

Evaluating the framing effect on the exchange rate in Iran using machine learning methods

Elmira Asle Roosta¹, Ali Erfani^{*2}, Abdolmohammad Kashian³

Received: 18-08-2023

Accepted: 08-04-2023

Extended Abstract

Purpose: In recent years, most of the currency fluctuations in Iran have occurred after the spread of influential domestic and foreign political-economic news. Despite this significant effect, the impact of the news content is not considered, and its results are used in the form of numerical data in modeling. However, numerical indirect results are available after the impact of the news on the market and are practically useless in forecasting. Therefore, there needs to be a model that includes the news directly in forecasting the exchange rate. Another important phenomenon about the exchange rates and news is the framing effect. This effect is a linguistic-cognitive phenomenon resulting in people with two different attitudes, positive and negative, making different choices regarding the same item or reality. While this action is done explicitly or implicitly in policymakers' announcements, criticisms, and statements, there needs to be a systematic way to analyze and predict its effect on the exchange rate. This paper presents a comprehensive model based on machine learning to predict exchange rate moves by receiving all kinds of textual, numerical, and categorical data. Also, using this model, it is possible to analyze the effect of framing on exchange rate changes systematically.

Methodology: A processing method has been designed to predict the exchange rate from receiving data to producing the final model. In this method, various types of input data, including time series data, batch data, and political-economic news, are received and preprocessed from essential and relevant sources. In numerical data preprocessing, noises and outliers are removed, and values are normalized. Text data are also the texts normalized and converted into tokens. In the next step, custom embedding is provided based on Pars-BERT embedding and the collected news data. Using this embedding, the textual data are converted into numerical vectors, and all

* This paper is extracted from the doctoral thesis of the first author.

1. PhD candidate in the Department of Economics, Semnan University, Semnan, Iran. Email: e.asleroosta@semnan.ac.ir

2. Corresponding Author. Professor, Department of Economics, Semnan University, Semnan, Iran. Email: aerfani@semnan.ac.ir

3. Assistant Professors, Department of Economics, Semnan University, Semnan, Iran. Email: a.m.kashian@profs.semnan.ac.ir

the data are given to the model. Here are three supervised models. The first and third models use textual and numerical data to predict the exchange rate, and the second model only uses numerical data. The core of all the models is a Bi-GRU, a deep neural network. Dropout and batch normalization and regularization techniques have been used in these models to avoid overfit and bias.

Findings and discussion: The tests performed to evaluate the models' efficiency are divided into two parts. The first part evaluates all the three developed models and their results. The second part is dedicated to assessing and analyzing the issue of news framing and the model's performance in this field. Based on the accuracy metric, the first to third models perform properly at the rate of 96.5, 87.2 and 97.07, respectively. The difference between the results of the second model and the first and third ones shows the effect of news on increasing the model's accuracy. In the second part, a dataset of the news affecting the exchange rate with different framings is prepared to evaluate the effect of framing. This set includes 74 main pieces of news and 435 secondary ones. In approximately 32% of the cases, where the news was announced to reduce the rate, the behavior of the market matched the purpose of the report. Meanwhile, in 68% of the other cases, the news that was expected to have a downward effect on the exchange rate did not match the market behavior. This can indicate their incorrect framing. On the other hand, the news that is expected to have a negative (increasing) effect on the exchange rate has worked about 78% of the time and has led to an increase in the rate. This observation also confirms the imbalance effect of positive and negative news on the currency market. Interestingly, the first and third models correctly identified 98.8% and 99.05% of the samples, including negative and positive news of internal and external origins, respectively. This indicates that the models resist different framings of a news story and have made correct predictions.

Conclusions and policy implications: In this article, using machine learning models, an operational method was presented to investigate the effect of framing on the exchange rate in Iran. The proposed architecture includes the five stages of preprocessing textual, numerical and categorical data, data vector representation, feature engineering, model training, and final evaluation and analysis. In the stage of textual data representation, customized embedding is used for economic data. In this regard, there are three models presented, including a model based on numerical data and two models based on numerical and textual data with a data fusion structure. All the three models are recurrent neural networks trained with deep learning techniques. The results of the experiments show that the models with combined data perform very well in forecasting the exchange rate. In addition to predicting the exchange rate, the produced models have been used to analyze the effect of the framing of the published news on the currency market. The research results show that negative news still has a far more significant impact on the currency market, and no positive framing can reduce its impact. Also, the mainly domestic report published to reduce the exchange rate has been successful in about 32% of the cases. Another significant achievement is the excellent performance of the presented models in framed samples. In other words, these models have correctly predicted market behavior by considering

ارزیابی اثر قاب‌بندی بر نرخ ارز در ایران با استفاده از روش‌های یادگیری ماشین*

المیرا اصل روستا^۱، علی عرفانی^۲، عبدالمحمد کاشیان^۳

دریافت: ۱۴۰۲-۰۵-۲۳

پذیرش: ۱۴۰۳-۰۸-۲۰

چکیده

در سال‌های اخیر اغلب نوسانات شدید ارز در ایران بعد از انتشار اخبار تأثیرگذار سیاسی-اقتصادی رخ داده‌اند. با وجود این تأثیر چشمگیر، در اغلب مدل‌های موجود محتوای اخبار منتشره استفاده نشده و یا نتایج آن به صورت غیرمستقیم و در قالب داده‌های عددی لحاظ شده است؛ این رویکرد غیرمستقیم عموماً از کارایی کافی برخوردار نبوده است. در این مقاله مدل جامعی برای پیش‌بینی نرخ ارز با پوشش مستقیم تأثیر اخبار بر آن ارائه شده است. مدل پیشنهادی با اتکاء بر تلفیق انواع داده‌های متنی، عددی و دسته‌ای و اعمال یادگیری عمیق، پیش‌بینی خوبی از حرکت بازار ارز حتی در شرایط نوسانات ارزی متأثر از اتفاقات مختلف ارائه می‌دهد. با استفاده از مدل پیشنهادی، تحلیل دقیقی از اثر قاب‌بندی بر بازار ارز انجام شده است. نتایج این تحلیل علاوه بر تأیید عدم تقارن تأثیر اخبار مثبت و منفی بر بازار، حکایت از عدم کارایی نسبی سیاست‌های اعلام شده به منظور مدیریت نرخ ارز در سال‌های اخیر دارد؛ بر روی مجموعه داده‌ی آزمون نشان داد که تنها در ۳۲٪ از سیاست‌های اتخاذ شده، قاب‌بندی انجام شده مؤثر بوده است. تشخیص درست رفتار بازار با وجود قاب‌بندی‌های مختلف، از ویژگی‌های دیگر مدل پیشنهادی است به نحوی که در آزمون انجام شده در حدود ۹۰٪ موارد پیش‌بینی‌های آن با رفتار بازار مطابقت دارد.

واژگان کلیدی: اثر قاب‌بندی، پیش‌بینی نرخ ارز، یادگیری ماشین، هوش مصنوعی، اخبار.

طبقه‌بندی JEL: C45, C51, C53, C55, G17

* این مقاله مستخرج از رساله‌ی دکتری نویسنده اول است.

۱. دانشجوی دکتری گروه اقتصاد، دانشگاه سمنان، سمنان، ایران e.asleroosta@semnan.ac.ir

۲. نویسنده مسئول. استاد گروه اقتصاد، دانشگاه سمنان، سمنان، ایران aerfani@semnan.ac.ir

۳. دانشیار گروه اقتصاد، دانشگاه سمنان، سمنان، ایران a.m.kashian@profs.semnan.ac.ir

۱- مقدمه

تعاریف گوناگونی از اثر قاب‌بندی^۱ ذکر شده است؛ در متداول‌ترین تعریف «اثر قاب‌بندی پدیده‌ای زبانی-شناختی^۲ است که در اثر آن نسبت به یک پدیده یا واقعیت یکسان، افراد دارای نگرش متفاوت مثبت و منفی، انتخاب‌های متفاوتی انجام می‌دهند» (گلپرتی و سرجیونی،^۳ ۲۰۲۳: ۳۲-۳۸). البته براساس زمینه و موضوع مورد بررسی، تعاریف دیگری نیز ارائه شده است. در بازارهای مالی و اقتصادی، اثر قاب‌بندی به پدیده‌ای اطلاق می‌شود که در آن انتخاب‌های بازیگران بازار براساس نحوه‌ی بیان گزینه‌های موجود، متفاوت می‌شود. با رویکرد مالی رفتاری^۴، اثر قاب‌بندی به نحوه‌ی ارائه‌ی اطلاعات مالی مانند ریسک و بازده اشاره دارد که بر درک و تصمیمات سرمایه‌گذاران مؤثر بوده و احتمالاً منجر به سرمایه‌گذاری‌های غیرعقلایی یا غیربهبه می‌شود. در تمامی این موارد، چند جزء مشترک وجود دارد:

- اطلاعات و محتوای ارائه شده مشخص و ثابت است.
- آنچه به عنوان قاب‌بندی تعبیر می‌شود، مربوط به نوع بیان اطلاعات است.
- منظور از قاب‌بندی، دروغ‌گویی یا ارائه اطلاعات نادرست نبوده و صرفاً تفاوت در نحوه‌ی بیان اطلاعات و واقعیت‌ها مدنظر است.

اثر قاب‌بندی نخستین بار در مقاله‌ای با عنوان نظریه‌ی چشم‌انداز^۵ توسط (کانمن و تیورسکی^۶، ۱۹۷۹: ۳۹-۴۸) معرفی شد. بنابر نظریه‌ی چشم‌انداز عایدی‌ها و زیان‌ها به طور متفاوتی ارزش‌گذاری می‌شوند و اگر دو گزینه در برابر افراد قرار گیرد به طوری که یکی از گزینه‌ها سود قطعی داشته و دیگری زیان احتمالی، فرد تصمیم‌گیرنده گزینه اول را انتخاب خواهد کرد. این سناریو زمانی که زیان قطعی بوده و دیگری سود احتمالی است، بالعکس می‌شود (کانمن و

^۱. Framing Effect

^۲. Linguistic-Cognitive Phenomenon

^۳. Galperti and Cerigioni (2023)

^۴. Behavioral Finance

^۵. Prospect Theory

^۶. Kahneman and Tversky (1979)

تیورسکی، ۱۹۸۱: ۴۵۳-۴۵۸). برای درک بهتری از موضوع، کانمن و تیورسکی مسئله‌ی بیماری آسیایی را مطرح کرده و براساس آن آزمایش جالبی ترتیب دادند. آنها سناریویی فرضی مبنی بر شیوع یک بیماری کشنده را به تعدادی از داوطلبان ارائه کردند که در آن انتظار می‌رفت این بیماری ۶۰۰ نفر را بکشد. از شرکت‌کنندگان خواسته شد بین دو برنامه جایگزین برای مقابله با این بیماری یکی را انتخاب کنند. دو برنامه به‌طور متفاوتی در مورد منافع (نجات جان) و زیان‌ها (از دست دادن جان) چارچوب‌سازی شده بودند. این دو سناریو به صورت زیر هستند:

سناریو ۱: فرض کنیم ایالات متحده در حال آمادگی برای شیوع یک بیماری عجیب آسیایی است که انتظار می‌رود ۶۰۰ نفر را بکشد. دو برنامه برای مقابله با این بیماری پیشنهاد شده است. برآورد علمی دقیق از عواقب هریک از این برنامه‌ها به شرح زیر است:

- اگر برنامه‌ی A تصویب شود، ۲۰۰ نفر نجات خواهند یافت.
- اگر برنامه‌ی B پذیرفته شود، با احتمال یک سوم ۶۰۰ نفر نجات یافته و با احتمال دو سوم هیچ فردی نجات پیدا نخواهد کرد.

سؤال مهم در اینجا آن است که کدامیک از این دو برنامه را ترجیح می‌دهیم؟ حال این مسئله را با ادبیات کمی متفاوت در بخش عواقب هر روش در نظر بگیریم.

سناریو ۲: در این حالت برنامه‌ی C و D به صورت زیر پیشنهاد می‌شوند:

- اگر برنامه‌ی C اجرا شود، ۴۰۰ نفر خواهند مرد.
- اگر برنامه‌ی D پذیرفته شود، احتمال یک سوم وجود دارد که کسی نمیرد و احتمال دو سوم وجود دارد که ۶۰۰ نفر بمیرند.

مجدداً سؤال مهم در اینجا آن است که کدامیک از این دو را ترجیح می‌دهیم؟

اگرچه برنامه‌ی A و برنامه‌ی C از نظر آماری معادل هستند (نجات ۲۰۰ نفر از ۶۰۰ نفر همانند مرگ ۴۰۰ نفر از ۶۰۰ نفر است)، و برنامه‌ی B و برنامه‌ی D نیز از نظر احتمال و نتیجه معادل هستند، اما نحوه چارچوب‌بندی گزینه‌ها بر انتخاب‌های افراد تأثیر گذاشت.

در چارچوب مثبت (منافع): اکثریت شرکت‌کنندگان (۷۲٪) برنامه A (گزینه مطمئن که در آن ۲۰۰ نفر نجات می‌یابند) را انتخاب کردند، در حالی که فقط ۲۸٪ برنامه B (گزینه احتمالی) را انتخاب کردند.

در چارچوب منفی (زیان‌ها): اکثریت شرکت‌کنندگان (۷۸٪) برنامه D (گزینه احتمالی که در آن احتمال ۳/۱ وجود دارد که هیچ‌کس نمی‌میرد) را انتخاب کردند، در حالی که فقط ۲۲٪ برنامه C (گزینه مطمئن که در آن ۴۰۰ نفر خواهند مرد) را انتخاب کردند.

پس از این معرفی و تشریح مسئله با سناریو بیماری آسیایی، در سال‌های بعد مفهوم قاب‌بندی در زمینه‌های دیگری نیز تعریف، بررسی و استفاده شد؛ تبلیغات، مدیریت ریسک (کوهرگر^۱، ۱۹۹۸: ۲۳-۵۵)، سیاست (دارشینگ و همکاران^۲، ۲۰۱۷: ۲۹۵-۳۰۵) و اقتصاد (لانسفورد^۳، ۲۰۲۰: ۲۹۳۴-۲۸۹۹) نمونه‌هایی از آن هستند.

از اثر قاب‌بندی در مواردی به عنوان سوگیری قاب‌بندی^۴ نیز یاد می‌شود. این سوگیری در موارد بسیاری چون سخنرانی‌ها، ارتباطات، و خرید و فروش دیده می‌شود. بخش مورد هدف در این مقاله، اثر قاب‌بندی در سیاست‌گذاری، سرمایه‌گذاری و بازارهای مالی است. مورد معامله در بازار می‌تواند ارز، سهام شرکت‌ها، اوراق قرضه، حق تقدم، طلا، انواع کالا و موارد دیگر باشد (خیمنز و کاسانو^۵، ۲۰۲۳: ۱۰۱-۱۰۹). به دلیل اهمیت نرخ ارز در سیاست‌های اقتصادی، در این مقاله اثر قاب‌بندی بر نرخ ارز مورد بررسی قرار می‌گیرد.

برای ارزیابی اثر قاب‌بندی بر نرخ ارز، باید تغییرات نرخ ارز متأثر از یک خبر با قاب‌بندی‌های متفاوت ارزیابی شود. در عین حال باید اطمینان حاصل شود که این تغییرات در اثر قاب‌بندی متفاوت و نه عوامل احتمالی دیگر ایجاد شده است. در این راستا مدل جامعی توسعه داده شده که تمامی عوامل مؤثر بر نرخ ارز و قاب‌بندی‌های مختلف را نیز به صورت متنی دریافت

^۱. Kühberger (1998)

^۲. Dharshing et al. (2017)

^۳. Lunsford (2020)

^۴. Framing Bias

^۵. Jiménez and Cosano (2023)

کند. با این رویکرد، علاوه بر اینکه مدل جامعی برای پیش‌بینی نرخ ارز خواهیم داشت، می‌توان اثر قاب‌بندی را نیز به صورت سیستماتیک نمایش داده و تحلیل کرد. مدل پیشنهادی مبتنی بر یادگیری ماشین^۱ بوده و از انواع داده‌های عددی (سری‌های زمانی)، دسته‌ای^۲ و متنی برای پیش‌بینی استفاده می‌کند.

۲- پیشینه‌ی پژوهش

به منظور حفظ اختصار مهم‌ترین و مرتبط‌ترین پژوهش‌ها در این بخش ذکر شده است. پژوهش‌های داخلی (جدول ۱) و خارجی (جدول ۲) مطروحه در این بخش، از چند منظر شامل نوع مدل مورد استفاده، بازه‌ی زمانی و نوع داده‌ی مورد استفاده، و همچنین روش جاسازی (نحوه‌ی تبدیل متن به بردارهای عددی) قابل دسته‌بندی هستند. استفاده از مدل‌های اقتصادسنجی، آماری و یادگیری ماشین در پژوهش‌ها مرسوم بوده، اما تا کنون اخبار منتشره به صورت مستقیم در پیش‌بینی نرخ ارز در ایران مورد استفاده قرار نگرفته است. همچنین پژوهشی در مورد بررسی اثر قاب‌بندی بر نرخ ارز در ایران، و تحلیل سیستماتیک و مبتنی بر داده انجام نشده است.

جدول ۱- پیشینه‌ی پژوهش‌های داخلی

پژوهش	مدل، ویژگی‌ها و پارامترها
دمیری و همکاران ^۳ (۲۰۲۰: ۲۲۰-۲۴۴)	مدل: تشخیص الگوهای پویایی سیستم در بازه‌ی ۱۳۸۳ تا ۱۴۰۱: ۱- تعداد ۴۱ شاخص و متغیر اقتصادی برای بازنمایی پویایی سیستم ۲- نرخ ارز رسمی سال پایه ۳- شاخص قیمت مصرف‌کننده در کشور معیار و میانگین شاخص قیمت مصرف‌کننده در کشورهای شریک تجاری
هاشمی‌دیزج و همکاران ^۴ (۲۰۲۰: ۵۳-۸۰)	مدل: شبکه‌ی عصبی MLP با تنظیمات مختلف نرون‌ها در بازه‌ی ۲۰۰۱ تا ۲۰۱۶ برای ارز یورو-دلار: ۱- نرخ ارز در بازه‌ی ۸ روز گذشته ۲- میانگین متحرک قیمت در ۸ روز گذشته ۳- اسلاتور RSI با پارامتر ۱۴ و نوسانگر تصادفی با پارامتر (۳، ۳، ۵) در ۸ روز گذشته ۴- نمودار شمعی با اندازه بدنه ۲ در ۸ روز گذشته
مدل: ۱- الگوی لجستیک هاروی ۲- الگوی توسعه‌یافته‌ی هاروی با عبارات غیر خطی	

1. Machine Learning

2. Categorical

3. Damiri et al. (2020)

4. Hashemi Dizaj et al. (2020)

پژوهش	مدل، ویژگی‌ها و پارامترها
منصوری‌گرگوری و خداویسی ^۱ (۲۰۱۹): ۱۴۱-۱۷۹	مدل: شبکه‌ی عصبی SOM بازگشتی در بازه‌ی فروردین ۱۳۹۲ تا خرداد ۱۳۹۸: ۱- نرخ روزانه دلار بازار آزاد
بیات ^۲ (۲۰۱۸): ۸۴-۵۵	مدل: شبکه‌ی عصبی SOM بازگشتی در بازه‌ی فروردین ۱۳۸۴ تا آبان ۱۳۹۶: ۱- نرخ ارز رسمی و غیررسمی ماهیانه در ۱۵۲ ماه ۲- نرخ تورم ماهانه ایران و آمریکا ۳- قیمت نفت ایران، حجم صادرات نفت ایران، سهم ایران از صادرات نفت خلیج فارس، سهم ایران از تولید نفت جهان، تراز غیر نفتی ۴- شاخص کل بورس اوراق بهادار ۵- رابطه‌ی مبادله، شاخص قیمت مسکن، قسمت طلای جهانی
یارمحمدی و محمودوند ^۳ (۲۰۱۵): ۱۳۷-۱۴۶	مدل: مجموعه مقادیر تکین (SSA) در بازه‌ی تیر ۱۳۹۲ تا شهریور ۱۳۹۴: ۱- نرخ ارز غیررسمی (بازار آزاد)
شیرازی و همکاران ^۴ (۲۰۱۴): ۵-۲۴	مدل: گام تصادفی در بازه‌ی ۱۹۷۳ تا ۲۰۱۱: ۱- نرخ ارز آزاد ۲- حجم نقدینگی ۳- نرخ بهره‌ی اسمی ایران و آمریکا ۴- نرخ تورم ایران و آمریکا
خداویسی و ملابهرامی ^۵ (۲۰۱۲): ۱۲۹-۱۴۴	مدل: معادلات دیفرانسیل تصادفی حرکت براونی ژنومتری و انتشار-پرش مرتن در بازه‌ی ۲۳ فروردین ۱۳۸۰ تا اول مرداد ۱۳۹۰: ۱- داده‌های نرخ ارز منتشره در سایت بانک مرکزی
خاشعی و همکاران ^۶ (۲۰۱۲): ۱-۱۴	مدل: ۱- شبکه‌ی عصبی MLP برای رگرسیون ۲- شبکه‌ی عصبی PNN برای تشخیص روند در بازه‌ی ۱۳ بهمن ۱۳۸۴ تا ۱۸ خرداد ۱۳۸۵: ۱- نرخ ارز روزانه یورو-ریال
تقوی و خدام ^۷ (۲۰۱۱): ۱۴۷-۱۹۲	مدل: ۱- مدل بازار دارائی‌ها ۲- مدل ماندل-فلمینگ ۳- مدل پولی با قیمت انعطاف‌پذیر ۴- مدل برابری قدرت خرید در بازه‌ی ژانویه ۱۹۸۸ تا ۱ ژوئن ۲۰۰۸: ۱- نرخ برابر یوند-دلار ۲- حجم نقدینگی آمریکا و انگلیس ۳- نرخ بهره‌ی آمریکا و انگلیس ۴- نرخ تورم آمریکا و انگلیس
ابونوری و همکاران ^۸ (۲۰۰۹): ۱۰۱-۱۲۰	مدل: خانواده‌ی مدل‌های ARCH در بازه‌ی ۱ اسفند ۱۳۸۱ تا ۱۹ مهر ۱۳۸۶: ۱- نرخ ارز روزانه مستخرج از سایت بانک مرکزی
زرانژاد و همکاران ^۹ (۲۰۰۸): ۱۰۷-۱۳۰	مدل: ۱- شبکه‌ی عصبی MLP برای رگرسیون ۲- مدل رگرسیون خطی ۳- مدل ARIMA در بازه‌ی ۱۳۳۸ تا ۱۳۸۱: ۱- نرخ ارز (دلار) بازار آزاد و رسمی ۲- شاخص واردات کل ۳- شاخص نسبت قیمت داخلی به خارجی ۴- شاخص حجم پول

- Mansourigargari and Khodaveisi (2019)
- Bayat (2018)
- Yarmohammadi and Mahmoudvand (2015)
- Shirazi et al. (2014)
- Khodaveisi and Molla-Bahrami (2012)
- Khashei et al. (2012)
- Taghavi and Khoddam (2011)
- Abunouri et al. (2020)
- Zaranzhad et al. (2008)

پژوهش	مدل، ویژگی‌ها و پارامترها
مرزبان و همکاران ^۱ (۲۰۰۵: ۱۵-۳۱)	مدل: ۱- شبکه‌ی عصبی MLP برای رگرسیون غیرخطی ۲- رگرسیون خطی ۳- فرآیند گام تصادفی ۴- نظریه برابری قدرت خرید در بازه‌ی مهر ۱۳۵۹ تا دی ۱۳۸۱: ۱- نرخ ارز بازار رسمی و آزاد ۲- شاخص قیمت مصرف‌کننده در ایران و امریکا

* طراحی و جمع‌آوری شده توسط نویسندگان مقاله.

جدول ۲ - پیشینه‌ی پژوهش خارجی با تمرکز بر استفاده از داده‌ی متنی در پیش‌بینی نرخ ارز*

پژوهش	تکات مهم
ویلامیل و همکاران ^۱ (۲۰۲۳)	۱- از یادگیری عمیق برای پیش‌بینی جهت حرکت قیمت سهام براساس اخبار و داده‌های قیمت استفاده شده است. ۲- برای پیش‌بینی جهت نرخ هر روز، اخبار و داده‌های مربوطه در ۵ روز گذشته مورد استفاده قرار می‌گیرد. ۳- ارزیابی مدل براساس معیار دقت انجام شده است. جاسازی: Word2Vec و BERT مدل: یادگیری عمیق، Bi-LSTM
لوپز و تنگ ^۲ (۲۰۲۳)	۱- در این پژوهش مدلی توسعه داده نشده و از ChatGPT نسخه‌ی ۳/۵ به عنوان مدل زبانی بزرگ برای پیش‌بینی جهت حرکت سهام براساس اخبار منتشر شده استفاده شده است. ۲- خبر به صورت یک دستور ۴ مشخص به ChatGPT داده شده و سپس سوال می‌شود که به ازای این خبر، قیمت سهم X بالا می‌رود، تغییری نمی‌کند، یا پائین خواهد آمد؟ ۳- این پژوهش مانند آن است که یک تحلیل‌گر احساسات براساس خبر ورودی با استفاده از ChatGPT ساخته شده باشد. جاسازی: --- مدل: ChatGPT-v3.5
دنیلسون و گرم ^۳ (۲۰۲۳: ۱۰۱-۱۰۹)	۱- از مدل یادگیری عمیق LSTM برای پیش‌بینی یک ساعت آینده‌ی نرخ یورو-دلار در بازار فارکس استفاده شده است. ۲- بردارهای ورودی به مدل از به هم چسباندن بردار قیمت و معیارهای بازار و بردارهای خروجی حاصل از جاسازی تولید شده است. جاسازی: BERT مدل: یادگیری عمیق، LSTM
شیلپا و شامبهاوی ^۴ (۲۰۲۱: ۷۷۳-۷۴۸)	۱- علاوه بر معیارها و اندیکاتورهای موجود در بازار، از مجموعه‌ای از داده‌های متنی شامل اخبار، ترندهای گوگل، و توییت‌ها استفاده شده است. ورودی مدل، برداری است که از ترکیب خروجی بخش تحلیل احساس (براساس اخبار) و مقادیر عددی مربوط به سهم تشکیل می‌شود. ۲- مدل مبتنی بر یادگیری عمیق LSTM برای پیش‌بینی بازار سهام کشور غنا به کار رفته است. به جاسازی مورد استفاده اشاره‌ای نشده است. به نحوی که مقادیر عددی در کنار خروجی تحلیل احساس از متون، ورودی مدل هستند. جاسازی: --- مدل: یادگیری عمیق، LSTM
سمیرومی و همکاران ^۵	۱- حالت‌های مختلفی از جاسازی‌های خانواده‌ی TF-IDF، لغت‌نامه‌های تشخیص احساسات و ترکیب آن‌ها مورد ارزیابی قرار گرفته است. ۲- از مدل‌های RF، SVM و XGB برای پیش‌بینی جهت حرکت چند جفت‌ارز دلار، یورو، فرانک و ین برای ۳۰ دقیقه‌ی آینده در بازار فارکس استفاده شده است. جاسازی: TF-IDF مدل: SVM, RF, XGB

1. Marzban et al. (2005)

2. Willamil et al. (2023)

3. Lopez et al. (2023)

4. Prompt

5. Danielsson and Gramer (2023)

6. Shilpa and Shambhavi (2021)

7. Semiromi et al. (2020)

تکات مهم	پژوهش
	۱۱۱-۲۰۲۰) (۱۰۱)
۱- از مدل‌های تطابق الگو و قاعده‌ی بر مبنای فرکانس یا رخداد کلمات خاص در متون برای تولید یک مدل تشخیص احساس استفاده شده است. ۲- مجموع ایده‌های ارائه شده برای متون مالی، نسبت به روش‌های کلاسیک BoW عملکرد بهتری داشته است. جاسازی: TF و TF-IDF مدل: تطابق الگو مبتنی بر قاعده	چان و چونگ ^۱ (۲۰۱۷: ۶۴- (۵۳)
۱- از یک مدل تشخیص احساسات براساس تطابق الگو و رخداد کلمات به منظور مدل‌سازی رفتار کاربران براساس اخبار منتشره در بازار سهام استفاده شده است. جاسازی: TF مدل: تطابق الگو	لیمان و همکاران ^۲ (۲۰۱۶: ۱۷۵- (۱۵۹)
۱- تلاش شده تا با استفاده از یک مدل SMF یا همان فاکتورسازی ماتریس پراکنده ۴ جهت حرکت سهام S&P500 را براساس متن توئیت‌های منتشر شده پیش‌بینی کنند. در این پژوهش ماتریس معادل داده‌های متنی در کنار داده‌های عددی بازار ورودی مدل هستند. ۲- در مدل ارائه شده بخش تشخیص احساسات به صورت صریح و جداگانه وجود ندارد. جاسازی: TF-IDF مدل: SMF	سان و همکاران ^۳ (۲۰۱۶: ۲۸۱- (۲۷۲)
۱- برای پیش‌بینی بازار سهام از یک مدل تشخیص احساسات مبتنی بر قاعده ۶ استفاده شده است. این مدل مبتنی بر یک لغت‌نامه بوده و تلاش شده تا با استفاده از خروجی مدل روند حرکت سهم تشخیص داده شود. ۲- از مدل توسعه‌داده شده در یک سناریوی یادگیری تقویتی یا RL استفاده شده و مونتوم انجام معاملات براساس بازخوردهای بازار تنظیم شده است. جاسازی: به طور ضمنی TF مدل: یادگیری تقویتی مبتنی بر قاعده	فیوری اگل و پرندیکر ^۴ (۲۰۱۶: ۷۴- (۶۵)
۱- از مدل SVM با هسته‌ی چندگانه ^۵ برای بررسی جهت حرکت سهم در حوزه‌ی سلامت استفاده شده است. روش مورد استفاده در واقع نوعی از ایده‌ی یادگیری جمعی است. جاسازی: TF-IDF مدل: MV-SVM	شاینکوچ و همکاران ^۶ (۲۰۱۶: ۷۴-۸۳)
۱- برای پیش‌بینی نرخ جفت ارز یورو-دلار در بازار فارکس، از مدل SVM استفاده شده است. خروجی مرحله‌ی تحلیل احساسات مبتنی بر اخبار، در کنار داده‌گان مربوط به قیمت ورودی مدل نهایی هستند. جاسازی: N-Grams مدل: SVM	نصیرطوسی و همکاران ^۷ (۲۰۱۵: ۳۲۴- (۳۰۶)

* طراحی و جمع‌آوری شده توسط نویسندگان مقاله.

1. Chan and Chong (2017)
2. Liebmann et al. (2016)
3. Sun et al. (2016)
4. Sparse Matrix Factorization
5. Feuerriegel and Prendinger (2016)
6. Rule-Based
7. Shynkevich et al. (2016)
8. Multi-Kernel SVM
9. Nassirtoussi et al. (2015)

۳- روش تحقیق

به منظور بررسی اثر قاب‌بندی بر نرخ ارز، در این پژوهش روشی مبتنی بر یادگیری ماشین پیشنهاد شده که به عنوان مدلی جامع از انواع داده‌ها از جمله داده‌های متنی استفاده می‌کند. یادگیری ماشین زیرمجموعه‌ای از هوش مصنوعی است که در آن سیستم‌ها دانش خود را با استخراج الگوها^۱ از داده‌های فراهم شده بدست می‌آورند. به عبارت دیگر در این سیستم‌ها دانش از قبل برنامه‌ریزی^۲ نشده است (کاپور و همکاران^۳، ۲۰۲۲). روش پیشنهادی از نوع یادگیری بانظارت^۴ است که در آن به ازای هر نمونه داده یک برچسب^۵ نیز وجود دارد. در این حالت باید مدلی ساخته شود که بتواند با داده‌های ورودی این برچسب را به درستی پیش‌بینی کند. در شکل ۱۲ اجزاء اصلی و فرآیند کلی آموزش در یک سیستم یادگیری نظارت شده نمایش داده شده است.

در این فرآیند به ازای داده‌های ورودی به مدل اولیه، یک خروجی محاسبه می‌شود. تفاوت این خروجی با برچسب واقعی متناظر با داده‌ی ورودی، تابع خطا را تشکیل می‌دهد. هدف تنظیم پارامترهای مدل به نحوی است که تابع خطا کمینه شود. انتخاب نحوه‌ی بهینه‌سازی تابع خطا، نحوه‌ی بروزرسانی پارامترهای مدل و نحوه‌ی تعریف تابع خطا، بسته به هر الگوریتم یادگیری متفاوت است. روش‌های زیادی براساس کاربرد و نوع داده‌ها در دسته‌ی یادگیری‌های بانظارت قرار می‌گیرند. در این پژوهش به دلیل توانمندی مناسب در کار با بردارهای ورودی بزرگ (حاصل از جاسازی متون)، مدل‌سازی روابط غیر خطی پیچیده و وابستگی‌های زمانی، از شبکه‌ی عصبی عمیق بانظارت استفاده شده است. فارغ از مدل، روش پیشنهادی در واقع یک چارچوب حل مسئله با یادگیری ماشین است؛ این چارچوب که اصطلاحاً خط لوله‌ی پردازش نیز نامیده

1. Patterns

2. Programmed

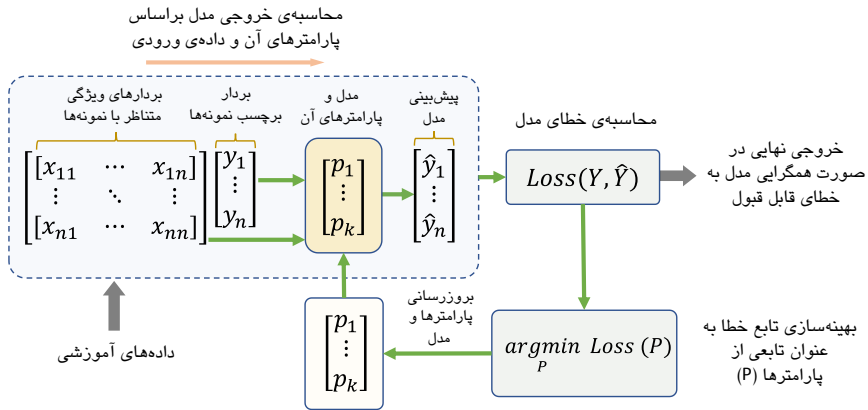
3. Kapoor et al. (2022)

4. Supervised Learning

5. Label

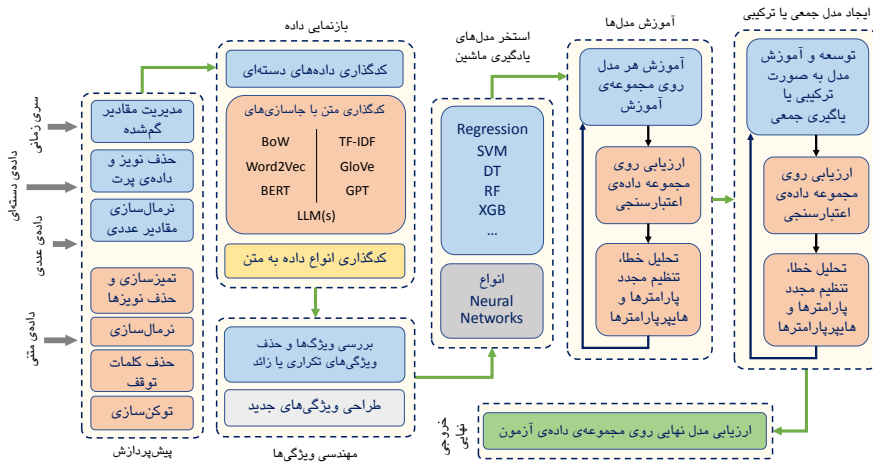
6. Pipeline

می‌شود، در شکل ۱۳ نمایش داده شده است. اقدامات انجام شده در هر بخش از این خط لوله، در ادامه تشریح شده است.



شکل ۱۲ - معماری کلی یک روش یادگیری با نظارت *

* طراحی شده توسط نویسندگان مقاله



شکل ۱۳ - خط لوله‌ی پردازش داده، آموزش و تنظیم مدل ترکیبی نهایی *

* طراحی شده توسط نویسندگان مقاله

۳-۱- داده‌گان^۱ مورد استفاده

داده‌گان مورد استفاده شامل داده‌گان مربوط به نرخ واقعی ارز (بازار آزاد) از ابتدای سال ۱۳۹۳ تا پایان تیرماه ۱۴۰۲ است. این داده‌ها از وب‌سایت صرافی ملی^۲، وب‌سایت شبکه‌ی اطلاع‌رسانی نرخ طلا و ارز^۳، و وب‌سایت بن‌بست^۴ به عنوان سه مرجع با دیدگاه‌های مختلف جمع‌آوری و مطابقت داده شده است. هر سطر از این داده‌ها، شامل نرخ باز شدن، نرخ بسته شدن، کمترین نرخ معامله و بیشترین نرخ معامله در هر روز است. بخش دیگری از داده‌گان عددی مانند نرخ تورم، تولید ناخالص داخلی، حجم نقدینگی و غیره، از گزارش‌های بانک مرکزی استخراج شده است. با توجه به اینکه برخی از این داده‌ها به صورت ماهیانه، فصلی یا حتی سالیانه اعلام می‌شوند، به منظور یکسان‌سازی واحد زمانی مدل‌ها، این مقادیر به صورت خطی در طول بازه‌ی گزارش، گسترش یافته‌اند. به عنوان مثال اگر شاخص اقتصادی به صورت ماهیانه اعلام شود، نرخ ابتدا و انتهای ماه را در نظر گرفته و با یک رابطه‌ی خطی ساده مانند $y = mx + b$ نرخ شاخص به ازای هر روز را تخمین می‌زنیم. در این رابطه، m شیب و b عرض از مبدأ خط متصل‌کننده مقادیر ابتدایی و انتهایی شاخص مذکور در یک ماه است. با داشتن دو نقطه از این خط (ابتدا و انتهای هر ماه) به سادگی می‌توان پارامترهای m و b را محاسبه کرد.

علاوه بر داده‌های عددی فوق، تمامی اخبار متنی منتشره توسط بانک مرکزی، روزنامه‌های دنیای اقتصاد، صنعت-معادن-تجارت، آسیا، ابرار اقتصادی و همچنین بخش سیاسی-اقتصادی خبرگزاری‌های ایسنا، خبرآنلاین، تابناک، بی‌بی‌سی فارسی، صدای امریکای فارسی در بازه‌ی زمانی مورد بررسی جمع‌آوری شده است.

۳-۲- پیش‌پردازش داده‌ها

در بخش پیش‌پردازش، اقدامات آماده‌سازی مربوط به هر نوع داده انجام می‌شود. این اقدامات

1. Data

2. <https://www.mex.co.ir/>

3. <https://www.tgju.org/>

4. <https://www.bonbast.com/>

برای سری‌های زمانی و داده‌های عددی مشابه بوده، اما برای داده‌ی متنی به کل متفاوت است.

۳-۲-۱- پیش‌پردازش داده‌های عددی، سری‌های زمانی و داده‌های دسته‌ای

داده‌های عددی نمایانگر مقدار یک شاخص یا پارامتر به صورت عددی هستند. اگر این داده‌ها به صورت توالی زمانی گزارش شوند به نحوی که تغییرات یک شاخص در زمان را منعکس کنند، از آن‌ها به عنوان سری زمانی تعبیر می‌شود. داده‌های دسته‌ای، نوع دیگری از داده‌ها هستند که مقدار یک شاخص یا پارامتر را به صورت مجموعه‌ای از انتخاب‌های محدود مشخص می‌کنند. به عنوان مثال تغییرات نرخ ارز می‌تواند با یکی از سه گزینه‌ی موجود در مجموعه‌ی {بدون-تغییر، تغییر-صعودی، تغییر-نزولی} مشخص شود.

پردازش داده‌گان عددی در سه دسته‌ی کلی جای می‌گیرد: ۱- نرمال‌سازی بازه‌ی مقادیر^۱ ۲- مدیریت مقادیر ناموجود^۲ ۳- حذف نویز و مقادیر پرت^۳.

در این مقاله با استفاده از تابع لگاریتم و همچنین نرمال‌ساز توزیع نرمال (سینگ و سنگ^۴، ۲۰۲۰: ۱۰۵-۱۲۴)، داده‌های عددی مسئله نرمال و کران‌دار شده است.

به منظور مدیریت داده‌هایی که در دسترس نیستند، ایده‌های مختلفی چون حذف داده‌ها، و تقریب مقادیر با استفاده از میانگین‌گیری یا درون‌یابی (جوزه و هیوسان^۵، ۲۰۱۲: ۷۹-۹۹) بر اساس داده‌های مجاور بررسی شده‌اند. در این مقاله در مجموع ۱۳ داده‌ی ناموجود داشتیم که حول آن‌ها نوسانات خاصی در نرخ ارز نبود. بنابراین با توجه به پراکنده بودن این داده‌ها در کل مجموعه‌ی داده و عدم توالی آنها، این داده‌ها را از مجموعه‌ی داده حذف کردیم.

داده‌های نامربوط به داده‌هایی اطلاق می‌شود که مقادیر آن‌ها با توجه به مسئله و شرایط آن، غیرممکن و یا بسیار نامحتمل است. به عنوان مثال در مسئله‌ی نرخ ارز در صورتی که قیمت دلار

1. Value Normalization

2. Missing Values

3. Outlier Values

4. Singh and Singh (2020)

5. Josse and Husson (2012)

امروز ۱۰۰۰ تومان بوده، در روز بعد ۱۰۰۰۰ هزار تومان و در روز سوم ۱۱۰۰ تومان باشد، با توجه به مقادیر مشاهده شده و دانش اقتصاد عدد ۱۰۰۰۰ تومان داده‌ی پرت و نویز است. روش‌های بسیار مختلفی برای تشخیص مقادیر نامربوط و تمایز آنها با مقادیر مربوط ولی نادر وجود دارد؛ در این مقاله از آنجا که داده‌ها از جنس سری‌زمانی است، از تحلیل‌های ساده سازگاری داده‌ها با یکدیگر مشابه مثالی که ذکر شد، استفاده شده است. نتایج بدست آمده مؤید کفایت و عملکرد خوب این روش است. در مجموع ۵ داده‌ی نویزی از مجموعه‌ی داده گان حذف شد.

برای داده گان دسته‌ای، کدگذاری^۱های مختلفی چون استفاده از اعداد ترتیبی نرمال شده حول صفر، کدگذاری وان-هات^۲، کدگذاری دودویی^۳ و کدگذاری همینگ^۴ قابل اعمال است (پاتدر و همکاران^۵، ۲۰۱۷: ۷-۹). در این مقاله به دلیل اینکه در داده گان ورودی صرفاً دو حالت مثبت، منفی وجود دارد، از کدگذاری توزیع حول صفر برای برچسب کلاس‌ها استفاده شد.

۳-۲-۲- پیش پردازش داده‌های متنی

پیش‌پردازش داده گان متنی شامل مجموعه اقداماتی است که هدف آن آماده سازی داده به منظور ساخت جاسازی^۶ یا تعبیه برداری بهتر از متن است. در ادبیات یادگیری ماشین، جاسازی‌ها بازنمایی‌هایی به شکل بردارهای عددی از متون، تصویر و انواع فضاهاى ورودی هستند.

شکل ۱۴ - نمونه‌ای از نویز در داده‌ی متنی دریافت شده از صفحات اینترنتی*

```
<title>عدد طلایی بازار برای دلار چند است؟</title>
<script type="text/javascript">
  if (window.top != window) {
    window.top.location.href = "https://donya-e-eqtesad.com/"
  }
</script>
<meta property="og:title" content="عدد طلایی بازار برای دلار چند است؟">
```

1. Coding
2. One-Hot
3. Binary
4. Hamming Coding
5. Potdar et al. (2017)
6. Embedding

* طراحی شده توسط نویسندگان مقاله.

عملیات پیش‌پردازش متنی عموماً عبارتند از: تمیزسازی و حذف داده‌های نویزی، نرمال‌سازی، توکن‌سازی^۱، ریشه‌یابی و حذف کلمات توقف^۲. در مرحله‌ی تمیزسازی هرگونه متن یا علائم زائد موجود در متن اصلی حذف می‌شود. این داده‌ها فاقد ارزش بوده و معنایی به متن اصلی اضافه نمی‌کنند؛ برچسب‌های اچ‌تی‌ام‌ال و سی‌اس‌اس، کدهای جاوااسکریپت و توضیحات موجود در این کدها اغلب زوائد را تشکیل می‌دهند (شکل ۱۴).

شکل ۱۵ - نمونه‌ای از کاراکترهای با معنای یکسان و کد متفاوت*

ی - Ë - ي | ۱ - 6 - ۶

* طراحی شده توسط نویسندگان مقاله.

در ادامه و در مرحله‌ی نرمال‌سازی، انواع مختلف کاراکترهای موجود در متون مختلف که مفهوم یکسان اما کد (اسکی^۳ یا یونیکد^۴) متفاوتی دارند، یکدست و متحدالشکل می‌شوند. نمونه‌هایی از کاراکترهایی با معنی مشابه اما با کد متفاوت در شکل ۱۵ نمایش داده شده است. در گام بعد و مرحله‌ی توکن‌سازی متن ورودی نرمال شده به دنباله‌ای از کلمات یا همان توکن‌ها شکسته می‌شود. به طور کلی هرچه توکن‌ها کمتر باشد، ابعاد مسئله در مرحله‌ی جاسازی و ساخت مدل کاهش خواهد یافت؛ بنابراین با اعمال روش‌هایی چون نرمال‌سازی و ریشه‌یابی^۵ این ابعاد کاهش داده می‌شود^۶.

اقدام دیگر در کاهش تعداد توکن‌ها و ابعاد مسئله، حذف برخی از کلمات فاقد بار معنایی

1. Tokenization

2. Stop Words

3. ASCII

4. Unicode

5. Stemming

۶. منظور از ریشه‌یابی نگاشت^۶ یا تبدیل صور مختلف یک کلمه به ریشه‌ی آنهاست (سینگ و گوپتا، ۲۰۱۶: ۴۶-۱).

به عنوان مثال می‌توان انواع صرف‌های افعال را به بن ماضی یا مضارع آنها نگاشت کرد.

خاص یا همان کلمات توقف است (نایاک و همکاران^۱، ۲۰۱۶: ۱۶۸۷۵-۱۶۸۷۹). به عنوان مثال حروف ربط مانند «از، به، در، با، را، بر» از جمله کلمات توقف هستند. استفاده از ریشه‌یابی و حذف کلمات توقف بستگی به نوع جاسازی مورد استفاده دارد. جاسازی‌های مدرن، از جمله جاسازی استفاده شده در این پژوهش، به دلیل مدیریت فضای بزرگی از کلمات و متون نیازی به این مراحل ندارند.

۳-۳- بازنمایی داده‌های متنی

به منظور بازنمایی داده‌گان متنی به بردارهای عددی، از انواع جاسازی‌ها می‌توان استفاده کرد. در سال‌های اخیر جاسازی‌های متنی مختلفی ارائه شده‌اند که هر یک از آنها تلاش داشتند تا اشکالات موجود در نسخه‌های قبلی را اصلاح کرده یا نیازهای جدیدی را پوشش دهند (لی و ینگ^۲، ۲۰۱۸: ۸۳-۱۰۴). روش‌های خورجین کلمات^۳ یا BoW، فرکانس عبارت^۴ و معکوس فرکانس سند^۵ یا TF-IDF، Word2Vec (میکولوف و همکاران^۶، ۲۰۱۳)، GloVe^۷ (پنینگتن و همکاران^۸، ۲۰۱۴)، FastText (بوجانوسکی و همکاران^۹، ۲۰۱۷: ۱۳۵-۱۴۶)، ELMo^{۱۰} (سرزاینسکا و همکاران^{۱۱}، ۲۰۱۸)، BERT^{۱۲} (دولین و همکاران^{۱۳}، ۲۰۱۸)، GPT^{۱۴} (براون و همکاران^{۱۵}، ۲۰۲۰: ۱۹۰۱-۱۸۷۷)، همگی تلاش دارند تا اسناد متنی را به بردارهای عددی تبدیل کنند.

1. Nayak et al. (2016)

2. Li and Yang (2018)

3. Bag of Words

4. Term Frequency

5. Inverse Document Frequency

6. Mikolov et al. (2013)

7. Global Vectors

8. Pennington et al. (2014)

9. Bojanowski et al. (2017)

10. Embeddings from Language Models

11. Sarzynska et al. (2018)

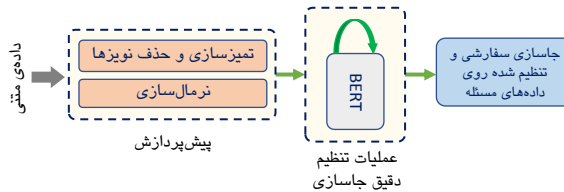
12. Bi-directional Embedding Representations from Transformers

13. Devlin et al. (2018)

14. Generative Pre-trained Transformer

15. Brown et al. (2020)

شکل ۱۶ - تنظیم دقیق جاسازی روی داده‌های متنی پژوهش *



* طراحی شده توسط نویسندگان مقاله.

در این پژوهش به دلیل حفظ روابط معنایی^۱ و نحوی^۲، قابلیت تنظیم دقیق^۳، در دسترس بودن و عملکرد مناسب از جاسازی BERT فارسی (فراهانی و همکاران^۴، ۲۰۲۱: ۳۸۳۱-۳۸۴۷) به عنوان جاسازی پایه استفاده شده که با داده‌گان مرتبط با پژوهش، تنظیم دقیق شده است (شکل ۱۶). جزئیات این فرآیند در (سوسا و همکاران^۵، ۲۰۱۹) موجود است. خروجی جاسازی تنظیم شده به ازای هر سند ورودی، یک بردار با ابعاد ۷۶۸ است.

۳-۴- مهندسی ویژگی‌ها

مهندسی ویژگی‌ها فرآیندی است که در آن سودمندی یا زائد بودن ویژگی‌های موجود بررسی شده و یا ویژگی‌های جدیدی بر اساس نیاز مسئله تعریف می‌شود (نرگسیان و همکاران^۶، ۲۰۱۷: ۱۹۶-۲۳۵). مرسوم‌ترین روش تشخیص ویژگی‌های زائد، روش بررسی همبستگی یا همان روش تحلیل سیستم ویژه^۷ است (هیتون^۸، ۲۰۱۶). در این روش از عدد و وضعیت^۹ استفاده می‌شود که به صورت رابطه‌ی ۱ تعریف می‌شود:

1. Semantic
2. Syntactic
3. Fine-Tuning
4. Farahani et al. (2021)
5. Sousa et al. (2019)
6. Nargesian et al. (2017)
7. Eigen System Analysis
8. Heaton (2016)
9. Condition Number

$$k = \frac{\lambda_{max}}{\lambda_{min}} = \frac{\max(EigenValues)}{\min(EigenValues)} \quad (1)$$

به ازای بردار ویژگی‌ها به شکل $X = [X_1, \dots, X_n]$ ، همبستگی آن‌ها به صورت زیر است:

$$Corr(X) = \begin{bmatrix} \rho_{11} & \cdots & \rho_{1n} \\ \vdots & \ddots & \vdots \\ \rho_{n1} & \cdots & \rho_{nn} \end{bmatrix}, \quad \rho_{nn} = \frac{COV(X_i, X_j)}{X_{\sigma_i} X_{\sigma_j}} \quad (2)$$

اگر درایه‌ی ρ_{ij} از ماتریس همبستگی X ، عدد وضعیت بزرگ‌تر از ۱۰۰ داشته باشد، نشان‌دهنده هم‌خطی جدی در آن دو ویژگی است و می‌توان یکی را حذف کرد (نرگسیان و همکاران، ۲۰۱۷: ۲۳۵-۱۹۶). برای ویژگی‌های عددی مؤثر در نرخ ارز، پس از انجام تحلیل فوق، به ویژگی‌های قیمت ارز در باز و بسته شدن بازار، میانگین نرخ روزانه، نرخ برابری ارز یورو-دلار در پایان هر روز، نرخ تورم ماهیانه ایران، نرخ تورم ماهیانه آمریکا، و نرخ تولید داخلی ایران و آمریکا رسیدیم.

۳-۵- مدل پیشنهادی

به منظور ارزیابی اثر قاب‌بندی و تأثیر اخبار بر نرخ ارز، باید مدل‌هایی داشته باشیم که در یکی از آنها صرفاً از داده‌های عددی و دسته‌ای استفاده شده و در مدل دیگر علاوه بر این داده‌ها، از داده‌های متنی (خبری) نیز استفاده شده باشد. با این رویکرد، در این پژوهش سه مدل توسعه داده شده است. در تمامی مدل‌ها از انواع داده‌های عددی و دسته‌ای برای مدل‌سازی نرخ ارز استفاده شده است. در مدل‌های اول و سوم، با دو تکنیک مختلف داده‌های متنی (اخبار) نیز علاوه بر سایر داده‌ها در مدل‌سازی نرخ ارز لحاظ شده است.

هر سه مدل از نوع بانظارت و کلاس‌بند هستند؛ مدل اول پوشش کاملی از انواع داده‌های مرتبط با پیش‌بینی نرخ ارز داشته، نسبت به قاب‌بندی اخبار مقاوم بوده و توانایی قضاوت در مورد تأثیر احتمالی یک خبر و قاب‌بندی آن بر نرخ ارز را دارد. برای تبدیل نرخ عددی ارز به یک مسئله

تشخیص حرکت قیمت^۱، رابطه‌ی ۳ را داریم:

$$\text{Label}(t) = y_t = \begin{cases} -1, & p_t \leq p_{t-1} \\ 1, & p_t > p_{t-1} \end{cases} \quad (3)$$

ورودی مدل مجموعه‌ای از مقادیر در پنجره‌ای از زمان، f ، در گذشته است. طول این پنجره از پارامترهای مسئله است؛ در این پژوهش با سعی و خطا عدد ۵ برای پنجره در نظر گرفته شد. به عبارت دیگر، برای هر پیش‌بینی در زمان t ، مقادیر ورودی در بازه‌ی $t - f + 1, \dots, t$ [1]، به مدل داده می‌شود.

بردار ورودی به مدل به ازای هر روز، شامل خروجی جاسازی به ازای هر سند و مقادیر متغیرهای بدست آمده از مرحله‌ی مهندسی ویژگی است. با قراردادن بردار حاصل از جاسازی متنی، به ازای هر سند یا خبر در روز t ، برداری به صورت $[e_R^t, \dots, v_i^t, \dots, e_K^t, \dots, e_1^t]$ خواهیم داشت که در آن e_i^t مقدار هر درایه از بردار جاسازی به طول K ، و v_i بیانگر مقدار نرمال شده‌ی یک متغیر عددی از مجموع R متغیر عددی است. این بردار را به صورت D_p^t نمایش داده و آن را به صورت بردار داده برای دنباله‌ی خبر p در روز t تفسیر می‌کنیم. با این کدگذاری از مسئله، برای هر روز، به تعداد اخبار موجود از منابع مختلف، نمونه خواهیم داشت. منظور از دنباله‌ی خبر، هر ترکیب از اخبار در روزهای متوالی در پنجره‌ی f است. از آنجا که مدل تعداد f حالت قبل را نیز به ازای هر خبر در نظر می‌گیرد، به فرض آنکه در هر روز از هر منبع به طور میانگین n_{avg} خبر منتشر شود، به ازای هر منبع $(n_{avg})^f$ نمونه برای تغذیه‌ی مدل خواهیم داشت. اگر تعداد منابع خبری برابر با E باشد، به ازای هر روز $E \times (n_{avg})^f$ نمونه خواهیم داشت. این نمونه‌ها را با نسبت‌های ۸۰، ۱۰ و ۱۰ به ترتیب برای آموزش، اعتبارسنجی و ارزیابی مدل مورد استفاده قرار داده‌ایم.

شبکه‌های عصبی عمیق، بهترین راهکار در مسائلی با بردارهای ورودی بزرگ، پیچیدگی‌های ذاتی و روابط غیرخطی است (خان و همکاران^۲، ۲۰۲۳: ۱۰۰-۱۲۶). در اینجا

¹ Price Movement Detection

² Khan et al. (2023)

هسته‌ی اصلی مدل انتخاب شده GRU دوطرفه یا Bi-GRU^۱ است که در زمهری شبکه‌های عصبی تکرارپذیر^۲ قرار می‌گیرد (سبیه و همکاران^۳، ۲۰۲۳: ۲۰۳-۲۱۵). همچنین مدل پیشنهادی به دلیل ترکیب و استفاده از انواع داده در فرآیند آموزش و پیش‌بینی، ذیل تکنیک‌های تلفیق داده^۴ قابل طبقه‌بندی است (لیو و همکاران^۵، ۲۰۲۰: ۱۲۳-۱۳۳).

ساختار کلی مدل استفاده شده، در شکل ۱۷ نمایش داده شده است. بردارهای عددی بعد از پردازش در مرحله‌ی نرمال‌سازی عددی و تولید خروجی جاسازی به مدل GRU وارد می‌شوند. این مدل دارای تعدادی مرحله یا دروازه^۶ است. تعداد این مراحل به اندازه پنجره‌ی وابستگی زمانی یا همان f است. مدل پیشنهادی در هر مرحله، داده‌گان مربوط به f روز گذشته را دریافت کرده و براساس آن وزن‌ها یا پارامترهای مدل را بروز می‌کند. تابع خطا کراس آنروپی^۷ بوده و در رابطه‌ی ۴ نمایش داده شده است. در این رابطه \hat{y}^t پیش‌بینی مدل و y^t برچسب حقیقی داده در زمان (روز) t است. این تابع توسط بهینه‌ساز ADAM^۸ در فرآیند آموزش بهینه می‌شود.

$$Loss(t) = \frac{1}{T} \sum_{t=1}^T (y^t \log(\hat{y}^t) + (1 - y^t) \log(1 - \hat{y}^t)) \quad (۴)$$

به منظور جلوگیری از بیش‌برازش^۹ و سوگیری مدل، از دو تکنیک رگولاریزیشن^{۱۰} متداول در شبکه‌های عصبی عمیق با عنوان دوراندازی^{۱۱} و نرمال‌سازی دسته‌ای^{۱۲} استفاده شده است.

1. Bi-Directional Gated Recurrent Unit

2. Recurrent Models

3. Seabe et al. (2023)

4. Data Fusion

5. Liu et al. (2020)

6. Gate

7. Cross-Entropy

8. Adaptive Moment Estimation

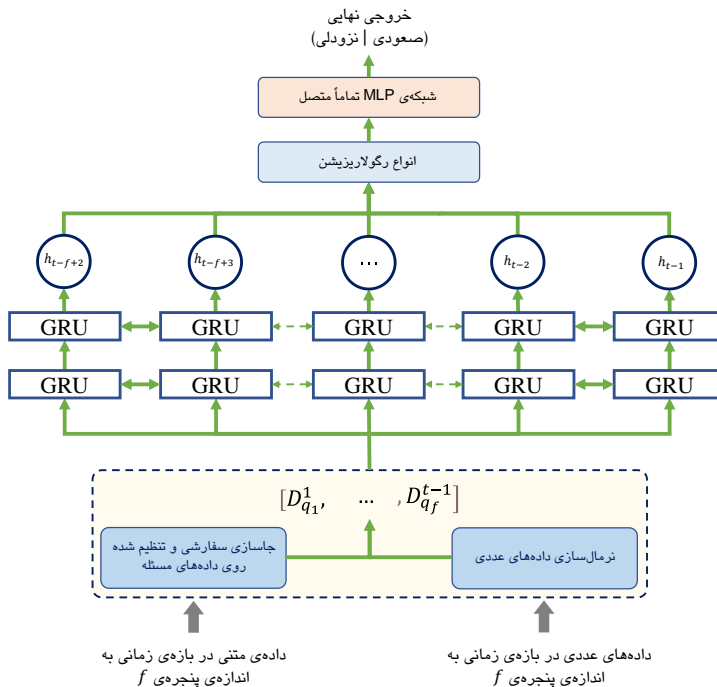
9. Overfitting

10. Regularization

11. Dropout

12. Batch Normalization

شکل ۱۷ - مدل پیشنهادی مبتنی بر تلفیق داده و یادگیری عمیق *



* طراحی شده توسط نویسندگان مقاله.

برای تجمع خروجی مراحل مدل GRU^۱ در لایه‌ی آخر شبکه از یک لایه شبکه عصبی MLP^۲ به صورت تماماً متصل^۳ استفاده شده است. تابع فعال‌سازی این شبکه تابع سافت‌مکس^۴ بوده و خروجی نهایی به صورت دودویی مشخص می‌شود. مدل دوم نیز کاملاً مشابه مدل اول بوده با این تفاوت که در آن صرفاً از داده‌های عددی برای پیش‌بینی نرخ ارز استفاده شده و اخبار و داده‌های متنی در آن نقشی ندارند.

1. Gated Recurrent Unit
 2. Multi Layer Perceptron
 3. Fully Connected
 4. Softmax

به دلیل عملکرد مناسب جاسازی‌ها و مدل‌های زبانی بزرگ در مدل‌سازی روابط معنایی، در مدل سوم، تأثیر همه‌ی داده‌های عددی با جملاتی به متن تبدیل شده و سپس خروجی جاسازی متنی به مدل داده می‌شود. به عنوان مثال تغییرات عددی متغیرها به صورت جملات متنی به صورت زیر به انتهای اخبار اضافه شد:

- امروز «نرخ دلار آمریکا» نسبت به روز گذشته به میزان کمی افزایش داشته است.
 - امروز «نرخ دلار آمریکا» نسبت به روز گذشته به میزان بسیار زیادی کاهش داشته است.
- بنابراین ورودی مدل سوم، صرفاً بردارهای حاصل از خروجی جاسازی روی متون خواهد بود.

۴- نتایج و بحث

هدف از این پژوهش، بررسی اثر قاب‌بندی بر تغییرات نرخ ارز در ایران با روشی دقیق و سیستماتیک است. لازمه‌ی این ارزیابی، داشتن مدلی برای توصیف نرخ ارز است که تمامی انواع داده‌ی مؤثر بر این شاخص اقتصادی، از جمله اخبار منتشره با قاب‌بندی‌های مختلف را در نظر گیرد. با توجه به این الزام و هدف پژوهش، دو دسته آزمایش طراحی شده است؛ دسته‌ی اول، به بررسی تأثیر اخبار بر تغییرات نرخ ارز اختصاص دارد. در این آزمایش‌ها هدف بررسی توانایی مدل‌های توسعه داده شده در مدل‌سازی نرخ ارز با در نظر گرفتن اخبار و بدون آن است. پس از اطمینان از کارایی مدل‌ها، از آن‌ها در دسته‌ی دوم از آزمایش‌ها به منظور تحلیل اثر قاب‌بندی بر نرخ ارز استفاده شده است.

۴-۱- ارزیابی مدل در پیش‌بینی نرخ ارز

برای ارزیابی مدل، از داده‌ی آزمون که هیچ‌یک از مدل‌ها آنها را از پیش ندیده‌اند، استفاده شده است. ۱۰٪ از داده‌های موجود در مجموعه‌ی داده، به عنوان داده‌ی آزمون در نظر گرفته شده‌اند. معیار ارزیابی دقت^۱ مدل است که به صورت رابطه‌ی ۵ تعریف می‌شود:

^۱. Accuracy

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (5)$$

تفسیر پارامترهای رابطه‌ی فوق براساس ماتریس درهم ریختگی^۱ است که در شکل ۱۸ نمایش داده شده است. به طور خلاصه:

- مقدار TP^2 برابر با تعداد نمونه‌هایی که مدل به درستی آنها را مثبت تشخیص داده است.
- مقدار TN^3 برابر با تعداد نمونه‌هایی که مدل به درستی آنها را منفی تشخیص داده است.
- مقدار FP^4 برابر با تعداد نمونه‌هایی که مدل به اشتباه آنها را مثبت تشخیص داده است.
- مقدار FN^5 برابر با تعداد نمونه‌هایی که مدل به اشتباه آنها را منفی تشخیص داده است.

به منظور کاهش تأثیر نتایج تصادفی، از روش اعتبارسنجی متقابل k -لایه^۶ استفاده شده است. در اینجا ابرپارامتر k برابر با ۱۰ در نظر گرفته شده و میانگین ۱۰ اجرا در جدول ۳ به عنوان نتایج عملکرد هر سه مدل گزارش شده است. در ادبیات یادگیری ماشین، منظور از پارامتر، همان پارامترهای مدل است که در فرآیند یادگیری بدست می‌آید و منظور از ابرپارامتر، پارامترهایی است که در خلال آزمایش، براساس تجربیات دیگران و سعی و خطا بهترین مقادیر آن بدست می‌آید. در اینجا نیز مقدار ۱۰ برای k براساس نرخ مرسوم در مقالات یادگیری ماشین برای شبکه‌های عصبی و اندازه‌ی داده مشابه با مسئله‌ی ما انتخاب شده است.

¹ Confusion Matrix

² True Positive

³ True Negative

⁴ False Positive

⁵ False Negative

⁶ K-Fold Cross-Validation

شکل ۱۸ - ماتریس درهم‌ریختگی *

		برچسب حقیقی	
		مثبت (P)	منفی (N)
پیش‌بینی مدل	مثبت (P)	به درستی مثبت TP	به اشتباه مثبت FP
	منفی (N)	به اشتباه منفی FN	به درستی منفی TN

* طراحی شده توسط نویسندگان مقاله.

همانطور که مشاهده می‌شود در نظر گرفتن اخبار تأثیر قابل ملاحظه‌ای در بهبود عملکرد پیش‌بینی نرخ ارز دارد. اما نکته‌ی جالب دیگر در این نتایج، خروجی مدل سوم است. در این مدل با وجود اینکه طول بردارهای ورودی کمتر شده، با تکنیک تبدیل اعداد و دسته‌ها به متن، نتیجه‌ی بسیار خوبی به دست آمد. به عبارت دیگر نتایجی نزدیک به مدل اول، اما با هزینه‌ی محاسباتی کمتر حاصل شد. البته مزیت مدل اول آن است که نیاز به طراحی و توصیف عبارات متنی برای تبدیل متغیرهای عددی و دسته‌ای به متن ندارد؛ در واقع روش اول یک روش انتها به انتها بدون نیاز به دخالت و تعریف عبارات‌های تبدیل عدد و دسته به متن است.

متأسفانه به دلیل در دسترس نبودن مجموعه داده‌های یکسان، جزئیات الگوریتم‌های پیاده‌سازی شده، و پارامترهای تنظیم شده از سایر پژوهش‌ها، امکان مقایسه‌ی مدل‌های پیشنهادی با سایر پژوهش‌ها میسر نیست. بنابراین عملکرد مدل‌های پیشنهادی با یکدیگر مقایسه شده است. در جدول ۳ خروجی مدل‌های اول و سوم بسیار امیدوار کننده است؛ دلیل این مسئله علاوه بر دقت مدل، رویکرد جامع، ساختار پودمانی^۱ و گسترش‌پذیر ارائه شده در این پژوهش است. در اینجا منظور از ساختار پودمانی و گسترش‌پذیر، معماری لایه لایه‌ی در نظر گرفته شده برای مدل است. هر یک از بخش‌های خط لوله‌ی طراحی شده را می‌توان مستقلاً و یا در ترکیب با سایر بخش‌ها

^۱. Modular

تغییر داده و برای مسائل دیگر سفارشی‌سازی کرد. به عنوان مثال می‌توان انواع دیگری از مدل‌های یادگیری ماشین را پیاده‌سازی و استفاده کرده و یا از جاسازی‌های مدرن‌تری در بخش بازنمایی داده‌های متنی بهره برد.

جدول ۳- عملکرد مدل‌های پیشنهادی در پیش‌بینی نرخ ارز بر اساس معیار دقت

مدل	مدل ۱ داده‌ی عددی و متنی	مدل ۲ داده‌ی عددی	مدل ۳ داده‌ی متنی و عددی تبدیل شده به متن
دقت روی مجموعه‌ی آزمون	۰/۹۰۲	۰/۸۲۵	۰/۹۱۵

منبع: یافته‌های تحقیق

۴-۲- تحلیل عملکرد مدل در مسئله‌ی قاب‌بندی

در این بخش اثر قاب‌بندی بر نرخ ارز مورد بررسی قرار می‌گیرد. همچنین بررسی می‌شود که مدل پیشنهادی چقدر در برابر قاب‌بندی‌های مختلف انجام شده از یک خبر، دقت دارد. در گام اول به منظور ارزیابی اثر قاب‌بندی، باید مجموعه‌ی داده‌ی مناسب این ارزیابی تولید شود. برای این منظور اخباری مورد نیاز است که هدف از آنها مثبت بوده، اما نتیجه‌ی آنها منفی شده و یا بالعکس. این اخبار به این دلیل اهمیت دارند که احتمالاً دو نوع قاب‌بندی از یک مفهوم برای آنها وجود دارد. برای تهیه‌ی این مجموعه‌ی داده به صورت زیر عمل شده است:

- روزهایی که در آنها تغییرات نرخ ارز بزرگتر یا مساوی یک انحراف معیار از میانگین f روز گذشته بوده، استخراج شده است. عدد f همان اندازه‌ی پنجره‌ی مدل است.
- در حوالی این روزها با فاصله‌ی ۸ الی ۲۴ ساعت قبل، تمامی اخبار، خصوصاً اخبار منتشره از عوامل تأثیرگذار چون بانک مرکزی، مسئولین حکومتی داخلی و خارجی مورد بررسی قرار می‌گیرد.

- خبر اصلی و خبرهای فرعی متعاقب آن پیدا می‌شود. به عنوان مثال خبر «مدل روسی برای مدیریت بازار ارز توسط رئیس بانک مرکزی» خبر اصلی و اخبار تفسیر و توضیح آن اخبار فرعی است.
- برچسب مورد انتظار خبر اصلی و خبرهای فرعی توسط کاربر خبره درج می‌شود. برچسب‌ها از دو حالت افزایش، کاهش (یا عدم تغییر)، انتخاب می‌شوند (برچسب مورد انتظار).
- برچسب اتفاق رخ داده در بازار پس از اعلام خبر و تفاسیر آن را نیز در نظر می‌گیریم (برچسب حقیقی).
- مجموعه داده‌های نهایی شامل خبر اصلی، برچسب مورد انتظار برای خبر اصلی، تعدادی خبر فرعی و برچسب‌های مورد انتظار برای آن‌ها، برچسب اتفاق حقیقی رخ داده در بازار، و تمامی داده‌های عددی و غیر عددی مربوط به روزهای متناظر با این اخبار است.
- برای اطمینان از اینکه رفتار متفاوت بازار ناشی از اخبار بوده و به دلیل اتفاقات دیگر مانند تورم امریکا یا کاهش ارزش دلار در برابر یورو نباشد، خروجی مدل عددی را با مدل‌های ترکیبی مقایسه شده است. مواردی که خروجی این دو مدل با یکدیگر یکسان بود از مجموعه‌ی داده حذف شده است.
- با این روش به ۳۷۴ خبر اصلی در مجموعه‌ی داده رسیدیم. برخی از این اخبار در قالب اخبار رسمی و با هدف مشخص توسط مسئولین به منظور کنترل بازار ارز منتشر شده‌اند و برخی دیگر ناشی از اتفاقات اقتصادی-سیاسی داخلی و خارجی است. در بررسی‌ها این دو دسته خبر از یکدیگر تفکیک شد.
- در مجموعه‌ی داده ۳۲/۱۵٪ از مواردی که خبری به منظور کاهش نرخ اعلام شده (مثلاً اطلاعیه‌های بانک مرکزی)، رفتار بازار با هدف خبر مطابقت داشته است؛ این در حالی

است که در ۶۷/۸۵٪ موارد دیگر، اخباری که انتظار تأثیر کاهشی بر نرخ ارز داشته‌اند، با رفتار بازار مطابقت نداشته‌اند. این مسئله می‌تواند بیانگر قاب‌بندی نادرست آن‌ها باشد. در جهت دیگر، اخباری که انتظار می‌رود تأثیر منفی (افزایشی) بر نرخ ارز داشته باشد (مثلاً اخبار مربوط به محدودیت انتقال ارز از کشورهای همسایه)، حدود ۷۷/۶٪ از مواقع کارساز بوده و منجر به افزایش نرخ شده‌اند. در این بررسی، به ازای هر خبر اصلی با تأثیر مورد انتظار، حداقل ۳ خبر فرعی با نیت مقابل وجود دارد. این مسئله برای اطمینان از وجود قاب‌بندی‌های مختلف و صحت تحلیل انجام شده ضروری است.

براساس تحلیل‌های انجام شده در این بخش، موارد زیر قابل استنتاج است:

- اخباری که توسط نهادها و مسئولین با قاب‌بندی مثبت به منظور کنترل بازار ارز و کاهش/ثبات نرخ منتشر می‌شوند، درصد موفقیت بالایی ندارند. به طور دقیق‌تر براساس مجموعه داده‌ی تهیه شده، تنها در ۳۲/۱۵٪ از موارد بازار برای مدت کوتاهی پس از انتشار اخبار مذکور کنترل شده است.
- اخبار منفی که انتظار می‌رود تأثیر افزایشی بر نرخ ارز داشته باشد، براساس مجموعه‌ی داده در ۷۷/۸٪ از مواقع منجر به افزایش نرخ شده‌اند. حتی قاب‌بندی‌های مثبت از اخبار اصلی (که دارای قاب‌بندی منفی است) نیز نتوانسته‌اند در اکثر موارد منجر به ثبات بازار ارز شوند.
- نتایج فوق مهر تأییدی بر مشاهدات قبلی مبنی بر رفتار نامتقارن بازار نسبت به اخبار مثبت و منفی دارد. به عبارت دیگر واکنش نسبت به اخبار منفی بیشتر و شدیدتر از واکنش به اخبار مثبت است.

در بخش بعدی تحلیل، هدف پاسخ به این سؤال است که در صورت وجود یک خبر با قاب‌بندی‌های مختلف، چه رفتاری را می‌توان از بازار انتظار داشت؟ به عبارت دیگر کدام قاب‌بندی

در بازار پیروز خواهد شد و با رفتار بازار مطابقت خواهد داشت؟ از آنجا که مدل پیشنهادی روی حجم قابل توجهی از اخبار با قاب‌بندی‌های مختلف آموزش دیده است، انتظار می‌رود تا بتوان به منظور بررسی تأثیر قاب‌بندی‌های مختلف بر نرخ ارز از آن استفاده کرد. همچنین به دلیل آنکه مدل در فرآیند آموزش، داده‌های عددی مربوط به شاخص‌های مؤثر بر نرخ ارز را نیز دریافت کرده است، انتظار می‌رود در صورتی که تغییرات نرخ ارز متأثر از این شاخص‌ها بوده و ارتباطی به قاب‌بندی اخبار نداشته باشد، خروجی درستی نسبت به قاب‌بندی‌های متفاوت ارائه دهد.

به منظور ارزیابی مدل، از مجموعه‌ی داده‌ی ساخته شده در بخش قبل، تعداد ۵۰ نمونه که مدل قبلاً آن‌ها را مشاهده نکرده است، انتخاب کرده‌ایم. توزیع کلاس‌ها در این نمونه‌ی آزمون به صورت زیر است:

- تعداد نمونه (خبر اصلی) با قاب‌بندی مثبت منطبق با رفتار بازار: ۱۰
- تعداد نمونه (خبر اصلی) با قاب‌بندی مثبت غیر منطبق با رفتار بازار: ۱۰
- تعداد نمونه (خبر اصلی) با قاب‌بندی منفی منطبق با رفتار بازار: ۱۰
- تعداد نمونه (خبر اصلی) با قاب‌بندی منفی غیر منطبق با رفتار بازار: ۱۰
- تعداد نمونه تغییر در نرخ ارز مستقل از خبر (تغییر در شاخص‌های عددی): ۱۰

بر اساس آزمون انجام شده مدل‌های اول و سوم به ترتیب در ۹۰/۸٪ و ۹۱/۰۵٪ روی مجموعه‌ی داده‌ی فوق رفتار بازار را درست پیش‌بینی کرده‌اند. دقت شود که این اعداد با دقت کلی مدل روی کل مجموعه داده‌ی آزمون متفاوت است اما به نظر می‌رسد که از همان الگو تبعیت می‌کند. نتایج حاصله بیانگر آن است که این مدل‌ها علاوه بر اینکه محتوای اخبار را مدل کرده‌اند، نسبت به قاب‌بندی‌های مختلف مطرح شده از یک خبر مقاوم بوده و پیش‌بینی درستی انجام داده‌اند. بنابراین می‌توان از مدل‌های اول و سوم، به منظور ارزیابی تأثیر اخبار با قاب‌بندی مختلف بر بازار ارز ایران با دقت حدود ۹۰٪ استفاده کرد.

۵- جمع‌بندی

در این مقاله با استفاده از مدل‌های یادگیری ماشین، روشی عملیاتی برای بررسی اثر قاب‌بندی بر نرخ ارز در ایران ارائه شد. رویکرد پیشنهادی در این پژوهش، براساس معماری و خط لوله‌ی استاندارد یادگیری ماشین از ورود داده‌ی خام تا ارزیابی خروجی نهایی مدل طراحی شده است. روش پیشنهادی شامل پنج مرحله‌ی پیش‌پردازش داده‌های متنی، عددی و دسته‌ای، بازنمایی برداری داده‌ها، مهندسی ویژگی‌ها، آموزش مدل‌ها و ارزیابی و تحلیل نهایی است. در مرحله‌ی بازنمایی داده‌های متنی، از یک جاسازی سفارشی شده برای داده‌های اقتصادی استفاده شده است. این ایده با رفع محدودیت‌های روش‌های قبلی، چالش کار با داده‌های متنی در مدل‌های عددی و اقتصادی را به خوبی برطرف می‌کند. در بخش مدل، سه مدل شامل یک مدل مبتنی بر داده‌ی عددی و دو مدل مبتنی بر داده‌ی عددی و متنی با ساختار تلفیق داده ارائه شده است. هر سه مدل از دسته‌ی شبکه‌های عصبی تکرارپذیر بوده که با تکنیک‌های یادگیری عمیق آموزش دیده‌اند. نتایج آزمایش‌ها نشان‌دهنده عملکرد مناسب مدل‌های با داده‌ی ترکیبی در پیش‌بینی نرخ ارز دارد. از مدل‌های تولید شده، علاوه بر پیش‌بینی نرخ ارز، در تحلیل اثر قاب‌بندی اخبار منتشره بر بازار ارز استفاده شده است. در این راستا ابتدا مجموعه‌ی داده‌ای از میان داده‌گان استخراج شده و با استفاده از تفاوت خروجی‌های مدل عددی و متنی، به مجموعه‌ی دقیق‌تر که تأثیر اخبار بر آن قطعی است محدود شده است. نتایج حاصل از تحقیق نشان می‌دهد که اخبار منفی همچنان تأثیر به مراتب بیشتری بر بازار ارز داشته و انواع قاب‌بندی‌های مثبت نیز چندان از تأثیر آن‌ها نمی‌کاهد. همچنین اخبار عمدتاً داخلی که به منظور کاهش نرخ ارز منتشر شده‌اند، در حدود ۳۲٪ از نمونه‌ها موفق عمل کرده‌اند. با توجه به عدم حضور عوامل دیگر، این نتیجه به معنی عدم موفقیت در قاب‌بندی مثبت، یا موفقیت رسانه‌های با قاب‌بندی منفی است. دستاورد مهم دیگر، عملکرد خوب مدل‌های ارائه شده در نمونه‌های دارای قاب‌بندی است. به عبارت دیگر این مدل‌ها با در نظر گرفتن جوانب مختلف یک خبر، تاریخچه‌ی اخبار و رفتار بازار براساس آن، و همچنین تاریخچه و اطلاعات بازار، فارغ از نوع قاب‌بندی خبر، رفتار بازار را به درستی پیش‌بینی کرده است.

در ادامه‌ی این پژوهش، پیشنهادهای سیاستی زیر ارائه می‌شود:

۱- ارتقای ثبات اقتصادی از طریق استراتژی‌های ارتباطی هدفمند: با توجه به تأثیر مشاهده شده‌ی قاب‌بندی مثبت و منفی بر نوسانات نرخ ارز، سیاست‌گذاران می‌توانند استراتژی‌های ارتباطی خود را بر مبنای تحلیل احساسات عمومی تنظیم کنند. با طراحی پیام‌هایی که باعث تقویت یا تثبیت اعتماد بازار می‌شود، تأثیر اطلاع‌رسانی‌هایی که به‌منظور کنترل ثبات ارزی انجام می‌شوند، افزایش می‌یابد. این مسئله در دوره‌های پرنوسان اهمیت بیشتری نیز می‌یابد.

۲- بررسی اثرات قاب‌بندی در بخش‌های خاص اقتصادی: تحلیل تأثیر قاب‌بندی در بخش‌هایی مانند کشاورزی، صنعت و خدمات می‌تواند حساسیت‌های خاص هر بخش را در اقتصاد ایران آشکار کند. به عنوان مثال، صنایعی که وابستگی بیشتری به واردات دارند، ممکن است نسبت به انتظارات منفی در نرخ ارز واکنش شدیدتری نشان دهند. این تحلیل می‌تواند سیاست‌گذاران را در زمینه ارتباطات و استراتژی‌های مداخله‌ای بخش‌محور هدایت کند.

مطالعات طولی بر اثربخشی سیاست‌ها: به‌منظور ارزیابی تأثیر بلندمدت استراتژی‌های قاب‌بندی، یک تحلیل طولی از اعلامیه‌های سیاستی و اثرات آن‌ها بر نرخ ارز، بینش‌های ارزشمندی ارائه می‌دهد. چنین پژوهش‌هایی به ارزیابی ماندگاری اثربخشی قاب‌بندی به عنوان ابزاری در سیاست اقتصادی کمک کرده و امکان بهینه‌سازی استراتژی‌ها بر اساس نتایج به‌دست آمده در طول زمان را فراهم می‌کنند.

References

- Abunouri, A., Khanalipour, A., & Abbasi, J. (2009). The Effect of News on Exchange Rate Fluctuations in Iran: An Application of the ARCH Family. *Business Journal*, 50, 101-120. (In Persian)
- Bayat, N. (2018). Forecasting the Exchange Rate Using Self-Organizing Ten-Recurrence Maps. *Modern Economy and Business*, 13, 55-84. (In Persian)

- Bojanowski, P., Grave, E., Joulin, A., & Mikolov, T. (2017). Enriching Word Vectors with Subword Information. *Transactions of the Association for Computational Linguistics*, 5, 135-146.
- Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J. D., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., & Askell, A. (2020). Language Models Are Few-Shot Learners. *Advances in Neural Information Processing Systems*, 33, 1877-1901.
- Chan, S. W., & Chong, M. W. (2017). Sentiment Analysis in Financial Texts. *Decision Support Systems*, 94, 53-64.
- Damiri, M., Saeedi, P., Didekhani, H., & Abbasi, A. (2020). Modeling Exchange Rate Fluctuations with System Dynamics Approach. *Financial Engineering and Securities Management*, 11(43), 220-244. (In Persian)
- Danielsson, S., & Gramer, A. (2023). Predicting Forex Rates Using Sentiment Analysis on Financial Articles. *Journal of Behavioral and Experimental Economics*, 103, 101-109.
- Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2018). Bert: Pre-training of Deep Bidirectional Transformers for Language Understanding. *arXiv preprint, arXiv:1810.04805*.
- Dharshing, S., Hille, S. L., & Wüstenhagen, R. (2017). The Influence of Political Orientation on the Strength and Temporal Persistence of Policy Framing Effects. *Ecological Economics*, 142, 295-305.
- Farahani, M., Gharachorloo, M., Farahani, M., & Manthouri, M. (2021). Parsbert: Transformer-based Model for Persian Language Understanding. *Neural Processing Letters*, 53, 3831-3847.
- Feuerriegel, S., & Prendinger, H. (2016). News-based Trading Strategies. *Decision Support Systems*, 90, 65-74.
- Galperti, S., & Cerigioni, F. (2023). Listing Specs: The Effect of Framing Attributes on Choice. *Journal of the European Economic Association*, 7, 32-38.
- Hashmi-Dizaj, A., Hazeri-Niri, H., & Pour-Vahdani, R. (2020). Comparing the Performance of Artificial Neural Network Models for Predicting the Exchange Rate in Iran. *Biquarterly Scientific Journal of Economic Studies and Policies*, 7(2), 53-80. (In Persian)
- Heaton, J. (2016). An Empirical Analysis of Feature Engineering for Predictive Modeling. *SoutheastCon 2016*.
- Jiménez-Jiménez, F., & Rodero-Cosano, J. (2023). Conditioning Competitive Behavior in Experimental Bertrand Markets Through Contextual Frames. *Journal of Behavioral and Experimental Economics*, 103, 101-109.
- Josse, J., & Husson, F. (2012). Handling Missing Values in Exploratory Multivariate Data Analysis Methods. *Journal de la société française de statistique*, 153(2), 79-99.
- Kahneman, D., & Tversky, A. (1979). Prospect theory. *Econometrica*, 47, 39-48.
- Kapoor, A., Gulli, A., Pal, S., & Chollet, F. (2022). *Deep Learning with TensorFlow and Keras: Build and deploy supervised, unsupervised, deep, and reinforcement learning models*. Packt Publishing Ltd.
- Khadaveisi, H., & Mollabahrani, A. (2012). Modeling and Forecasting Exchange Rates Based on Stochastic Differential Equations. *Economic Research*, 100(47),

- 129-144. (In Persian)
- Khan, W., Daud, A., Khan, K., Muhammad, S., & Haq, R. (2023). Exploring the Frontiers of Deep Learning and Natural Language Processing: A Comprehensive Overview of Key Challenges and Emerging Trends. *Natural Language Processing Journal*, 100-126.
- Khashee, M., Bijari, M., & Mokhatab-Rafiei F., (2012). Forecasting Exchange Rates Using Hybrid Models of Multilayer Perceptrons (MLPs) and Probabilistic Neural Classifiers (PNNs). *Scientific Research Journal of Numerical Methods in Engineering*, 32(1), 1-14. (In Persian)
- Kühberger, A. (1998). The Influence of Framing on Risky Decisions: A meta-analysis. *Organizational Behavior and Human Decision Processes*, 75(1), 23-55.
- Li, Y., & Yang, T. (2018). Word Embedding For Understanding Natural Language: A Survey. *Guide to Big Data Applications*, 83-104.
- Liebmann, M., Orlov, A. G., & Neumann, D. (2016). The Tone of Financial News and the Perceptions of Stock and CDS Traders. *International Review of Financial Analysis*, 46, 159-175.
- Liu, J., Li, T., Xie, P., Du, S., Teng, F., & Yang, X. (2020). Urban Big Data Fusion Based on Deep Learning: An Overview. *Information Fusion*, 53, 123-133.
- Lopez-Lira, A., & Tang, Y. (2023). Can ChatGPT Forecast Stock Price Movements? Return Predictability and Large Language Models. *arXiv preprint*, arXiv:2304.07619.
- Lunsford, K. G. (2020). Policy Language and Information Effects in the Early Days of Federal Reserve Forward Guidance. *American Economic Review*, 110(9), 2899-2934.
- Mansourigargari, H., & Khodavisi, H. (2019). Exchange Rate Forecasting: Comparing Logistics Growth Patterns with Competing Patterns. *Economics and modeling*, 10, 141-179. (In Persian)
- Marzban, D. H., Javaheri, B., Behnam, & Akbarian. (2005). A Comparison Between Structural, Time Series and Neural Network Econometric Models for Forecasting Exchange Rates. *Journal of Economic Research*, 40(2). (In Persian)
- Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). Efficient Estimation of Word Representations in Vector Space. *arXiv preprint*, arXiv:1301.3781.
- Morales, E. F., & Escalante, H. J. (2022). A Brief Introduction to Supervised, Unsupervised, and Reinforcement Learning. In *Biosignal Processing and Classification Using Computational Learning and Intelligence* (pp. 111-129). Elsevier.
- Nargesian, F., Samulowitz, H., Khurana, U., Khalil, E. B., & Turaga, D. S. (2017). Learning Feature Engineering for Classification. *IJCAI*, 196-235.
- Nassirtoussi, A. K., Aghabozorgi, S., Wah, T. Y., & Ngo, D. C. L. (2015). Text mining of News-headlines for FOREX Market Prediction: A Multi-layer Dimension Reduction Algorithm with Semantics and Sentiment. *Expert Systems with Applications*, 42(1), 306-324.
- Nayak, A. S., Kanive, A. P., Chandavekar, N., & Balasubramani, R. (2016). Survey on Pre-processing Techniques for Text Mining. *International Journal of Engineering and Computer Science*, 5(6), 16875-16879.

- Pennington, J., Socher, R., & Manning, C. D. (2014). Glove: Global Vectors for Word Representation. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*.
- Potdar, K., Pardawala, T. S., & Pai, C. D. (2017). A Comparative Study of Categorical Variable Encoding Techniques for Neural Network Classifiers. *International Journal of Computer Applications*, 175(4), 7-9.
- Sarzynska-Wawer, J., Wawer, A., Pawlak, A., Szymanowska, J., Stefaniak, I., Jarkiewicz, M., & Okruszek, L. (2021). Detecting Formal Thought Disorder by Deep Contextualized Word Representations. *Psychiatry Research*, 304, 114-135.
- Seabe, P. L., Moutsinga, C. R. B., & Pindza, E. (2023). Forecasting Cryptocurrency Prices Using LSTM, GRU, and Bi-directional LSTM: a Deep Learning Approach. *Fractal and Fractional*, 7(2), 203.
- Semiromi, H. N., Lessmann, S., & Peters, W. (2020). News Will Tell: Forecasting Foreign Exchange Rates Based on News Story Events in the Economy Calendar. *The North American Journal of Economics and Finance*, 52, 101-111.
- Shilpa, B., & Shambhavi, B. (2021). Combined Deep Learning Classifiers for Stock Market Prediction: Integrating Stock Price and News Sentiments. *Kybernetes*, 52(3), 748-773.
- Shirazi, Homayun, & Nasrallahi. (2014). Monetary Models and Exchange Rate Forecasting in Iran: From Theory to Empirical Evidence. *Financial and Economic Policy Quarterly*, 1(4), 5-24. (In Persian)
- Shynkevich, Y., McGinnity, T. M., Coleman, S. A., & Belatreche, A. (2016). Forecasting Movements of Health-care Stock Prices Based on Different Categories of News Articles Using Multiple Kernel Learning. *Decision Support Systems*, 85, 74-83.
- Singh, D., & Singh, B. (2020). Investigating the Impact of Data Normalization on Classification Performance. *Applied Soft Computing*, 97, 105-124.
- Singh, J., & Gupta, V. (2016). Text Stemming: Approaches, Applications, and Challenges. *ACM Computing Surveys (CSUR)*, 49(3), 1-46.
- Sousa, M. G., Sakiyama, K., de Souza Rodrigues, L., Moraes, P. H., Fernandes, E. R., & Matsubara, E. T. (2019). BERT for Stock Market Sentiment Analysis. *IEEE 31st International Conference on Tools with Artificial Intelligence (ICTAI)*.
- Sun, A., Lachanski, M., & Fabozzi, F. J. (2016). Trade the Tweet: Social Media Text Mining and Sparse Matrix Factorization For Stock Market Prediction. *International Review of Financial Analysis*, 48, 272-281.
- Tagvi, M., & Khodam, M. (2011). A Comparative Study of the Effectiveness of Currency Theories in Predicting Exchange Rate Changes in the International Currency Exchange Market. *Financial Knowledge of Securities Analysis (Financial Studies)*, 9, 147-192. (In Persian)
- Tversky, A., & Kahneman, D. (1981). The Framing of Decisions and the Psychology of Choice. *Science*, 211(4481), 453-458.
- Villamil, L., Bausback, R., Salman, S., Liu, T. L., Horn, C., & Liu, X. (2023). Improved Stock Price Movement Classification Using News Articles Based on Embeddings and Label Smoothing. *arXiv preprint*, arXiv:2301.10458.
- Yarmohammadi, M., & Mahmouand, R. (2015). Forecasting the Exchange Rate Using the Method of Analyzing the Set of Singular Values. *Quarterly Journal of Applied*

Economics Studies in Iran, 18, 146-137. (In Persian)

Zaranjad, M., Feqh Majidi, A., & Rezaei, R. A. (2008). Forecasting Exchange Rate Using Artificial Neural Networks and ARIMA Model. *Quantitative Economics (Economic Reviews)*, 19, 107-130. (In Persian).