازارهای مالی مورد استفاده قرار می‌دهند. با طبقه‌بندی این داده‌ها، درک بهتری از روندهای موجود و چالش‌های مرتبط با آن فراهم می‌شود.

۲-۱-بازارهای مالی

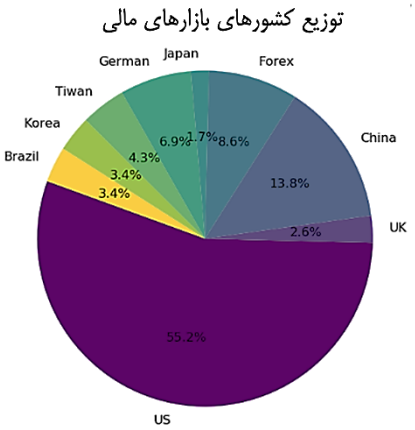
بر اساس نظریهٔ بازار کارآمد[3] که در سال ۱۹۶۵ توسط فاما[4] مطرح شد، قیمت سرمایه منعکس‌کنندهٔ تمام اطلاعات در دسترس راجع به آن سرمایه است. این مسئله امری طبیعی است؛ زیرا با انتشار اطلاعات جدید در اخبار و رسانه‌های اجتماعی، و واکنش بازار نسبت به آن، سبب تغییر قیمت سرمایه خواهد شد و بازار مداوم بر مبنای ریسک سرمایه‌گذاران تغییر نمی‌کند[۲۸]. بازارهای مالی به سه دستهٔ اصلی تقسیم می‌شوند: بازارهای پول که شامل ابزارهای کوتاه‌مدت و نقدشونده مانند اوراق خزانه است، بازارهای سرمایه که در آن دارایی‌های بلندمدت مانند سهام شرکت‌های بزرگ در شاخص S&P 500 معامله می‌شوند، و بازارهای فارکس که محل تبادل ارزها مانند جفت ارز EUR/USD است؛ همچنین، بازارهای دیجیتال مانند ارزهای رمزنگاری‌شده نیز به‌عنوان بخشی از بازارهای مالی نوین، فرصت‌های جدیدی برای سرمایه‌گذاری ایجاد کرده‌اند. هر یک از این بازارها نقش منحصر به فردی در اقتصاد جهانی دارند.

در میان پژوهش‌های انجام‌شده، بازارهای مالی متفاوتی مورد بررسی قرار گرفته‌اند. در هر کدام از بازارهای مالی نوع خاصی از سرمایه دادوستد

[3]. Efficient Market Hypothesis
[4] Eugene Fama

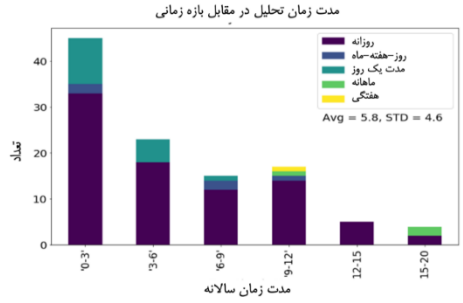
[Downloaded from jsdp.rcisp.ac.ir on 2026-11-03]
[DOI: 10.61882/jsdp.22.2.109]

می‌شود[۲۹]؛ برای مثال، می‌توان از بازار بورس Standard & Poor's 500 که به طور خلاصه آن را S&P 500 می‌نامند و متشکل از سهام پانصد شرکت بزرگ در آمریکا است نام برد و شرکت‌هایی نظیر مایکروسافت و اپل[1] در این فهرست قرار دارند. در بازار تبادل خارجی فارکس به مبادلهٔ پول بر اساس انواع جفت‌ارزهای خارجی مانند نسبت یورو به دلار[2] پرداخته می‌شود. (شکل-۳) پراکندگی روش‌ها بر اساس بازار مالی مورد مطالعه را نشان می‌دهد.



(شکل-۳): انواع بازارهای مالی مورد مطالعه در منابع مرورشده
(Figure-3): Distribution of market countries in literature

بیشتر مقالات واکنش سرمایه‌گذاران بازارهای مالی را در برش زمانی روز و به طور متوسط در یک بازه سه ساله مطالعه کرده‌اند؛ (شکل-۴): **نمودار پراکندگی روش‌ها بر اساس بازه زمانی مورد بررسی)** نمودار پراکندگی روش‌ها بر اساس بازه زمانی مورد بررسی را نشان می‌دهد.



(شکل-۴): نمودار پراکندگی روش‌ها بر اساس بازه زمانی مورد بررسی
(Figure-4): Distribution of methods per period of analysis

۲-۲-رسانه‌های اجتماعی و اخبار

اخبار، داده‌های شبکه‌های اجتماعی نظیر توییتر، آمار جست‌وجوهای برخط در موتورهای جست‌وجو، آمار مراجعه به صفحات ویکی‌پدیا[3] و همچنین بوردهای تخصصی گفت‌وگو در بورس نظیر سینا[4]، انواع منابع داده-ای هستند که از طریق اینترنت در اختیار سرمایه‌گذاران قرار می‌گیرند. در میان روش‌های بررسی‌شده برخی تنها از یک منبع داده‌ای استفاده کرده‌اند.

هم‌زمان با وقوع یک رویداد خبری، آمار مراجعه به صفحات ویکی‌پدیا و تعداد جست‌وجوها در گوگل با واژگان کلیدی مرتبط با آن رویداد بیشتر می‌شود و افراد به بیان نظرات خود در شبکه‌های اجتماعی می‌پردازند[۳۰]؛ لذا اخبار، داده‌های متنی موجود در شبکه‌های اجتماعی و همچنین روند بازارهای مالی به‌عنوان منابع داده‌ای مهم شناخته می‌شوند. در روش پیشنهادی [۳۰] برای بهبود دقت پیش‌بینی یک پایگاه دانش[5] از منابع داده‌ای مختلف نظیر تعداد دفعات بازدید از صفحات ویکی‌پدیا مرتبط با سهام شرکت اپل از تارنمای WikipediaTrends.com، حجم اطلاعات برخط تولیدشده از قبیل اخبار و نظرات افراد در google News راجع به کمپانی اپل، شاخص‌های فنی متداول در بورس مانند قیمت بستن[6] از تارنمای yahoo finance و شاخص‌های مالی فنی[7] نظیر RSI , LW و سایر تشکیل شده‌اند.

در روش پیشنهادی [۳۱] از ترکیبی از داده‌های شبکهٔ اجتماعی، اخبار و داده‌های بورس چین برای پیش‌بینی قیمت سهام در بورس شانگهای استفاده شده‌است. در روش پیشنهادی [۳۲] از ترکیب داده‌های بورس، گوگل ترند[8] و تحلیل احساس اخبار برای پیش‌بینی سهام اپل استفاده شده‌است. در روش پیشنهادی [۳۳] یک فرهنگ لغات از واژه‌های مربوط به کمپانی‌های بورس سهام نیویورک[9] از اخبار منتشرشده در تارنمای YAHOO Finance در بازه ۲۰۱۲ تا ۲۰۱۶ استخراج شده‌است.

۳- روش‌های استخراج اطلاعات

۳-۱-تحلیل احساس

تحلیل احساسات با استفاده از مدل‌های ترانسفورمر به‌دلیل توانایی برجستهٔ آن‌ها در پردازش زبان طبیعی و استخراج ویژگی‌های پیچیدهٔ متن، به ابزاری کلیدی در حوزه‌های مختلف از جمله پیش‌بینی روندهای مالی تبدیل شده‌است. این مدل‌ها به‌ویژه در ترکیب با تکنیک‌های fine-tuning، عملکرد برتری نسبت به سایر روش‌های سنتی ارائه داده‌اند. در مقالات [۳۴،۳۵]، نویسندگان به بررسی مسئلهٔ پیش‌بینی روند پرداخته و نشان داده‌اند که تحلیل احساسات مبتنی بر مدل ترانسفورمر عملکرد

[1] Apple
[2] EUR/USD
[3] Wikipedia
[4] Sina Wibo

[5] Knowledge Based
[6] Close Price
[7] Indicators
[8] Google Trends
[9] NewYork Stock Exchange

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-03]
[DOI: 10.61882/jsdp.22.2.109]

بهتری نسبت به سایر روش‌های بازنمایی متن ارائه می‌دهد؛ همچنین، پژوهش‌گران در مطالعات [۹, ۳۶] از یک نسخهٔ بهسازی‌شده BERT برای تحلیل احساسات مالی (FSA) استفاده کرده‌اند که این مدل بر پایهٔ یک مجموعه‌دادهٔ خبری دسته‌بندی‌شده به‌صورت دستی برای حل مسئلهٔ پیش‌بینی آموزش‌داده‌شده است. FinBERT [۲۱]، نیز یک مدل زبانی ترانسفورمر مبتنی بر BERT است که به‌طور خاص برای تحلیل احساسات در حوزهٔ مالی تنظیم و بهینه‌سازی شده‌است. با توجه به ماهیت متفاوت اخبار و پست‌ها در شبکه‌های اجتماعی تحلیل احساس بازارهای مالی در دو حوزهٔ اخبار و رسانه‌های اجتماعی جداگانه بررسی می‌شود.

۳-۱-۱- تحلیل احساس اخبار

در حوزهٔ تحلیل احساسات، توسعهٔ FinSoSent [۱۰]، یک مدل زبانی بزرگ مرتبط با حوزهٔ مالی که روی اخبار مالی پیش‌آموزش‌دیده و روی مجموعه‌داده‌های رسانه‌های اجتماعی مالی تنظیم دقیق شده‌است، نمونه‌ای از کاربرد مؤثر منابع داده‌های چندحالته شامل اخبار مالی، شاخص‌های فنی و پست‌های رسانه‌های اجتماعی برای بهبود تحلیل احساسات است. استفاده از مدل‌های هوش مصنوعی مولد مانند GPT-3.5 برای پردازش متن نیز نشان‌دهندهٔ مزایای درک زمینه‌ای و مقابله با چالش‌های مرتبط با واژگان خاص حوزهٔ مالی است[۱۰].

روش پیشنهادی [۳۷] که در سال ۲۰۱۵ با استفاده از روش مبتنی بر فرهنگ لغات به پیش‌بینی بورس بر اساس تحلیل احساس و داده‌های مالی پرداخته است از دو فرهنگ لغت Harvard psychological dictionary و Loughran–McDonald استفاده کرده‌اند. روش پیشنهادی [۳۸] با ارائهٔ یک روش مبتنی بر یادگیری ماشین به استخراج یک پیکره از واژگان دارای برچسب بر اساس فرکانس تکرار در اخبار برچسب‌گذاری‌شده بر اساس مدل پیش‌گوی GARCH پرداخته است. در این روش اخبار به دو دستهٔ جذاب و غیرجذاب دسته‌بندی شده‌اند. آن‌ها با درنظرداشتن سری زمانی نوسان با استفاده از مدل پیش‌گوی GHARCH پیش‌بینی بازار را برای لحظهٔ بعد انجام داده‌اند؛ درصورتی‌که تفاوت بیشتر از حد آستانه بین مقدار واقعی و پیش‌بینی‌شده وجود داشته باشد، به اخباری که چند دقیقه قبل از این برش زمانی منتشر شده‌اند، برچسب جذاب داده شده و بدین صورت یک مجموعه‌دادهٔ دارای برچسب از اخبار تشکیل شده‌است. روش پیشنهادی [۳۹] با ارائهٔ یک روش تحلیل احساس مبتنی بر فرهنگ لغات، سعی در شناسایی احساس‌های صریح و ضمنی در متون خبری اقتصادی وابسته به چند شرکت هلندی داشته‌اند. در روش پیشنهادی [۴۰]، به تحلیل احساس متون خبری بر اساس نقش معنایی واژگان در عنوان خبر پرداخته شده‌است. در فرایند استخراج ویژگی از عناوین خبری پس از پیش‌پردازش‌های متداول، تنها واژگانی استخراج شده‌اند که به همان شکل در آنتولوژی وردنت وجود داشته‌اند و مترادف آن‌ها نیز به مجموعه ویژگی‌ها افزوده شده‌است. در روش پیشنهادی [۴۱]، دسته‌بندی متون خبری به سه دستهٔ مثبت، منفی و خنثی به روش مبتنی بر فرهنگ لغت[1] و روش کاوش قواعد انجمنی[2] انجام گرفته است؛ در این روش به واژگان بعد از تعیین نقش نحوی به‌کمک ابزار porterStemmer شش نوع برچسب یا شاخص کارایی اختصاص می‌یابد و سپس با استفاده از روش کاوش قواعد انجمنی طبقه‌بندی انجام گرفته است. روش پیشنهادی [۴۲] یک فرهنگ لغات دارای بار احساسی چندزبانه از پیکرهٔ متنی چندزبانه‌ای در حوزهٔ اقتصادی ساخته است. روش پیشنهادی [۴۳] با بیان این نکته که بیشتر افراد علاوه‌بر توجه به‌عنوان خبر در بخش‌هایی از متن خبر نیز به دنبال اطلاعات مورد نیاز خود می‌گردند با بیان یک رابطهٔ ریاضی بخش‌های جذاب از متن و عنوان خبر را استخراج کرده و سپس به تحلیل احساس آن‌ها پرداخته است. در روش [۴۴]، علاوه‌بر فرایند تحلیل احساس اخبار به دو دستهٔ مثبت و منفی، برای هر خبر منبع انتشار آن خبر و نقطه نظر مربوط به آن نیز بررسی شده‌است. منبع خبر می‌تواند یکی از چهار دستهٔ (رسانهٔ دولتی مرکزی، رسانهٔ دولتی محلی، رسانهٔ غیر دولتی و رسانه‌های اقتصادی چینی) باشد و برای هر خبر تحلیل آن از نقطه نظر دانشگاهی، دولتی و صنعت نیز وجود دارد. روش‌های [۴۵،۴۶]، علاوه‌بر تحلیل احساس اخبار از ویژگی‌هایی نظیر میزان ارتباط هر خبر به هر کدام از شرکت‌های صاحب سهام و میزان جدیدبودن آن خبر نیز استفاده کرده‌اند.

۳-۱-۲- تحلیل احساس داده‌های شبکهٔ اجتماعی

از جمله ویژگی‌های رسانه‌های اجتماعی حجم داده‌ها و سرعت بالای تولید آن‌ها، وجود نوفهٔ زیاد در نگارش متن پیام‌های منتشرشده، ابهام در احساس بیان‌شده در جملات، خلوت‌بودن ماتریس ویژگی‌ها و پویابودن نظرات

[1] Dictionary Based
[2] ARM

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-03]
[DOI: 10.61882/jsdp.22.2.109]

در زمان است. در هر کدام از پژوهش‌های زیر به بخشی از این چالش‌ها توجه شده‌است. روش پیشنهادی [۴۷] که تاکنون بیش از هزار ارجاع به آن شده‌است، به بررسی تأثیر توییتر بر سرمایه‌گذاران پرداخته است. آن‌ها توییت‌ها را با استفاده از ابزارهای Opinion Finder و GPOMS به ترتیب به دو و شش سطح احساس دسته‌بندی کرده‌اند؛ سپس با استفاده از تست علیت گرنجر[1] به بررسی هم‌بستگی متقابل[2] بین سری زمانی احساس‌های استخراج‌شده و بازگشت در بازار پرداخته‌اند. روش پیشنهادی [۴۸] از تگ‌های بیان‌کنندهٔ احساس نظرات افراد در توییتر استفاده کرده‌است و به بررسی هم‌بستگی بین تگ‌هایی نظیر ترس، اضطراب، خوشحالی و روند سهام DOW Jones، S&P 500 و NASDAQ پرداخته است. نتایج آن‌ها نشان می‌دهد سرمایه‌گذاران در زمانی که عدم قطعیت وجود دارد بیشتر از داده‌های احساسی استفاده می‌کنند. روش پیشنهادی [۴۹] با درنظرگرفتن حجم زیاد داده‌های مربوط به شبکه‌های اجتماعی، با ارائهٔ یک روش جدید در تجزیهٔ ماتریس‌ها برای غلبه بر مشکل فضای خلوت[3] سعی در مدل‌سازی تأثیر نظرات کاربران در بازگشت در سهام S&P 500 داشته است.

در روش پیشنهادی [۵۰]، یک روش با نظارت تحلیل احساس با استفاده از ویژگی‌های لغوی و معنایی استخراج‌شده از عناوین خبری و داده‌های شبکهٔ اجتماعی ارائه داده‌است. در این روش برچسب عددی پیوسته در بازه [1,1-] است. آن‌ها از یک روش تخمین هم‌بستگی واژگان با هر سند برای تعیین قطبیت[4] اسناد مجموعهٔ آموزشی استفاده کرده‌اند. در روش پیشنهادی [۵۱]، به بررسی پویای نظرات سرمایه‌گذاران در زمان پرداخته شده‌است. در این روش، نظرات در هر لحظه به نظر و احساس سرمایه‌گذاران در برش زمانی پیشین وابسته در نظر گرفته شده‌اند. جهت پیش‌بینی بازگشت در بورس از دو دسته داده‌های مالی مربوط به بازار و تحلیل احساس نظرات کاربران YahooFinance استفاده شده‌است.

۳-۲- سامانه‌های پیش‌گو

در چند دههٔ گذشته، طیف گسترده‌ای از مدل‌های پیش‌بینی به تحلیل پرتفوی‌های مختلف پرداخته‌اند. این روش‌ها با استفاده از فنون یادگیری ماشین، یادگیری عمیق و همچنین مدل‌های زبانی بزرگ به پیش‌بینی آیندهٔ بازار بر اساس داده‌های چندحالته[5] مانند اخبار و پارامترهایی نظیر بازگشت در بورس، قیمت و یا حجم معاملات پرداخته‌اند.

۳-۲-۱- روش‌های مبتنی بر یادگیری عمیق

با ظهور و گسترش شبکه‌های یادگیری عمیق، به‌ویژه شبکه‌های کانولوشنی و بازگشتی، روش‌های متعددی توسعه یافته‌اند[۵۲، ۵۳]. پیشرفت‌های اخیر شامل به‌کارگیری سازوکارهای توجه برای بهبود استخراج ویژگی‌های کلیدی در طول زمان بوده‌است[۵۴-۵۷]. مطالعات اخیر بر ادغام انواع مختلف داده‌ها برای بهبود عملکرد پیش‌بینی تمرکز کرده‌اند؛ برای مثال، لی و همکاران [۵۸] روشی ارائه کردند که داده‌های قیمت سهام در بازه‌های زمانی روزانه، ماهانه و هفتگی را با شاخص‌های کلان اقتصادی ترکیب می‌کند و نشان می‌دهند که این رویکرد دقت پیش‌بینی را نسبت به مدل‌های تک‌حالته بهبود می‌بخشد. این رویکرد کارایی ترانسفورمر چندحالته برای دسته‌بندی جهت حرکت سهام را برجسته می‌کند. به‌طور مشابه، گانگ وانگ و همکاران [۵۹]، روش RCMA را توسعه دادند که یک مدل یادگیری عمیق مبتنی بر توجه است و داده‌های مالی و متنی را برای بهبود تشخیص تقلب در حوزهٔ مالی ادغام می‌کند که نشان‌دهندهٔ فواید بالقوه ادغام داده‌های چندحالته در شناسایی فعالیت‌های مالی مشکوک است.

یکی دیگر از دستاوردهای مهم در حوزهٔ ادغام چندحالته توسط فریمانی و همکاران [۷] ارائه شده که در آن یک روش یادگیری عمیق چندحالته مبتنی بر توجه برای رگرسیون قیمت بازار مالی توسعه یافته است. این روش دو نوع دادهٔ مالی و متنی را ادغام می‌کند تا قابلیت رگرسیون را افزایش دهد. این رویکرد ضمن برجسته‌کردن پتانسیل ادغام داده‌های چندحالته، نقش استراتژی نرمال‌سازی را نیز برای بهبود پیش‌بینی در بازارهای آشفته تأکید می‌کند.

روش پیشنهادی [۶۰]، با استفاده از روش یادگیری تقویتی به پیش‌بینی بر اساس اخبار پرداخته است. روش‌های [۳۱، ۶۴-۶۱] از حافظهٔ طولانی کوتاه‌مدت[6] [۶۵،۶۶] برای پیش‌بینی بر اساس اخبار و قیمت در بازار بورس استفاده کرده‌اند.

۳-۲-۲. روش‌های مبتنی بر یادگیری ماشین

روش پیشنهادی [۶۷] در سال ۲۰۰۷ را می‌توان از نخستین روش‌های پیش‌گو با رویکرد متن‌کاوی دانست که به تحلیل فرکتال بازار تحت تأثیر اخبار خوب و بد پرداخته است. تحلیل احساس اخبار با Openion Finder انجام شده‌است؛ سپس با استفاده از شاخصی که بر روی

[1] Granger Causality
[2] Cross Correlation
[3] Sparsity
[4] Polarity
[5] Multimodal
[6] LSTM

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-03]
[DOI: 10.61882/jsdp.22.2.109]

تحلیل احساس تعریف شده‌است بعد فرکتال محاسبه می‌شود و بر این اساس از آریما[1] برای پیش‌بینی استفاده شده‌است. در روش پیشنهادی شی[2] و همکاران [۴۶] به بررسی میزان تأثیر جریان اطلاعات روی بازگشت سهام S&P100 stocks برای بازه ۲۰۰۰ تا ۲۰۱۰ به‌صورت ساعتی پرداخته است. اخبار از مجموعه‌دادهٔ RavenPack News Analytics Database استخراج شده‌است. در این مجموعه‌داده اخبار علاوه‌بر دارابودن برچسب مثبت یا منفی دارای چند برچسب دیگر نظیر رتبهٔ میزان ارتباط خبر به هر شرکت[3]، رتبهٔ احساس هر خبر[4]، رتبهٔ جدیدبودن یک خبر[5] و رتبه‌ای که با استفاده از روش‌های مختلف تحلیل احساس برای یک خبر به‌دست آمده‌است[6]، نیز هستند. در روش پیشنهادی [۶۸] پیش‌بینی بازگشت در بورس به‌صورت روزانه با توجه به تحلیل احساس روی اخبار با درنظرگرفتن یک گروه‌بندی بر شرکت‌ها انجام و از مجموعه‌دادهٔ LexiNexis برای اخبار استفاده شده‌است.

در روش پیشنهادی [۶۹] به بررسی و تحلیل احساس مبتنی بر فرهنگ لغات داده‌های شبکهٔ اجتماعی www.psychsignal.com در بازگشت و حجم معاملات در بازار سهام پنج شرکت معروف و در تایم فریم دو دقیقه پرداخته شده و از یک مدل رگرسیونی برای پیش‌بینی استفاده شده‌است. نوآوری روش پیشنهادی [۷۰] معرفی یک شاخص آماری به نام شاخص تجمعی احساس اخبار[7] به نام ANSI بوده‌است. این شاخص برای سهام هر شرکت با توجه به تحلیل احساس اخبار همان شرکت برای هر روز/هفته/ ماه محاسبه شده‌است. برای شرکت‌های بزرگ که تأثیر بیشتری بر بازار دارند، وزن بیشتری اختصاص داده‌است. تأثیر این شاخص بر حجم معاملات و بازگشت به‌صورت روزانه هفتگی و ماهانه بررسی شده‌است.

در این دسته روش‌ها از معیارهایی نظیر صحت[8]، دقت و recall و همچنین میانگین دو پارامتر دقت و recall تحت عنوان معیار F1 استفاده شده‌است[۴۰]. در دستهٔ دیگری از روش‌های مورد مطالعه با درنظرگرفتن یک توزیع پیوسته روی داده‌ها، از روش‌های رگرسیونی روی داده‌ها برای پیش‌بینی استفاده شده و معیار مورد استفاده برای ارزیابی روش، معیار متوسط خطای مطلق[9] و یا مجذور خطای مطلق متوسط[10] است.

[1] ARIMA
[2] Shi
[3] Relevance Score (REL)
[4] Event Sentiment Score (ESS) رتبه‌ای بین صفر تا صد از میزان مثبت یا منفی‌بودن یک خبر.
[5] Event Novelty Score (ENS) رتبه‌ای بین صفر تا صد میزان جدیدبودن خبر را در ۲۴ ساعت گذشته تعیین می‌کند.
[6] Composite Sentiment Score (CSS) بین صفر تا صد، کمتر از پنجاه منفی و بیشتر از آن مثبت تلقی می‌شود.
[7] Aggregate News Sentiment Index
[8] Accuracy

۳-۳- سامانه‌های توصیه‌گر تجاری

سامانه‌های پیشنهاددهنده یکی از عنوان‌های داغ پژوهشی در حوزهٔ اقتصاد هستند که با پیشنهاد پرتفوی معاملاتی به سرمایه‌گذاران در جهت کسب سود بیشتر و جلوگیری از زیان کمک می‌کنند. روش پیشنهادی [۷۱] یک سامانهٔ پیشنهاددهندهٔ استراتژی تجارت طراحی کرده‌است که همیشه فهرستی از پرفروش‌ترین و پرخریدترین را با الگوریتم RankNet و ListNet بر اساس تحلیل احساس اخبار سهام‌ها در اختیار سرمایه‌گذاران قرار می‌دهد. در روش پیشنهادی [۷۲] یک سامانهٔ پیشنهاددهندهٔ استراتژی تجارت بر اساس تحلیل احساس اخبار در بازهٔ زمانی پنج دقیقه‌ای با استفاده از یک ابزار تجاری ارائه شده‌است. در روش پیشنهادی [۷۳] بر اساس اخبار یک استراتژی کوتاه‌مدت خرید-فروش با استفاده از روش یادگیری ماشین جنگل تصادفی[11] پیشنهاد می‌شود. در روش پیشنهادی [۷۴] با استخراج جامعه‌ای از سرمایه‌گذاران شناخته‌شده از توییتر، یک روش پیشنهاد استراتژی تجارت بر اساس اخبار و توییت‌ها با معرفی دو شاخص فنی بر اساس تحلیل احساس اخبار و توییتر ارائه شد. در روش پیشنهادی [۷۵] یک سامانهٔ پیشنهاددهندهٔ سرمایه‌گذاری بر اساس تحلیل احساس داده‌های شبکهٔ اجتماعی سرمایه‌گذاران گوبا[12] در بورس چین ارائه شده‌است. پژوهش‌گران با استفاده از روش متداول مبتنی بر فرهنگ لغت یک شاخص توافق برای هر سهام در هر زمان فریم بر اساس تعداد نظرات مثبت و منفی تعریف کرده‌اند. نتایج این پژوهش نشان می‌دهد بین روند بازار سهام و شاخص احساس یک هم‌بستگی مثبت وجود دارد، احساس منفی طولانی مدت خبر از وقوع یک نزول در بازار می‌دهد.

۳-۳-۱- تحلیل رفتار سرمایه‌گذاران

در روش‌های تحلیل رفتار بیشتر به تحلیل رابطهٔ علّی و یا هم‌بستگی بین مقدار بازگشت یک سرمایه با انتشار رویدادها در اخبار و رسانه پرداخته شده‌است؛ برای، در مطالعهٔ [۷۶]، یک مدل ریاضی برای تحلیل نوسانات بازار فارکس در بازه زمانی پنج دقیقه‌ای ارائه شده‌است که نشان می‌دهد مدل با نوفه ضربی می‌تواند پویایی‌های بازار تحت تأثیر اخبار مهم را شبیه‌سازی کند. در مطالعهٔ [۷۷]، با استفاده از روش رگرسیون، تأثیر اخبار بر حجم معاملات و نوسانات در بازار NYSE بررسی شده و مشخص

[9] Mean Absolute Error
[10] Root Mean Squared Error
[11] Random Forest
[12] Guba

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-03]
[DOI: 10.61882/jsdp.22.2.109]

شده‌است که کشف قیمت مرتبط با اخبار از طریق معاملات نهادی قبل از تاریخ اعلام خبر رخ می‌دهد؛ همچنین، در مطالعهٔ [۷۸] بدون تحلیل احساسات، واکنش بازار سهام ایالات متحده به اخبار اقتصاد کلان بررسی شده و نتایج نشان داده‌است که بازار به اخبار منفی واکنش شدیدتری نشان می‌دهد؛ در حالی که اخبار مثبت تأثیر کمتری دارند.

در مطالعات دیگر، تمرکز بیشتر بر رابطهٔ بین اخبار و پارامترهای مختلف بازار بوده‌است. در مطالعهٔ [۷۹]، رابطهٔ آماری معناداری بین اخبار قدیمی دربارهٔ بیکاری و بازده هفتگی S&P 500 مشاهده شده‌است که این اثر در طول هفتهٔ بعد معکوس می‌شود.

در مطالعهٔ [۸۰]، با استفاده از روش تحلیل چندفراکتالی، تغییرات Google Trends و بازار بیت‌کوین تحلیل شده و نشان داده شده‌است که بازار بیت‌کوین در بلندمدت چندفراکتالی بالاتری دارد. در مطالعهٔ [۸۱]، تأثیر اخبار اقتصادی بر تمایل به ریسک در بازار DAX بررسی شده و مشخص شده‌است که افزایش کوتاه‌مدت اخبار مثبت با تمایل به ریسک مرتبط است، اما در بلندمدت این رابطه منفی است. روش‌های [۸۲ و۸۳] برای بررسی واکنش سرمایه‌گذاران بر اخبار دست دوم[1] ارائه شد؛ بر اساس یافته‌های این دو پژوهش، سرمایه‌گذاران به اخبار کهنه به‌صورت مضاعف واکنش نشان می‌دهند و ارتباط مستقیمی بین تأثیر اخبار اقتصادی راجع به بیکاری و بازگشت سهام شرکت‌های S&P 500 در هفتهٔبعد وجود دارد و این روند در طی هفته‌های بعد به‌صورت معکوس ادامه می‌یابد.

در روش پیشنهادی [۸۴] به بررسی هم‌بستگی بین آمار جستوجوی واژگان کلیدی مرتبط با بورس مستخرج از تارنمای گوگل ترند و بازگشت در بازار بیت‌کوین پرداخته شده‌است. یک معیار متوسط شاخص قیمت بیت‌کوین بر اساس ارزهای مختلف و حجم معاملات آن‌ها معرفی شد؛ همچنین یک شاخص google Trend Index روی جستوجوی واژه‌های مربوط به بیت‌کوین نیز از سایت گوگل ترند برای مدل‌سازی رفتار سرمایه‌گذاران بیت‌کوین محاسبه شده‌است؛ بر اساس این دو معیار دو سری زمانی تشکیل شده‌است که به روش MF-DCCA که یک روش تحلیل هم‌بستگی بین دو زمان سری است به بررسی هم‌بستگی این دو سری زمانی پرداخته‌است.

در روش پیشنهادی[۸۵] به بررسی هم‌بستگی بین شاخص احساس سرمایه‌گذاران و میزان بازگشت در بورس آمریکا به‌صورت متغیر با زمان در بازه بلندمدت پرداخته شده‌است. پژوهش‌گران با استفاده از روش DCC-MIDAS به بررسی متغیر با زمان هم‌بستگی پرداخته‌اند؛ درحالی‌که سایرین مدل خود را ایستا در نظر گرفته‌اند. در روش پیشنهادی [۶۴] برای بررسی نقش رویدادهای سیاسی، اجتماعی و یا اقتصادی در بورس به گروه‌بندی اخبار بر اساس نوع جهت‌گیری گروه خبری که خبر را منتشر می‌کند، پرداخته شده‌است. پژوهش‌گران با استفاده از روش آزمون علیت[2] گرنجر به بررسی فرضیهٔ مؤثربودن رویدادهای هر دسته بر نوسانات بورس با توجه به الگوی تکرارشده در گذشته پرداخته‌اند؛ همچنین در روش پیشنهادی [۸۶،۸۷] با استفاده از تحلیل احساس و معرفی یک شاخص تجمعی بر اساس آن به شناسایی رویداد و مدل‌سازی تأثیر آن با استفاده از آزمایش علیت گرنجر پرداخته شده‌است. نتایج این پژوهش نشان می‌دهد در هر کدام از تغییرات شدید احساس، یک رویداد مهم رخ داده‌است. در روش پیشنهادی [۷۴] یک روش پیشنهاد استراتژی تجارت بر اساس اخبار و توییت‌ها ارائه شده‌است. پژوهش‌گران نشان داده‌اند داده‌های شبکه‌های اجتماعی نظیر توییتر، زودتر از اخبار، رویدادها را گزارش می‌دهند، اما اخبار قابلیت اعتماد بیشتری دارند. آن‌ها با استفاده از این دو ویژگی، در نتایج نشان داده‌اند زمانی که تحلیل احساس اخبار و داده‌های شبکهٔ اجتماعی در یک جهت حرکت می‌کنند، بازار نیز در همان جهت حرکت می‌کند و می‌توان یک استراتژی تجاری بلندمدت اتخاذ کرد.

۴- مدل‌های زبانی بزرگ در پردازش متن و سری‌های زمانی

مدل‌های زبانی بزرگ مورد استفاده در کاربردهای تحلیل بازارهای مالی به دو دستهٔ اصلی تقسیم می‌شوند که هر کدام در حوزه‌های متفاوتی از پردازش داده‌ها کاربرد دارند: دسته نخست، مدل‌هایی هستند که به‌طور خاص برای تحلیل متن و درک زبان طبیعی طراحی شده‌اند و در وظایفی مانند استخراج اطلاعات، تحلیل احساسات و نمایش معنایی متون به‌کار می‌روند؛ این دسته شامل معماری‌هایی مانند BERT، Sentence-BERT و AoE [۸۸] است که با بهره‌گیری از

[1] منظور از اخبار دست دوم اخباری است که به صورت دو روز متوالی شبیه به هم تکرار شده باشند.

[2] از یک روش آماری تحلیل هم‌بستگی که به بررسی تأثیر گذشتهٔ مرتبهٔ n از یک سری زمانی بر آیندهٔ یک سری زمانی دیگر می‌پردازد.

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-03]

[DOI: 10.61882/jsdp.22.2.109]

روش‌های پیشرفته مانند یادگیری مقایسه‌ای[1] و بهینه‌سازی شباهت‌های معنایی، قابلیت‌های قدرتمندی در تحلیل دقیق متون ارائه می‌دهند. دستهٔ دوم، مدل‌هایی نظیر Time-LLM [۸۹] هستند که برای تحلیل سری‌های زمانی و داده‌های موقتی توسعه یافته‌اند و به شناسایی الگوهای پنهان در داده‌های متوالی می‌پردازند. این مدل‌ها در کاربردهایی مانند پیش‌بینی روندهای بازار، تحلیل رفتارهای مالی و مدل‌سازی داده‌های زمانی مؤثرند. این تقسیم‌بندی نشان‌دهندهٔ تنوع و انعطاف‌پذیری مدل‌های زبانی بزرگ در پردازش انواع مختلف داده‌ها و حل مسائل پیچیده در حوزه‌های مختلف است.

۴-۱-مدل‌های بزرگ زبانی در تحلیل متنی رسانه‌ها در بازارهای مالی

تاریخچهٔ پردازش متن با روش‌های اولیه مانند تجمیعی از واژه‌ها آغاز شد که در آن متون بر اساس فراوانی واژگان در یک پیکره سازماندهی می‌شدند[۶۲, ۹۰-۹۲]؛ اما چالش‌هایی مانند ابعاد بالا و ماتریس‌های خلوت، دقت تحلیل احساس را کاهش می‌دادند. برای غلبه بر این مشکلات، روش‌هایی مانند استفاده از هستان‌شناسی و انتخاب ویژگی‌های معنادار توسعه یافتند که به تحلیل دقیق‌تر مفاهیم معنایی کمک کردند. در ادامه، مدل‌سازی مفاهیم معنایی با استفاده از روش‌هایی نظیر فاکتورگیری نامنفی ماتریس [۹۲] (NMF) و تحلیل سطحی بیزی، تحولی در کاهش ابعاد ویژگی‌ها و بهبود تحلیل احساس ایجاد کرد[۳۳، ۹۳].

در سال ۲۰۱۳، پژوهش‌گران گوگل روش جاسازی واژه‌ها را معرفی کردند که واژگان را بر اساس زمینه‌شان به بردارهای عددی تبدیل می‌کرد و زمینه‌های جدیدی را برای سازماندهی متون در مقیاس کلان‌داده‌ها فراهم آورد. در روش‌های پیشنهادی [۶۱-۶۳] برای بهبود دقت پیش‌بینی، اسناد خبری با استفاده از روش بردار برای هر واژه، برداری شده‌اند و پیش‌بینی با استفاده از شبکهٔ یادگیری عمیق انجام گرفته‌است. این رویکرد با توسعهٔ مدل‌های پیش‌آموزش‌دیده مانند BERT و شبکه‌های عصبی عمیق، به مرزهای جدیدی در پردازش زبان طبیعی رسید و دقت پیش‌بینی و تحلیل متون را به‌طور قابل توجهی افزایش داد. در روش‌های [۹۴, ۹۵] از مدل‌های پیش‌آموزش دیده‌ای نظیر BERT در تولید بردار برای اسناد خبری استفاده شده‌است.

در سال‌های اخیر، ترانسفورمرها و مدل‌های زبانی بزرگ مانند BERT نقش مهمی در تحلیل اخبار و بازارهای مالی ایفا کرده‌اند؛ پیش از این، روش‌های جاسازی سنتی به‌دلیل درنظرنگرفتن زمینهٔ جملات، در تولید بردارهای دقیق معنایی با محدودیت‌هایی مواجه بودند. با معرفی Sentence-BERT، یک مدل تخصصی مبتنی بر BERT قابلیت تولید بردارهای مشابه برای اسناد با موضوعات نزدیک افزایش یافته است؛ این مدل با بهره‌گیری از شباهت کسینوسی در فضای برداری و شبکه‌هایGAN توانسته است شباهت‌های معنایی بین اسناد را بهتر یادگیری کند و در تحلیل اخبار مالی و شناسایی الگوهای بازار کاربردی مؤثر داشته باشد.

مدل AoE با حل چالش‌های مربوط به اشباع تابع کسینوسی در نقاط بیشینه و کمینه، عملکرد Sentence-BERT را بهبود بخشیده و افق‌های جدیدی را در حوزهٔ تحلیل داده‌های مالی گشوده است. این مدل با معرفی روش‌های بهینه‌سازی جدید در فضای پیچیده‌تر برداری، محدودیت‌های روش‌های سنتی را مرتفع کرده و دقت تحلیل احساسات اخبار مالی، خوشه‌بندی داده‌های بازار و پیش‌بینی رفتارهای مالی را افزایش داده‌است. به‌کمک این فناوری‌ها، تحلیل‌های دقیق‌تری از روندهای بازار و واکنش‌های اقتصادی امکان‌پذیر شده‌است.

با توجه به پیشرفت‌های اخیر در فناوری‌های مبتنی بر ترانسفورمرها، حوزهٔ تحلیل اخبار و بازارهای مالی به‌عنوان یکی از مهم‌ترین زمینه‌های کاربردی این مدل‌ها شناخته می‌شود. مدل‌هایی مانند Sentence-BERT و AoE نه‌تنها با بهبود شباهت‌های معنایی و ارائهٔ روش‌های نوین در بهینه‌سازی نمایش جملات، دقت تحلیل‌ها را افزایش داده‌اند، بلکه امکان کشف بینش‌های دقیق‌تر در حوزهٔ اقتصاد رفتاری و مالی را فراهم آورده‌اند. این دستاوردها به لطف استفاده از روش‌های پیشرفته مانند یادگیری مقایسه‌ای حاصل شده‌اند که به مدل‌ها کمک می‌کند تا شباهت‌ها و تفاوت‌های ظریف بین داده‌ها را بهتر تشخیص دهند. در ادامه، به بررسی مبانی یادگیری مقایسه‌ای و نقش آن در بهبود عملکرد مدل‌های زبانی بزرگ می‌پردازیم.

۴-۱-۱-روش‌های مقایسه‌ای بر یادگیری رقابتی

یادگیری رقابتی شیوه‌ای مهم در آموزش شبکه‌های مبتنی بر ترانسفورمر است که هدف اصلی آن یادگیری بازنمایی است؛ به‌طوریکه ورودی‌های بسیار مشابه، بازنمایی برداری بسیار نزدیکی پیدا کنند و ورودی‌هایی که تفاوت زیادی با هم دارند؛ درنهایت دارای بردار بازنمایی با فاصلهٔ کسینوسی زیاد از هم باشند[۹۶]. این شبکه‌ها کاربرد گسترده‌ای در مواردی نظیر مشابهت معنایی در تحلیل اخبار بازارهای مالی دارند[۸۱،۹۷،۹۸]. بیشتر تابع خطا در

[1] contrastive learning

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-03]

[DOI: 10.61882/jsdp.22.2.109]

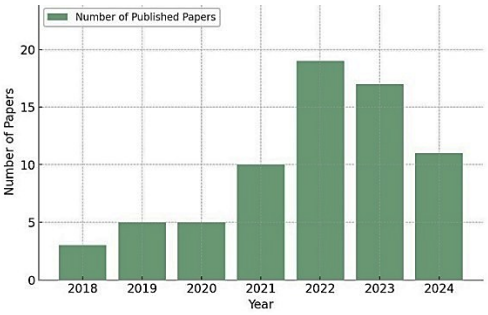
این شبکه‌ها مبتنی بر یک معیار شباهت مانند شباهت کسینوسی مانند رابطهٔ زیر است:

$$\mathcal{L}_{cos} = \log\left[1 + \sum_{s(\mathbf{X}_i,\mathbf{X}_j)>s(\mathbf{X}_m,\mathbf{X}_n)} e^{\frac{\cos(\mathbf{X}_m,\mathbf{X}_n)-\cos(\mathbf{X}_i,\mathbf{X}_j)}{\tau}}\right]$$

در فرایند یادگیری، ورودی مدل شامل دو جفت با شباهت زیاد است و تکنیک‌هایی نظیر نمونه‌برداری منفی دسته‌ای[1] نیز کاربرد فراوانی دارد[۹۹]. نمونه‌برداری منفی دسته‌ای، یک روش رایج در یادگیری ماشین است که برای آموزش مدل‌های زبانی به‌کار می‌رود. این روش به منظور افزایش کارایی و دقت مدل در تشخیص نمونه‌های منفی، به‌خصوص در مجموعه‌داده‌های نامتعادل استفاده می‌شود. در این روش ابتدا، تعدادی نمونهٔ مثبت از مجموعه‌داده انتخاب می‌شوند؛ این نمونه‌ها می‌توانند شامل واژگان یا عباراتی باشند که هم‌زمان در یک جمله یا متن ظاهر می‌شوند. به‌ازای هر نمونهٔ مثبت، تعدادی نمونهٔ منفی به‌صورت تصادفی از مجموعه‌داده انتخاب می‌شوند. این نمونه‌ها شامل واژگان یا عباراتی هستند که هم‌زمان در یک جمله یا متن ظاهر نمی‌شوند؛ سپس، برای هر نمونهٔ مثبت و نمونه‌های منفی مرتبط با آن، تابع خطای مربوط به دسته که متفاوت از تابع خطای کل فرایند یادگیری است، محاسبه می‌شود.

۴-۲-مدل‌های زبانی بزرگ سری زمانی در تحلیل فنی بازارهای مالی

با توجه به ارائهٔ ساختار ترانسفورمر در سال ۲۰۱۷، کاربرد مبدل‌ها در حوزه‌های مختلف یادگیری ماشینی پس از آن گسترش داشته است. روند روبه‌رشد پژوهش‌های انجام‌شده در سال‌های اخیر نشان‌دهندهٔ نوبودن حوزهٔ پیش‌بینی سری‌های زمانی با استفاده از مبدل‌هاست. نمودار (شکل-۵): **نمودار تعداد روش‌های مبتنی بر مدل‌های مبدل در پیش‌بینی سری‌های زمانی منتشرشده در سال‌های اخیر)** تعداد مقالات بررسی‌شده در این حوزه به تفکیک سال را نشان می‌دهد، که بیان‌کنندهٔ روند روبه‌رشد پژوهش‌های کاربرد مبدل‌ها در تحلیل سری زمانی است. در این بخش به بیان پیشینهٔ پژوهش‌های انجام‌شده در تحلیل سری‌های زمانی با استفاده از روش‌های مبتنی بر مدل‌های بزرگ زبانی پرداخته شده‌است.



(شکل-۵): نمودار تعداد روش‌های مبتنی بر مدل‌های مبدل در پیش‌بینی سری‌های زمانی منتشرشده در سال‌های اخیر
(Figure-5): Distribution of reviewd method in Financial Time series prediction leveraging Time Series based LLM

مدل‌های مبتنی بر ساختار مبدل در سری‌های زمانی از لحاظ نوع دادهٔ ورودی به شبکه به دو دستهٔ مبدل‌های با ورودی سری زمانی پیوسته[2] متعلق به یک فضای نامتناهی از اعداد و مبدل‌های با ورودی سری زمانی گسسته[3] متعلق به یک مجموعهٔ محدود از مشاهدات گسسته [۱۰۰] تقسیم می‌شوند. بیشتر روش‌های ارائه‌شده دارای ورودی پیوسته [۱۰۱] هستند. از این میان دسته‌ای از روش‌ها ابتدا سری زمانی ورودی را به فرم مانا تبدیل کرده‌اند و تغییرات سری زمانی را مطالعه کرده‌اند و دسته‌ای دیگر به بررسی داده‌های خام سری زمانی پیوسته با وجود خاصیت نامانایی در سری پرداخته‌اند[۱۰۲]. دستهٔ کمی از این روش‌های نوظهور، به گسسته‌سازی سری زمانی برای مطالعهٔ الگوهای موجود در انتقال بین این حالات پرداخته‌اند.

روش پیشنهادی پژوهش‌گران با عنوان PatchTST در [۱۰۰]، با تکیه بر این حقیقت که دادهٔ هر لحظهٔ سری زمانی مانند یک واژه در جمله است که بهتنهایی مفهومی ندارد، به بخش‌بندی سری زمانی و تولید زیرالگوهایی برای آموزش مدل مبدل در کشف هم‌بستگی میان لحظات زمانی و پیش‌بینی سری پرداخته است. این مدل به پیش‌بینی سری زمانی در کاربرد اقتصاد صنعت برق پرداخته و از معیار متوسط خطای مطلق به‌منظور ارزیابی استفاده کرده‌است.

مزیت بخش‌بندی سری زمانی ورودی به مبدل در (۱) انعکاس اطلاعات معنایی محلی در بازنمایی تولیدشده برای کل بخش، (۲) کاهش درجهٔ دو سربار حافظه و سربار محاساباتی سازوکار توجه، (۳) اجبار مدل در اهمیت‌دادن به یک دنباله با تاریخچهٔ طولانی‌تر است. ویژگی برجستهٔ دیگر این روش درنظرگرفتن سری زمانی چندمتغیره به‌مانند یک تصویر با چندین کانال رنگی است که برای هر کانال جداگانه ویژگی استخراج می‌شود؛ همچنین استفاده

[1] In batch negative sampling

[2] Continues time series
[3] Discrete time series

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-03]
[DOI: 10.61882/jsdp.22.2.109]

از بلاک رمزگشای[1] مبدل در طراحی ساختار شبکهٔ پیشنهادی این روش نشان از درنظرداشتن رعایت ترتیب در محاسبهٔ بردارهای توجه سری زمانی است. فرایند آموزش این مدل به‌صورت خودنظارتی انجام پذیرفته است. توکنایزر ارائه‌شده در این روش بر روی داده‌های پیوسته اعمال شده‌است، اما برای نرمال‌سازی از روش نرمال‌سازی نمونهٔ [۱۰۳] استفاده شده‌است که در آن هر بخش ورودی به شبکه بر اساس میانگین و واریانس خودش نرمال می‌شود و در خروجی نیز همین میانگین و واریانس دوباره به آن اضافه می‌شود.

این سبک نرمال‌سازی تا حد قابل ملاحظه‌ای چالش نامانابودن سری‌های زمانی را پوشش می‌دهد؛ زیرا دادهٔ یادگیری مدل و داده‌هایی که در مرحله آزمون به مدل داده می‌شوند هر کدام بر اساس توزیع خودشان نرمال‌سازی می‌شوند. توکنایزر ارائه‌شده در این روش سری زمانی را به بسته‌هایی با طول ثابت L دارای هم‌پوشانی به‌طول S تقسیم می‌کند؛ از جمله معایب بخش‌بندی با طول ثابت، شکسته‌شدن یک الگو به دو بخش است. ساختار شبکهٔ یک‌لایهٔ ترانسفورمر تشکیل‌شده و تابع خطای مجذور کمینهٔ مربعات خطا در نظر گرفته شده‌است. نتایج این پژوهش نشان می‌دهد با تنظیم شبکه با توجه به دنباله‌های طولانی‌تر میزان خطا پنجاه درصد کاهش پیدا کرده‌است.

روش پیشنهادی FTS-Diffusion [۱۰۴] در راستای پیش‌بینی و رگرسیون قیمت سهام S&P 500 و همچنین سهام Google به بخش‌بندی دادهٔ ورودی به ارائهٔ یک شبکهٔ انتشاری[2] مولد بر اساس مشابهت الگوها پرداخته است. در این روش سری زمانی ورودی به شبکه، ابتدا از یک لایهٔ خوشه‌بندی بر اساس معیار مشابهت کش‌وقوس زمانی می‌گذرد و برای هر سری، مرکز خوشه به‌عنوان نمایندهٔ الگوی موجود در آن به‌عنوان ورودی به شبکه داده می‌شود. این روش برخلاف سایر روش‌های مبدل سری زمانی تنها برای پیش‌بینی سری‌های زمانی مالی طراحی شده‌است. ساختار شبکه در قسمت یادگیری بازنمایی سری زمانی ورودی به‌صورت رمزگذار ترانسفورمر طراحی شده‌است که ترتیب رخداد حالات در آن بی اهمیت است.

روش پیشنهادی [۱۰۵] به پیش‌بینی قیمت تبادل ارز هشت کشور مختلف در بازه سال‌های ۱۹۹۰ تا ۲۰۱۶ و همچنین پیش‌بینی شاخص‌های اقتصادی اعلام‌شده از سوی بانک فدرال آمریکا پرداخته است. این روش با توجه به ماهیت مبدل‌های مورد استفاده در پردازش متن که بر روی مجموعهٔ محدودی از حروف الفبا آموزش می‌بینند، سعی در ارائهٔ یک بازتعریف در کاربرد سری‌های زمانی داشته است. در این روش، گسسته‌سازی دادهٔ ورودی به شبکه بر اساس میانگین و واریانس کل توزیع داده‌ها انجام شده و سپس بر اساس تعداد سطوح گسسته‌سازی، بازه بین صفر و یک به تعدادی زیربازه تقسیم شده و درنهایت هر x_t بر اساس تعلق به بازه متناظر خود نگاشت[3] شده‌است. این روش به‌دلیل وابستگی به میانگین و واریانس کل داده‌های خام سری زمانی در کاربردهای مربوط به بازارهای مالی در مرحلهٔ استنتاج با مشکل مواجه خواهد شد؛ زیرا شبکه بر اساس داده‌های گسسته‌شده‌ای که بر اساس میانگین فضای آموزش نرمال شده‌اند، آموزش دیده‌است؛ درحالی‌که در سری‌های زمانی مالی توزیع داده‌ها به‌مرورزمان بسیار تغییر می‌کند.

ساختار شبکه در این روش مشابه ساختار مدل T5 [۱۰۶] به‌صورت دو بلاک مجزای رمزگذار و رمزگشا توسعه پیدا کرده‌است. یکی دیگر از نقاط ضعف مهمی که به این ساختار شبکه وارد است، وجود ساختار مبدل رمزگذار است که در آن احتمال انتقال از حالات آینده به گذشته در تولید بازنمایی یک حالت در گذشته تأثیرگذار است و اطلاعاتی از آینده به گذشتهٔ دنباله نشت می‌کند؛ درحالی‌که در یک سری زمانی رعایت ترتیب مشاهدات دارای اهمیت است؛ از جمله مزیت‌های این روش توانایی مدل در پیش‌بینی دنبالهٔ مشاهدات با طول زیاد (دوازده مشاهدهٔ آتی) بدون نیاز به بهسازی مبتنی بر دستورالعمل[4] است.

روش پیشنهادی Time-LLM [۸۹] ازجمله روش‌هایی است که بر روی یک مدل پیش‌آموزش‌دیدهٔ زبانی بزرگ بهسازی شده‌است؛ به‌طوری‌که مدل نهایی قابلیت درک متن و سری زمانی را در پرامپت ورودی داشته باشد. بهسازی به روش فریز وزن‌های شبکهٔ پیش‌آموزش‌دیده و یادگیری وزن لایهٔ آخر شبکهٔ عصبی[5] انجام گرفته است. ضمن توجه به تغییر توزیع داده‌ها در سری زمانی، داده‌ها را به‌صورت بسته‌هایی هم‌پوشان و با طول ثابت در نظر گرفته و هر دسته را به روش RevIN [۱۰۳] نرمال‌سازی کرده‌است. در این روش نرمال‌سازی، میانگین و واریانس جدیدی برای داده‌های هر بسته یاد گرفته می‌شود و داده‌های هر بسته تحت تبدیل مقیاس و جابه‌جایی نرمال می‌شوند که این مزیت را ایجاد می‌کند که نرمال‌سازی مستقل از فضای آزمون و آموزش یاد گرفته شود. از تکنیک prompt as prefix استفاده کرده‌است؛ به این معنی که ساختار شبکه طوری طراحی شده‌است که خروجی بلاک ترانسفورمر برای عبارت پرامپت به جاسازی تولیدشده برای سری زمانی الحاق می‌شود. به‌منظور

[1] Decoder
[2] Diffusion
[3] Dequantization
[4] Instruction based fine tuning
[5] Head based fineTuning

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-03]
[DOI: 10.61882/jsdp.22.2.109]

ارزیابی به مسئلهٔ پیش‌بینی میزان برق مصرفی در کاربرد اقتصاد صنعت برق پرداخته است.

روش پیشنهادی LLM4TS [۱۰۷] به بهسازی یک مدل پیش‌آموزش‌دیده به روش LoRA پرداخته است. در روش LoRA بلاک‌های رمزگذار-رمزگشا چندلایهٔ پرسپترونی برای یادگیری بازنمایی ورودی‌های جدید به مدل افزوده می‌شود و وزن‌های لایه‌های توجه فریز شده‌است. لایه‌های LoRA، نرمال‌سازی نمونه، امبدینگ ورودی در مرحلهٔ بهسازی آموزش دیده‌اند. از روش patchTST برای بسته‌بندی سری زمانی ورودی به شبکه استفاده کرده‌است. یک لایهٔ کانولوشنی برای بازنمایی توکن‌های ورودی به شبکه در نظر گرفته است و بازنمایی مکان نیز به‌صورت قابل یادگیری در نظر گرفته شده‌است. به‌منظور ارزیابی به مسئلهٔ رگرسیون سری زمانی آب‌وهوا، ترافیک و همچنین میزان برق مصرفی در کاربرد اقتصاد صنعت برق پرداخته است.

روش پیشنهادی GPT4TS[1] [۱۰۸] به‌منظور ارائهٔ یک مدل یک‌پارچه برای کاربردهای مختلف پردازش سری زمانی نظیر طبقه‌بندی، رگرسیون، تشخیص ناهنجاری‌ها، تخمین مقادیر گم‌شده، پیش‌بینی کوتاه‌مدت و بلندمدت سری‌های زمانی، به بهسازی یک مدل پیش‌آموزش‌دیدهٔ زبانی بزرگ پرداخته و روش خود را روی مجموعه‌داده‌های متنوعی نظیر آب‌وهوا، ترافیک و همچنین میزان برق مصرفی در کاربرد تشخیص ناهنجاری‌ها و رگرسیون ارزیابی کرده‌است. تمام وزن‌های مدل پیش‌آموزش‌دیده در این روش فریز شده‌اند به‌جز لایه‌های نرمال‌سازی و جاسازی ورودی و فرایند تنظیم دقیق[2] به روش افزودن لایهٔ خروجی بر مدل پایه انجام گرفته است. نرمال‌سازی به روش نرمال‌سازی نمونه انجام پذیرفته است. همانند روش patchTST [۱۰۰] دادهٔ ورودی به شبکه ابتدا نرمال‌سازی نمونه شده و سپس بسته‌بندی شده‌است؛ لذا تفاوت این روش با روش patchTST استفاده از یک بنیاد پیش‌آموزش‌دیده و آموزش لایه‌های نرمال‌سازی است. نتایج این روش نسبت به patchTST بهبود دارد. نوآوری اصلی این مقاله بیان این نکته است که ساختار توجه در بلاک ترانسفورمر درواقع تحلیل اجزای اصلی[3] دادهٔ ورودی است.

در کل روش‌های پیشنهادی در این بخش با بهره‌گیری از مدل‌های پیش‌آموزش‌دیدهٔ زبانی و روش‌های بهسازی خاص، گام‌های مؤثری در جهت غلبه بر چالش‌های موجود در پردازش سری‌های زمانی برداشته‌اند؛ لذا هر کدام از مدل‌های مبدل بررسی‌شده را برای غلبه بر چالش‌هایی نظیر نرمال‌سازی سری‌های زمانی مالی، شیوهٔ گسسته‌سازی سری، بخش‌بندی سری زمانی در مسئلهٔ پیش‌بینی قیمت سری‌های زمانی مالی به‌کار برد.

وجود مشکلاتی نظیر نشت اطلاعات از آینده به گذشته در ساختارهای سنتی مانند T5 نیازمندی به روش‌های نرمال‌سازی مناسب و لزوم حفظ ترتیب مشاهدات در سری‌های زمانی، همگی به‌عنوان نقاط ضعف شناخته شده‌اند که روش‌های جدید تلاش کرده‌اند آن‌ها را برطرف کنند. روش Time-LLM با بهسازی وزن‌های لایهٔ آخر و استفاده از تکنیک RevIN، عملکرد قابل توجهی در پیش‌بینی دنباله‌های بلند ارائه داده‌است. LLM4TS با به‌کارگیری LoRA وpatchTST توانسته است بازنمایی دقیق‌تری از ورودی‌ها یاد بگیرد؛ درحالی‌که GPT4TS با فریزکردن وزن‌های پایه و آموزش لایه‌های نرمال‌سازی، به یک مدل یک‌پارچه برای کاربردهای مختلف دست یافته است. نوآوری‌های این روش‌ها، از جمله تفسیر ساختار توجه به‌عنوان تحلیل اجزای اصلی دادهٔ ورودی نشان‌دهندهٔ پتانسیل بالای این رویکردها در توسعهٔ مدل‌های پیشرفته‌تر برای پردازش سری‌های زمانی است. این پیشرفت‌ها نه‌تنها عملکرد مدل‌ها را بهبود بخشیده‌اند، بلکه پایه‌ای قوی برای پژوهش‌های آینده در این حوزه فراهم کرده‌اند.

۵- زمینه‌های باز پژوهشی پیش‌رو

مدل‌های زبانی منبع باز و پیشرفت‌های فناوری، فرصت‌های بزرگی برای پژوهش‌های در اقتصاد رفتاری فراهم کرده‌اند. این مدل‌ها قادرند حجم عظیمی از داده‌های متنی از منابعی مانند اخبار، شبکه‌های اجتماعی و ویکی‌ها را به‌صورت بلادرنگ پردازش و الگوهای رفتاری و عاطفی سرمایه‌گذاران را شناسایی کنند؛ برای مثال، تحلیل احساسات در دوره‌های بحران اقتصادی می‌تواند واکنش‌های بازار و رفتار غیرمنطقی سرمایه‌گذاران را بهتر توضیح دهد. در این مسیر، تدوین سیستم‌های چندعامله (Multiagent) و پردازش بلادرنگ اطلاعات اهمیت ویژه‌ای دارد؛ این سامانه‌ها می‌توانند ارتباطات پیچیده بین اخبار و رویدادها را شناسایی کرده و تصویر کلی‌تری از وضعیت بازار ارائه دهند؛ همچنین، استفاده از این فناوری‌ها در چهار حوزهٔ اصلی رسانه‌ها، بازنمایی داده‌ها، بازیابی اطلاعات و تحلیل رفتار هنوز زمینه‌های باز پژوهشی فراوانی دارد که نیازمند توسعهٔ مدل‌های دقیق‌تر و تخصصی‌تر است.

[1] GitHub - DAMO-DI-ML/NeurIPS2023-One-Fits-All: The official code for "One Fits All: Power General Time Series Analysis by Pretrained LM (NeurIPS 2023 Spotlight)"
[2] Fine Tuning
[3] Principle Componenet Analysis

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-03]
[DOI: 10.61882/jsdp.22.2.109]

رسانه‌ها: با گسترش مدل‌های زبانی منبع باز و روش‌های پردازش داده‌های متنی، امکان تجمیع و تحلیل داده‌های متنوع از منابع مختلف مانند اخبار، شبکه‌های اجتماعی و تارنماهای خبری به‌طور هم‌زمان فراهم شده‌است. در سال‌های اخیر، پژوهشگران به سمت استفاده از چندین منبع داده‌ای برای بهبود دقت پیش‌بینی‌ها حرکت کرده‌اند؛ برای مثال، مدل‌های زبانی پیشرفته می‌توانند اطلاعات مستتر در متون غیرساختاری را استخراج کرده و با داده‌های مالی ترکیب کنند تا الگوهای دقیق‌تری از رفتار بازار ارائه دهند؛ همچنین، توسعهٔ چت‌بات‌های هوشمند که بتوانند با کاربران تعامل داشته باشند و اطلاعات لحظه‌ای را جمع‌آوری کنند، زمینه‌های جدیدی برای پژوهش‌های در حوزهٔ تنوع داده‌ها و استفاده از منابع داده‌ای ناهمگن ایجاد کرده‌است.

سازماندهی اطلاعات: مدل‌های زبانی منبع باز مانند BERT و روش‌های یادگیری رقابتی، انقلابی در سازماندهی و بازنمایی اطلاعات ایجاد کرده‌اند. این مدل‌ها قادرند اطلاعات پیچیده‌ای را که در متون طبیعی وجود دارد، به‌صورت معنایی و ساختاریافته استخراج کنند؛ علاوه‌براین، تلفیق این مدل‌ها با سری‌های زمانی می‌تواند به درک بهتر تأثیر اطلاعات منتشرشده در طول زمان بر بازارهای مالی کمک کند؛ بااین‌حال، استفاده از این تکنیک‌ها در اقتصاد رفتاری هنوز در مراحل اولیه است و نیاز به توسعهٔ روش‌های تخصصی‌تر برای تحلیل احساسات و رفتارهای پیچیدهٔ انسانی وجود دارد.

بازیابی اطلاعات: تکنیک‌های چندعامله[1] و مدل‌های زبانی پیشرفته می‌توانند به شناسایی اطلاعات پنهان در جریان داده‌های خبری کمک کنند. به جای استفاده از قواعد سادهٔ مبتنی بر واژگان کلیدی، این روش‌ها قادرند ارتباطات پیچیدهٔ بین اخبار مرتبط را شناسایی کرده و رویدادهای مهم را استخراج کنند؛ برای مثال، سامانه‌های چندعاملی می‌توانند با همکاری یکدیگر، اخباری را که به‌صورت مجزا ممکن است، غیرقابل تفسیر باشند به هم مرتبط کنند و تصویر کلی‌تری از وضعیت بازار ارائه دهند؛ همچنین، شناسایی شایعات و اخبار جعلی با استفاده از این فناوری‌ها می‌تواند به کاهش تأثیرات منفی آن‌ها بر بازارهای مالی کمک کند.

تحلیل رفتار: ترکیب سری‌های زمانی و یادگیری عمیق فرصت‌های جدیدی برای مدل‌سازی رفتارهای پیچیده در بازارهای مالی ایجاد کرده‌است. مدل‌های یادگیری عمیق می‌توانند الگوهای بلندمدت و کوتاه‌مدت در داده‌های مالی و خبری را شناسایی کنند و تأثیر آن‌ها بر تصمیم‌گیری‌های سرمایه‌گذاران را تحلیل کنند؛ علاوه‌بر این، سامانه‌های چندعاملی می‌توانند رفتارهای انسانی را در محیط‌های شبیه‌سازی شده مدل کنند و به پژوهش‌گران کمک کنند تا واکنش‌های سرمایه‌گذاران به اخبار و رویدادهای مختلف را بهتر درک کنند. این تکنیک‌ها همچنان در حال توسعه‌اند و می‌توانند به بهبود پیش‌بینی‌های بازار و کاهش ریسک‌های سرمایه‌گذاری کمک کنند.

[1] Multiagent

۶-نتیجه‌گیری

آنچه به داده ارزش می‌بخشد، شیوهٔ بازیابی و تحلیل اطلاعات از آن است. در این زمینه، مدل‌های بزرگ زبانی تحولی شگرف ایجاد کرده‌اند. این مدل‌ها با توانایی پردازش و تفسیر حجم عظیمی از داده‌های متنی، امکان استخراج بینش‌های عمیق از منابع داده‌ای مبتنی بر وب نظیر شبکه‌های اجتماعی، اخبار و گروه‌های خبری را فراهم می‌کنند. در این پژوهش به‌مرور روش‌های ارائه‌شده طی سال‌های ۲۰۰۶ تا ۲۰۲۴ پرداخته شد و بیش از دویست مرجع در حوزهٔ تأثیر اطلاعات مستتر در بازارهای مالی از دیدگاه علم کامپیوتر و با رویکرد متن‌کاوی بررسی شد. این مطالعه به تحلیل کیفی و کمی روش‌های مبتنی بر اقتصاد رفتاری در چهار حوزهٔ اصلی شامل رسانه‌های مبتنی بر وب، سازماندهی داده‌های متنی، بازیابی اطلاعات و تحلیل آن‌ها جهت استخراج دانش پرداخت. هدف این بود که مرز دانش در حوزهٔ تأثیر رسانه بر سرمایه‌گذاران بازارهای مالی مشخص و مسیرهای آیندهٔ پژوهش‌ها تعیین شود. در این مسیر، مدل‌های بزرگ زبانی نقش کلیدی ایفا می‌کنند؛ آن‌ها قادر به شناسایی الگوها، پیش‌بینی رفتار سرمایه‌گذاران و حتی توسعهٔ سامانه‌های توصیه‌گر استراتژی‌های معاملاتی هستند. این فناوری‌ها نه‌تنها دقت و سرعت تحلیل داده‌ها را افزایش می‌دهند، بلکه به دولت‌ها، سیاست‌گذاران اقتصادی و سرمایه‌گذاران کمک می‌کنند تا با استفاده از سامانه‌های پشتیبان تصمیم، ریسک‌ها را کاهش داده و استراتژی‌های بلندمدت مؤثرتری اتخاذ کنند؛ بنابراین، مرور انجام‌شده می‌تواند منبعی ارزشمند برای پژوهش‌های آینده در حوزهٔ متن‌کاوی، اقتصاد رفتاری و کاربردهای نوین هوش مصنوعی در بازارهای مالی مورد استفاده قرار گیرد.

۷-مراجع 7-Reference

[1] Li, Y., Wang, S., Ding, H. and Chen, H, "Large Language Models in Finance: A Survey", in *Proceedings of the Fourth ACM International Conference on AI in Finance*. *Association for Computing Machinery: Brooklyn, NY, USA.*, 2023. pp. 374–382.

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-03]

[DOI: 10.61882/jsdp.22.2.109]

[2] Nie, Y., Kong, Y., Dong, X., Mulvey, J.M., Poor, H.V., Wen, Q. and Zohren, S., "A survey of large language models for financial applications: Progress, prospects and challenges". *arXiv preprint arXiv:2406.11903*, 2024.

[3] Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J.D., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A. and Agarwal, S., "Language models are few-shot learners" *Advances in neural information processing systems*, vol. 33, pp.1877-1901, 2020.

[4] کاظمی تبار، سیدجواد، شهباززاده، مجید، «کشف تقلب در بازار بورس اوراق بهادار با استفاده از کاربرد نامساوی چبیشف»، *فصلنامهٔ پردازش علائم و داده‌ها*، دورهٔ ۱۷، شمارهٔ ۱، صص ۳-۱۴، ۱۳۹۹.

[4] Kazemitabar S. J., Shahbazzadeh M., "Stock Market Fraud Detection, A Probabilistic Approach". *Signal and Data Processing*, vol. 17(1), pp. 3-14, 2020.

[5] Ashish, V., "Attention is all you need". *Advances in neural information processing systems*, vol. *30*, pp. I, 2017.

[6] وفایی جهان، مجید، «استخراج ویژگی‌های ساختاری فایل‌های کامپیوتری مبتنی بر تحلیل و ارزیابی آماری»، *فصلنامهٔ پردازش علائم و داده‌ها*، دورهٔ ۱۳، شمارهٔ ۴، صص ۴۳-۶۲، ۱۳۹۵.

[6] VAFAEI, J.M., "Feature Extraction of Computer Files Structure by Statistical Analysis". *Signal and Data Processing*, vol. 13(4), pp. 43-62, 2017.

[7] Farimani, S.A., M.V. Jahan, and A.M. Fard, "An Adaptive Multimodal Learning Model for Financial Market Price Prediction". *IEEE Access*, vol. 12, pp. 121846-121863, 2024.

[8] Farimani, S.A., Jahan, M.V., Fard, A.M. and Tabbakh, S.R.K., "Investigating the informativeness of technical indicators and news sentiment in financial market price prediction". *Knowledge-Based Systems*, vol. 247, pp. 108742, 2022.

[9] Farimani, S.A., Jahan, M.V., Fard, A.M. and Haffari, G., "Leveraging Latent Economic Concepts and Sentiments in the News for Market Prediction". In *2021 IEEE 8th International Conference on Data Science and Advanced Analytics. Porto, Portugal., DSAA. IEEE,ACM*. 2021. pp. 1-10.

[10] Delgadillo, J., Kinyua, J. and Mutigwe, C., "FinSoSent: Advancing Financial Market Sentiment Analysis through Pretrained Large Language Models". *Big Data and Cognitive Computing*, vol. 8(8), pp. 87, 2024.

[11] Du, K., Xing, F., Mao, R. and Cambria, E., "Financial Sentiment Analysis: Techniques and Applications". *ACM Computing Surveys*, vol. 56(9), pp. 1-42, 2024.

[12] Shen, Y. and Zhang, P.K., "Financial sentiment analysis on news and reports using large language models and finbert". *In 2024 IEEE 6th International Conference on Power, Intelligent Computing and Systems (ICPICS)*, 2024. pp. 717-721.

[13] Park, T., "Enhancing anomaly detection in financial markets with an llm-based multi-agent framework". *arXiv preprint arXiv:2403.19735*, 2024.

[14] Cao, Y., Chen, Z., Pei, Q., Dimino, F., Ausiello, L., Kumar, P., Subbalakshmi, K.P. and Ndiaye, P.M., "Risklabs: Predicting financial risk using large language model based on multi-sources data". 2024.

[15] Xu, Y., Hao, J., Tang, K., Chen, J., Liu, A., Liu, P. and Zhang, G., "FinRipple: Aligning Large Language Models with Financial Market for Event Ripple Effect Awareness". *arXiv preprint arXiv:2505.23826*, 2025.

[16] Farimani, S.A., Jahan, M.V. and Milani Fard, A., "From Text Representation to Financial Market Prediction: A Literature Review". *Information,* vol. 13, 2022.

[17] Zhao, F., Li, X., Gao, Y., Li, Y., Feng, Z. and Zhang, C., "Multi-layer features ablation of BERT model and its application in stock trend prediction". *Expert Systems with Applications*, vol. 207, pp. 117958, 2022.

[18] Avramelou, L., Nousi, P., Passalis, N. and Tefas, A., "Deep reinforcement learning for financial trading using multi-modal features". *Expert Systems with Applications*, vol. 238, pp. 121849, 2024.

[19] Sanh, V., Debut, L., Chaumond, J. and Wolf, T., "DistilBERT, a distilled version of BERT: smaller, faster, cheaper and lighter". *arXiv preprint arXiv:1910.01108,* 2019.

[20] Mo, K., Liu, W., Xu, X., Yu, C., Zou, Y. and Xia, F., "Fine-tuning gemma-7b for enhanced sentiment analysis of financial news headlines". *In 2024 IEEE 4th International Conference on Electronic Technology, Communication and Information (ICETCI)*, IEEE, 2024, pp. 130-135.

[21] Araci, D., "Finbert: Financial sentiment analysis with pre-trained language models". *arXiv preprint arXiv:1908.10063*, 2019.

[22] Jeong, C., "Domain-specialized LLM: Financial fine-tuning and utilization method using Mistral 7B". *Journal of Intelligence and Information Systems*, vol. 30(1), pp. 93-120, 2024.

[23] Cutler, D.M., Poterba, J.M. and Summers, L.H., "What moves stock prices?". 1988.

[24] Shiller, R.J., "From efficient markets theory to behavioral finance". *Journal of Economic Perspectives*, vol. 17(1), pp. 83–104, 2003.

[25] Davies, P.L. and Canes, M., "Stock prices and the publication of second-hand information". *Journal of Business*, pp. 43–56, 1978.

[26] Wuthrich, B., Cho, V., Leung, S., Permunetilleke, D., Sankaran, K. and Zhang, J., "Daily stock market forecast from textual web data". *In SMC'98 Conference Proceedings. 1998 IEEE International Conference on Systems, Man, and Cybernetics (Cat. No. 98CH36218), IEEE*, 1998. vol. 3, pp. 2720-2725.

[27] Barber, B.M. and Loeffler, D., "The "Dart board" column: Secondhand information and price pressure". *Journal of Financial and Quantitative Analysis*, vol. 28(2), pp.273-284, 1993.

[28] Fama, E.F., "The behavior of stock-market prices". *The Journal of Business*, vol. 38(1) pp. 34–105, 1965.

[29] Nassirtoussi, A.K., Aghabozorgi, S., Wah, T.Y. and Ngo, D.C.L., "Text Mining for Market Prediction: A Systematic Review". *Expert Systems with Applications*, vol. 41(16), pp. 7653-7670, 2014.

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-03]

[DOI: 10.61882/jsdp.22.2.109]

[30] Weng, B., Ahmed, M.A. and Megahed, F.M., "Stock Market One-Day Ahead Movement Prediction Using Disparate Data Sources". *Expert systems with applications*, vol. 79, 2017.
[31] Zhang, G., Xu, L. and Xue, Y., "Model and forecast stock market behavior integrating investor sentiment analysis and transaction data". *Cluster Computing,* vol. 20(1), pp. 789-803, 2017.
[32] Kaushal, A. and Chaudhary, P., "News and events aware stock price forecasting technique". *In 2017 International Conference on Big Data, IoT and Data Science (BID), IEEE*, 2017. pp. 8-13.
[33] Hajek, P. and Barushka, A., "Integrating Sentiment Analysis and Topic Detection in Financial News for Stock Movement Prediction". *In Proceedings of the 2nd International Conference on Business and Information Management 2018, ACM: Barcelona, Spain*, 2018. pp. 158-162.
[34] Othan, D., Kilimci, Z.H. and Uysal, M., "Financial sentiment analysis for predicting direction of stocks using bidirectional encoder representations from transformers (BERT) and deep learning models". In *Proc. int. conf. innov. intell. technol*, 2019. pp. 30-35.
[35] Cheng, W. and Chen, S., "Sentiment analysis of financial texts based on attention mechanism of FinBERT and BiLSTM". In *2021 International Conference on Computer Engineering and Application (ICCEA), IEEE*, 2021. pp. 73-78).
[36] Hiew, J.Z.G., Huang, X., Mou, H., Li, D., Wu, Q. and Xu, Y., "Bert-based financial sentiment index and lstm-based stock return predictability". arXiv 2019. arXiv preprint arXiv:1906.09024, 2019.
[37] Li, X., Xie, H., Chen, L., Wang, J. and Deng, X., "News impact on stock price return via sentiment analysis". *Knowledge-Based* Systems, vol. 69, pp. 14-23, 2014.
[38] Nizer, P.S. and Nievola, J.C., "Predicting published news effect in the Brazilian stock market". *Expert Systems with Applications*, vol. 39(12), pp. 10674-10680, 2012.
[39] Van de Kauter, M., Breesch, D. and Hoste, V., "Fine-grained analysis of explicit and implicit sentiment in financial news articles". *Expert Systems with Applications*, vol. 42(11), pp. 4999-5010, 2015.
[40] Nassirtoussi, A.K., Aghabozorgi, S., Wah, T.Y. and Ngo, D.C.L., "Text mining of news-headlines for FOREX market prediction: A Multi-layer Dimension Reduction Algorithm with semantics and sentiment". *Expert Systems with Applications*, vol. 42(1), pp. 306-324, 2015.
[41] Krishnamoorthy, S., "Sentiment analysis of financial news articles using performance indicators". *Knowledge and Information Systems*, vol. 56(2), pp. 373-394, 2018.
[42] Moreno-Ortiz, A. and Fernández-Cruz, J., "Identifying Polarity in Financial Texts for Sentiment Analysis: A Corpus-based Approach". *Procedia-Social and Behavioral Sciences*, vol. 198, pp. 330-338, 2015.
[43] Liu, Q., Cheng, X., Su, S. and Zhu, S., "Hierarchical Complementary Attention Network for Predicting Stock Price Movements with News". In *Proceedings of the 27th ACM International Conference on Information and Knowledge Management*, ACM: Torino, Italy, 2018, pp. 1603-1606.
[44] Li, K., "Reaction to news in the Chinese stock market: A study on Xiong'an New Area Strategy". *Journal of Behavioral and Experimental Finance*, vol. 19, pp. 36-38, 2018.
[45] Gupta, K. and Banerjee, R., "Does OPEC news sentiment influence stock returns of energy firms in the United States?" *Energy Economics*, vol. 77, pp. 34-45, 2019.
[46] Shi, Y., Ho, K.Y. and Liu, W.M., "Public information arrival and stock return volatility: Evidence from news sentiment and Markov Regime-Switching Approach". *International Review of Economics & Finance*, vol. 42, pp. 291-312, 2016.
[47] Bollen, J., Mao, H. and Zeng, X., "Twitter mood predicts the stock market". *Journal of Computational Science*, vol. 2, pp. 1-8, 2011.
[48] Zhang, X., Fuehres, H. and Gloor, P.A., "Predicting Stock Market Indicators Through Twitter "I hope it is not as bad as I fear"". *Procedia-Social and Behavioral Sciences*, vol. 26, pp.55-62, 2011.
[49] Sun, A., Lachanski, M. and Fabozzi, F.J., "Trade the tweet: Social media text mining and sparse matrix factorization for stock market prediction". *International Review of Financial Analysis*, vol. 48: pp. 272-281, 2016.
[50] Atzeni, M., Dridi, A. and Reforgiato Recupero, D., "Using frame-based resources for sentiment analysis within the financial domain". *Progress in Artificial Intelligence*, vol. 7(4), pp. 273-294, 2018.
[51] Ho, C.S., Damien, P., Gu, B. and Konana, P., "The time-varying nature of social media sentiments in modeling stock returns". *Decision Support Systems*, vol. 101, pp. 69-81, 2017.
[52] Zou, Y. and Herremans, D., "PreBit—A multimodal model with Twitter FinBERT embeddings for extreme price movement prediction of Bitcoin". *Expert Systems with Applications*, vol. 233, pp. 120838, 2023.
[53] Wang, H., Lu, S. and Zhao, J., "Aggregating multiple types of complex data in stock market prediction: A model-independent framework". *Knowledge-Based Systems,* vol. 164, pp. 193-204, 2019.
[54] Chen, X., Ma, X., Wang, H., Li, X. and Zhang, C., "A hierarchical attention network for stock prediction based on attentive multi-view news learning". *Neurocomputing*, vol. 504, pp. 1-15, 2022.
[55] Ma, Y., Mao, R., Lin, Q., Wu, P. and Cambria, E., "Multi-source aggregated classification for stock price movement prediction". *Information Fusion*, vol. 91, pp. 515-528, 2023.
[56] Xu, H., Cao, D. and Li, S., "A self-regulated generative adversarial network for stock price movement prediction based on the historical price and tweets". *Knowledge-Based Systems*, vol. 247, pp. 108712, 2022.
[57] Zeng, P., Hu, G., Zhou, X., Li, S., Liu, P. and Liu, S., "Muformer: A long sequence time-series forecasting model based on modified multi-head attention". *Knowledge-Based Systems*, vol. 254, pp. 109584, 2022.

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-03]
[DOI: 10.61882/jsdp.22.2.109]

sentiment in the Taiwan stock market". *The North American Journal of Economics and Finance*, vol. 39, pp. 158-181, 2017.
[71] Song, Q., Liu, A. and Yang, S.Y., "Stock portfolio selection using learning-to-rank algorithms with news sentiment". *Neurocomputing*, vol. 264, pp. 20-28, 2017.
[72] Geva, T. and Zahavi, J., "Empirical evaluation of an automated intraday stock recommendation system incorporating both market data and textual news". *Decision Support Systems*, vol. 57, pp. 212-223, 2014.
[73] Feuerriegel, S. and Prendinger, H., "News-based trading strategies". *Decision Support Systems*, vol. 90(C), pp. 65-74, 2016.
[74] Yang, S.Y., Mo, S.Y.K., Liu, A. and Kirilenko, A.A., "Genetic programming optimization for a sentiment feedback strength based trading strategy". *Neurocomputing*, vol. 264, pp. 29-41, 2017.
[75] Sun, Y., Fang, M. and Wang, X., "A novel stock recommendation system using Guba sentiment analysis". *Personal and Ubiquitous Computing,* vol. 22(3), pp.575-587, 2018.
[76] Ochiai, T. and Nacher, J.C., "A model for the dynamic behavior of financial assets affected by news: The case of Tohoku–Kanto earthquake". *Physics letters A*, vol. 375(41), pp. 3552-3556, 2011.
[77] Hendershott, T., Livdan, D. and Schürhoff, N., "Are institutions informed about news?". *Journal of Financial Economics*, vol. 117(2), pp. 249-287, 2015.
[78] Medovikov, I., "When does the stock market listen to economic news? New evidence from copulas and news wires". *Journal of Banking & Finance*, vol. 65, pp. 27-40, 2016.
[79] Kaushik, B., Hemani, H. and Ilavarasan, P.V., "Social media usage vs. stock prices: an analysis of Indian firms". *Procedia computer science*, vol. 122, pp. 323-330, 2017.
[80] Nisar, T.M. and Yeung, M., "Twitter as a tool for forecasting stock market movements: A short-window event study". *The Journal of Finance and Data Science*, vol. 4(2), pp. 101-119, 2018.
[81] Xiao, Y., Liu, B., Ventre, C. and Li, H., "A measure of climate change in financial news and its impact on the stock market". *Journal of Digital Economy*, vol. 3, pp.146-157, 2025.
[82] Birz, G., "Stale economic news, media and the stock market". *Journal of Economic Psychology*, vol. 61, pp. 87-102, 2017.
[83] Tetlock, P.C., "All the News That's Fit to Reprint: Do Investors React to Stale Information?" *The Review of Financial Studies*, vol. 24(5), pp. 1481–1512, 2011.
[84] Zhang, W., Wang, P., Li, X. and Shen, D., "Quantifying the cross-correlations between online searches and Bitcoin market". *Physica A: Statistical Mechanics and its Applications*, vol. 509, pp. 657-672, 2018.
[85] Fang, L., Yu, H. and Huang, Y., "The role of investor sentiment in the long-term correlation between U.S. stock and bond markets". *International Review of Economics & Finance*, vol. 58, pp. 127-139, 2018.
[86] Fernández Vilas, A., Díaz Redondo, R.P., Crockett, K., Owda, M. and Evans, L., "Twitter
[58] Lee, T.W., Teisseyre, P. and Lee, J., "Effective exploitation of macroeconomic indicators for stock direction classification using the multimodal fusion transformer". *IEEE Access*, vol. 11, pp. 10275-10287, 2023.
[59] Wang, G., Ma, J. and Chen, G., "Attentive statement fraud detection: Distinguishing multimodal financial data with fine-grained attention". *Decision Support Systems*, vol. 167, pp. 113913, 2023.
[60] Li, X., Xie, H., Wang, R., Cai, Y., Cao, J., Wang, F., Min, H. and Deng, X., "Empirical analysis: stock market prediction via extreme learning machine". *Neural Computing and Applications*, vol. 27(1), pp. 67–78, 2016.
[61] Vargas, M.R., Dos Anjos, C.E., Bichara, G.L. and Evsukoff, A.G., "Deep Leaming for Stock Market Prediction Using Technical Indicators and Financial News Articles". In *2018 international joint conference on neural networks (IJCNN), IEEE, 2018.* pp. 1-8.
[62] Huynh, H.D., Dang, L.M. and Duong, D., "A New Model for Stock Price Movements Prediction Using Deep Neural Network". In *Proceedings of the 8th international symposium on information and communication technology,* ACM: Nha Trang City, Viet Nam, 2017, pp. 57-62.
[63] Lee, C.Y. and Soo, V.W., "Predict Stock Price with Financial News Based on Recurrent Convolutional Neural Networks". In *2017 conference on technologies and applications of artificial intelligence (TAAI), IEEE,* 2017, pp. 160-165.
[64] Verma, I., Dey, L. and Meisheri, H., "Detecting, quantifying and accessing impact of news events on Indian stock indices". In *Proceedings of the international conference on web intelligence, ACM: Leipzig, Germany*, 2017, pp. 550-557.
[65] Gurin, Y., Szymanski, T. and Keane, M.T., "Discovering news events that move markets". In *2017 Intelligent Systems Conference (IntelliSys), IEEE,* 2017, pp. 452-461.
[66] Hochreiter, S. and Schmidhuber, J., "Long short-term memory". *Neural computation*, vol. 9(8), pp. 1735–1780, 1997.
[67] Romanov, V.P., Naletova, O.A., Panteleeva, E.A. and Federyakov, A.S., "Fractal Model of Estimating News and Insider Influence on Market Volatility". *Automatic Documentation and Mathematical Linguistics*, vol. 41(4), pp. 141–149, 2007.
[68] Shynkevich, Y., McGinnity, T.M., Coleman, S.A. and Belatreche, A., "Forecasting movements of health-care stock prices based on different categories of news articles using multiple kernel learning". *Decision Support Systems*, vol. 85, pp. 74-83, 2016.
[69] Checkley, M.S., Higón, D.A. and Alles, H., "The hasty wisdom of the mob: How market sentiment predicts stock market behavior". *Expert Systems with Applications*, vol. 77, pp. 256-263, 2017.
[70] Wei, Y.C., Lu, Y.C., Chen, J.N. and Hsu, Y.J., "Informativeness of the market news

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-03]
[DOI: 10.61882/jsdp.22.2.109]

permeability to financial events: an experiment towards a model for sensing irregularities". *Multimedia Tools and Applications*, vol. 78(7), pp. 9217-9245, 2019.

[87] Wong, C. and Ko, I.Y., "Predictive Power of Public Emotions as Extracted from Daily News Articles on the Movements of Stock Market Indices". In *2016 IEEE/WIC/ACM International Conference on Web Intelligence (WI), IEEE,* 2016, pp. 705-708.

[88] Li, X. and Li, J., "AoE: Angle-optimized embeddings for semantic textual similarity. In *Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics,* vol. 1, Long Papers, 2024 pp. 1825-1839.

[89] Jin, M., Wang, S., Ma, L., Chu, Z., Zhang, J.Y., Shi, X., Chen, P.Y., Liang, Y., Li, Y.F., Pan, S. and Wen, Q., "Time-LLM: Time Series Forecasting by Reprogramming Large Language Models". *arXiv preprint arXiv:2310.01728*, 2023.

[90] Salton, G., "Automatic text processing: the transformation, analysis, and retrieval of information by computer". *Reading: Addison-Wesley*, vol.169, 1989.

[91] Hagenau, M., Liebmann, M. and Neumann, D., "Automated news reading: Stock price prediction based on financial news using context-capturing features". *Decision Support Systems*, vol. 55(3), pp. 685-697, 2013.

[92] Seifollahi, S. and Shajari, M., "Word sense disambiguation application in sentiment analysis of news headlines: an applied approach to FOREX market prediction". *Journal of Intelligent Information Systems*, vol. 52(1), pp. 57-83, 2019.

[93] Rao, Y., Zhong, X. and Lu, S., "Research on News Topic-Driven Market Flucatuation and Predication". In *2016 International Conference on Identification, Information and Knowledge in the Internet of Things (IIKI), IEEE,* 2016, pp. 559-562.

[94] Yang, L., Xu, Y., Ng, T.L.J. and Dong, R., "Leveraging BERT to Improve the FEARS Index for Stock Forecasting". In *The First Workshop on Financial Technology and Natural Language Processing in conjunction with IJCAI,* Macao, China, 2019, p. 54.

[95] Chen, D., Harimoto, K., Bao, R., Su, Q. and Sun, X., "Group, Extract and Aggregate: Summarizing a Large Amount of Finance News for Forex Movement Prediction". *arXiv preprint arXiv:1910.05032*, 2019.

[96] Reimers, N. and Gurevych, I., "Sentence-BERT: Sentence Embeddings using Siamese BERT-Networks". *arXiv preprint arXiv:1908.10084,* 2019.

[97] Soon, P.C., Tan, T.P., Chan, H.Y. and Gan, K.H., "Stock Trend Prediction Using Multi-Attention Network on Domain-specific and Domain-general Features in News Headline". *Pertanika Journal of Science & Technology,* vol. 33(2), 2025.

[98] Wibisono, O., Septiandri, A.A. and Najogie, R.D., "Assessing the Impact of ESG-Related News on Stock Trading in the Indonesian Market: A Text Similarity Framework Approach". In *Proceedings of the Joint Workshop of the 7th Financial Technology and Natural Language Processing, the 5th Knowledge Discovery from Unstructured Data in Financial Services, and the 4th Workshop on Economics and Natural Language Processing@ LREC-COLING 2024,* 2024, pp. 34-39.

[99] Wang, L., Du, C., Zhao, P., Luo, C., Zhu, Z., Qiao, B., Zhang, W., Lin, Q., Rajmohan, S., Zhang, D. and Zhang, Q., "Contrastive Learning with Negative Sampling Correction". *arXiv preprint arXiv:2401.08690*, 2024.

[100] Nie, Y., Nguyen, N.H., Sinthong, P. and Kalagnanam, J., "A time series is worth 64 words: Long-term forecasting with transformers". *arXiv preprint arXiv:2211.14730*, 2022.

[101] Ericson, L., Zhu, X., Han, X., Fu, R., Li, S., Guo, S. and Hu, P., "Deep Generative Modeling for Financial Time Series with Application in VaR: A Comparative Review". *arXiv preprint arXiv:2401.10370*, 2024.

[102] Liu, Y., Wu, H., Wang, J. and Long, M., "Non-stationary transformers: Exploring the stationarity in time series forecasting". *Advances in Neural Information Processing Systems*, vol. 35, pp. 9881-9893, 2022.

[103] Kim, T., Kim, J., Tae, Y., Park, C., Choi, J.H. and Choo, J., "Reversible instance normalization for accurate time-series forecasting against distribution shift". In *International conference on learning representations*, 2021.

[104] Huang, H., Chen, M. and Qiao, X., "Generative Learning for Financial Time Series with Irregular and Scale-Invariant Patterns". In *The Twelfth International Conference on Learning Representations,* 2023.

[105] Ansari, A.F., Stella, L., Turkmen, C., Zhang, X., Mercado, P., Shen, H., Shchur, O., Rangapuram, S.S., Arango, S.P., Kapoor, S. and Zschiegner, J., "Chronos: Learning the Language of Time Series". *arXiv preprint arXiv:2403.07815*, 2024.

[106] Raffel, C., Shazeer, N., Roberts, A., Lee, K., Narang, S., Matena, M., Zhou, Y., Li, W. and Liu, P.J., "Exploring the limits of transfer learning with a unified text-to-text transformer". *Journal of machine learning research*, vol. 21(140), pp. 1-67, 2020.

[107] Chang, C., Wang, W.Y., Peng, W.C. and Chen, T.F., "Llm4ts: Aligning pre-trained llms as data-efficient time-series forecasters". *ACM Transactions on Intelligent Systems and Technology*, vol. 16(3), pp.1-20, 2025.

[108] Zhou, T., Niu, P., Sun, L. and Jin, R., "One fits all: Power general time series analysis by pretrained lm". *Advances in neural information processing systems*, vol. 36, pp.43322-43355, 2024.



دکتر سعیده انبائی فریمانی مدرک کارشناسی خود را در رشتهٔ مهندسی نرم‌افزار کامپیوتر از دانشگاه فردوسی

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-03]

[DOI: 10.61882/jsdp.22.2.109]

مشهد و مدارج کارشناسی‌ارشد و دکترای خود را در رشتهٔ مهندسی نرم‌افزار کامپیوتر از دانشگاه آزاد اسلامی واحد مشهد دریافت کرده‌است. او در حال حاضر در دانشگاه آزاد اسلامی، به‌عنوان دانشمند داده، فعالیت صنعتی و پژوهشی دارد. تجربهٔ پژوهشی و صنعتی او در زمینه‌های پردازش زبان طبیعی (NLP) و تحلیل داده‌های بازهای مالی است و تحت عنوان دانشمند داده در تحلیل سری‌های زمانی و مدل‌سازی رفتار سرمایه‌گذاران بازارهای مالی با شرکت‌های دانش‌بنیان همکاری تجاری دارد. ایشان موفق به کسب عنوان طرح تجاری رتبهٔ برتر در نخستین فراخوان ملی برنامهٔ گرنت جوانه شد. او به‌عنوان داور برای مجلاتی مانند IEEE TNNLS، Expert Systems with Applications و Electronic Commerce Research and Applications فعالیت کرده‌است.

نشانی رایانامهٔ ایشان عبارت است از:
anbaee@mshdiau.ac.ir



دکتر راهله قوچان نژادنورنیا

دانش‌آموختهٔ کارشناسی مهندسی کامپیوتر-نرم‌افزار دانشگاه آزاد مشهد ۱۳۹۱، کارشناسی‌ارشد مهندسی کامپیوتر-هوش مصنوعی دانشگاه آزاد مشهد ۱۳۹۴، دکترای تخصصی مهندسی کامپیوتر-نرم‌افزار دانشگاه آزاد مشهد ۱۴۰۱ و هم‌اکنون در حال گذراندن دورهٔ پسادکترای انفورماتیک پزشکی دانشگاه علوم پزشکی مشهد است. به‌عنوان پژوهش‌گر تحلیل داده با دانشگاه کارلسروهٔ آلمان همکاری کرده‌است و به‌عنوان داور با مجلهٔ Materials Today Communications همکاری کرده‌است. ایشان موفق به کسب رتبهٔ برتر در نخستین فراخوان ملی طرح گرنت جوانه شد.

نشانی رایانامهٔ ایشان عبارت است از:
rghoochannejad@yahoo.com



دکتر مجید وفایی جهان

دانش‌آموختهٔ مهندسی کامپیوتر نرم‌افزار دانشگاه فردوسی مشهد ۱۳۷۸، دانشگاه صنعتی شریف ۱۳۸۰ و علوم‌وتحقیقات تهران در سال ۱۳۸۸ هستند. زمینهٔ پژوهشی ایشان تحلیل داده‌های حجیم و هوش مصنوعی است. ایشان هم‌اکنون دانشیار دانشگاه آزاد اسلامی مشهد و از بنیان‌گذاران شرکت دانش‌بنیان سامانه‌های ابری شهرافزار و نوآوران موج فناوری هستند.

نشانی رایانامهٔ ایشان عبارت است از:
vafaeijahan@mshdiau.ac.ir

[Downloaded from jsdp.rcisp.ac.ir on 2026-11-03]

[DOI: 10.61882/jsdp.22.2.109]