

## Forecasting Inflation Rate in Kermanshah Province with LSTM Neural Network

Muhyiddin Izadi

Department of Statistics, Faculty of Science, Razi University, Kermanshah, Iran.  
m.izadi@razi.ac.ir

### Abstract

Inflation is a crucial issue whose rate prediction can be effective and helpful in correcting or continuing societal and economic decisions and setting macro policies. Also, forecasting the inflation rate helps investors, businesses, companies, and consumers make informed decisions about the future, ultimately leading to promotion, stability, and economic growth. Therefore, this paper discusses the problem of forecasting the inflation rate in Kermanshah province. Various statistical models have been introduced to forecast time series, including the widely used Seasonal Autoregressive Aggregate Moving Average (SARIMA) model. The purpose of providing different statistical models is to provide predictions with high accuracy. Along with statistical models, machine learning methods, including neural networks, have shown that they are a powerful and competitive tool with statistical models in predicting time series. One of the widely used neural networks in this field is the Long-Short-Term Memory (LSTM) network, a type of recurrent network. According to its architecture, the LSTM network is specifically designed for time series data, which can accurately remember the long-term dependencies of sequential data. Therefore, in this paper, LSTM neural network is used to predict the inflation rate of Kermanshah province. Using the data of the inflation rate, which was recorded and reported seasonally from March 2013 to June 2023 by the Iranian Statistics Center, the prediction accuracy of the LSTM network has been compared with the SARIMA model. The results show that the LSTM network is competitive with the SARIMA model. Therefore, using the LSTM network and the available data, the inflation rate has been predicted in the coming

months after June 2023. Python software has been used to run the LSTM network and SARIMA model on inflation rate data.

**Keywords:** Activation function, long-short-term memory network, Python software, Recurrent neural network, root mean square error, seasonal autoregressive integrated moving average.

## پیش بینی نرخ تورم استان کرمانشاه با استفاده از شبکه عصبی LSTM

محی‌الدین ایزدی

گروه آمار، دانشکده علوم، دانشگاه رازی، کرمانشاه، ایران.

m.izadi@razi.ac.ir

### چکیده

تورم یک موضوع بسیار مهم است که پیش‌بینی نرخ آن می‌تواند در تصحیح و یا تداوم تصمیمات اقتصادی در جامعه و ریل‌گذاری سیاست‌های کلان تأثیرگذار و یاری‌گر باشد. همچنین، پیش‌بینی نرخ تورم به سرمایه‌گذاران، مشاغل، شرکت‌ها و مصرف‌کنندگان کمک می‌کند تا تصمیمات آگاهانه‌ای در مورد آینده اتخاذ کنند که در نهایت می‌تواند به ارتقاء، ثبات و رشد اقتصادی منجر شود. از این‌رو در این مقاله، به مسئله پیش‌بینی نرخ تورم در استان کرمانشاه پرداخته می‌شود. مدل‌های مختلف آماری برای پیش‌بینی سری‌های زمانی معرفی شده‌اند که از جمله می‌توان به مدل پرکاربرد میانگین متحرک جمع‌بسته اتورگرسیو فصلی (SARIMA) اشاره کرد. هدف از معرفی مدل‌های مختلف آماری ارائه پیش‌بینی‌هایی با دقت بالا است. در کنار مدل‌های آماری، روش‌های یادگیری ماشین از جمله شبکه‌های عصبی نشان داده‌اند که ابزاری قدرتمند و رقابت‌پذیر با مدل‌های آماری در پیش‌بینی سری‌های زمانی هستند. یکی از شبکه‌های عصبی پرکاربرد در این زمینه شبکه حافظه طولانی کوتاه-مدت (LSTM) است که خود نوعی از شبکه‌های بازگشتی است. شبکه LSTM با توجه به معماری آن، به طور خاص برای داده‌های (دنباله‌ای) سری زمانی طراحی شده است که توانایی بالایی در به خاطر سپردن وابستگی‌های طولانی مدت داده‌های دنباله‌ای دارد. از این‌رو در این مقاله، برای پیش‌بینی نرخ تورم استان کرمانشاه از شبکه عصبی LSTM استفاده می‌شود. با استفاده از داده‌های نرخ تورم که به‌طور فصلی از اسفند ۱۳۹۱ تا خرداد ۱۴۰۲ توسط مرکز آمار ایران ثبت و گزارش شده است، دقت پیش‌بینی شبکه LSTM با مدل SARIMA مقایسه شده است. نتایج نشان می‌دهند، شبکه LSTM رقابت‌پذیر با مدل SARIMA است. بنابراین با استفاده از شبکه LSTM و داده‌های موجود، نرخ تورم در ماه‌های آتی بعد از خرداد ۱۴۰۲ پیش‌بینی شده است. برای اجرای شبکه LSTM و مدل SARIMA روی داده‌های نرخ تورم از نرم افزار پایتون استفاده شده است.

**کلید واژه‌ها:** تابع فعال‌ساز، شبکه طولانی کوتاه-مدت، شبکه عصبی بازگشتی، ریشه میانگین توان دوم خطا، میانگین متحرک جمع‌بسته اتورگرسیو فصلی، نرم‌افزار پایتون

سازمان مدیریت و برنامه‌ریزی استان کرمانشاه

فصلنامه پیشرفت و توسعه استان کرمانشاه، دوره ۳، شماره ۱، ص ۷۴-۹۲

تاریخ ارسال: ۱۴۰۲/۰۶/۰۷ تاریخ پذیرش: ۱۴۰۲/۰۹/۰۸

## ۱- مقدمه

تورم عبارت است از افزایش قیمت کالاها و خدمات در یک جامعه و در یک بازه زمانی مشخص که به صورت درصد تغییرات متوسط (وزنی) قیمت کالاها و خدمات محاسبه می شود. تورم یکی از موضوع های بسیار مهم در علم اقتصاد است؛ زیرا تأثیر مستقیم بر وضعیت اقتصادی و اجتماعی جامعه دارد. به عنوان مثال، تورم بر قدرت خرید تأثیر مستقیم دارد. وقتی قیمت کالاها و خدمات افزایش می یابند، ارزش پول کاهش یافته و این بدان معناست که برای همان مقدار کالا یا خدمات مورد نیاز می بایست پول بیشتری پرداخت نمود. همچنین تورم بالا می تواند بر تصمیمات سرمایه گذاری تأثیر مستقیم داشته باشد، زیرا افزایش مداوم قیمت ها موجب عدم اطمینان و در نتیجه سلب انگیزه و تأخیر در تصمیم گیری برای سرمایه گذاری می شود، تخصیص منابع را دچار اختلال و بر سوددهی سرمایه گذاری تأثیر منفی دارد (پژویان و خسروی، ۱۳۹۱؛ شاکری و باقرپوراسکویی، ۱۴۰۱).

به طور کلی، تورم یک موضوع بسیار مهم است که پیش بینی نرخ آن می تواند در تصحیح و یا تداوم تصمیمات اقتصادی در جامعه و ریل گذاری سیاست های کلان تأثیر گذار و یاری گر باشد. همچنین، پیش بینی نرخ تورم به سرمایه گذاران، مشاغل، شرکت ها و مصرف کنندگان کمک می کند تا تصمیمات آگاهانه ای در مورد آینده اتخاذ کنند که در نهایت می تواند به ارتقاء، ثبات و رشد اقتصادی منجر شود. با توجه به اهمیت این موضوع، در این مقاله، به پیش بینی نرخ تورم در استان کرمانشاه براساس داده های موجود در بازه زمانی اسفند ۱۳۹۱ تا خرداد ۱۴۰۲ که به صورت ماهانه ثبت شده است پرداخته می شود.

شبکه های عصبی ابزاری قدرتمند برای پیش بینی داده های سری زمانی هستند. داده های سری زمانی به داده هایی گفته می شوند که در طول زمان گردآوری شده اند. مثال هایی از داده های سری زمانی عبارتند از: قیمت های سهام، الگوهای آب و هوا، نرخ تورم و نرخ بیکاری. هدف از پیش بینی سری زمانی، پیش بینی مقادیر آینده یک متغیر (یا یک ویژگی) بر اساس رفتار گذشته آن، که در طول زمان ثبت شده است، می باشد. شبکه های عصبی نوعی از الگوریتم های یادگیری ماشین هستند که بر اساس ساختار و عملکرد مغز انسان شبیه سازی و مدل بندی شده اند. شبکه های عصبی از لایه هایی متشکل از گره های پیوسته به هم، یا همان نورون ها، که وظیفه پردازش اطلاعات و انتقال آنها را دارند، تشکیل شده اند. در پیش بینی سری زمانی، شبکه های عصبی براساس داده های گردآوری شده آموزش داده می شوند تا الگوها و روابط پنهان موجود در آنها را شناسایی کرده و با استفاده از این دانش، پیش بینی دقیقی از مقادیر آینده داشته باشند. چندین نوع شبکه عصبی برای پیش بینی سری زمانی وجود دارند، که از جمله می توان به شبکه های بازگشتی (RNN<sup>۱</sup>) و شبکه های پیچشی<sup>۲</sup> اشاره کرد. شبکه های بازگشتی، با توجه به معماری

1. Recurrent neural network  
2. Convolutional neural network

آنها، به طور خاص برای داده‌های سری زمانی طراحی شده‌اند و می‌توانند با در نظر گرفتن وابستگی‌های زمانی بین مقادیر داده، عملکرد بهتری از خود نشان دهند. شبکه‌های پیچشی می‌توانند برای داده‌های سری زمانی با وابستگی‌های فضایی مانند تصاویر ماهواره‌ای استفاده شوند. یکی از قدرتمندترین شبکه‌های عصبی بازگشتی در پیش‌بینی سری‌های زمانی، شبکه‌های حافظه طولانی کوتاه-مدت (LSTM<sup>۱</sup>) است که توسط محققین حوزه‌های مختلف بسیار مورد استفاده قرار گرفته است. دووآن<sup>۲</sup> و همکاران (۲۰۱۶) برای پیش‌بینی طول سفر در یک بزرگراه انگلیس از شبکه LSTM استفاده کردند. وو<sup>۳</sup> و همکاران (۲۰۱۸) با استفاده از شبکه LSTM پیش‌بینی قیمت ارز دیجیتال بیت‌کوین را مورد مطالعه قرار دادند. موقر<sup>۴</sup> و همیچه (۲۰۲۰) شبکه LSTM را برای پیش‌بینی قیمت سهام شرکت‌های گوگل و نایکی<sup>۵</sup> به کار بردند. چیمولا و ژانگ<sup>۶</sup> (۲۰۲۰) با استفاده از شبکه LSTM سری زمانی انتقال کووید-۱۹ را در کشور کانادا پیش‌بینی کردند. آتشی<sup>۷</sup> و همکاران (۲۰۲۲) برای پیش‌بینی سیل در رودخانه سرخ شمالی در آمریکا از سه روش شبکه LSTM، مدل کلاسیک میانگین متحرک جمع‌بسته اتورگرسیو فصلی (SARIMA<sup>۸</sup>) و جنگل تصادفی استفاده کردند. براساس داده‌های ثبت شده از سطح آب رودخانه در چند ایستگاه در بازه زمانی ۲۰۰۷ تا ۲۰۱۹، نتایج نشان داده است که استفاده از شبکه LSTM دارای دقت پیش‌بینی بیشتر نسبت به دو روش دیگر است. مخلوقی و گشوارپور (۱۴۰۱) با استفاده از شبکه عصبی LSTM به پیش‌بینی نرخ ابتلا و فوت ناشی از کووید-۱۹ در ایران براساس داده‌های ۱۳۹۸/۱۱/۲ تا ۱۴۰۰/۹/۲۳ پرداختند. نتایج نشان داده است که شبکه عصبی LSTM کارایی خوبی در پیش‌بینی موارد ابتلا به کووید-۱۹ و فوتی در ایران دارد.

در این مقاله، با به کارگیری شبکه عصبی LSTM به پیش‌بینی نرخ تورم استان کرمانشاه پرداخته می‌شود. همچنین با استفاده از داده‌های نرخ تورم، عملکرد این روش با مدل کلاسیک آماری SARIMA از نظر دقت پیش‌بینی مورد مقایسه قرار می‌گیرد. بر این اساس ساختار مقاله به صورت زیر است.

در بخش ۲، مبانی نظری و روش‌شناسی پژوهش توضیح داده می‌شود. با استفاده از داده‌های ثبت شده ماهانه تورم استان کرمانشاه در بازه زمانی اسفند ۱۳۹۱ تا خرداد ۱۴۰۲، یافته‌ها و نتایج به دست آمده در بخش ۳ ارائه و مورد بحث قرار می‌گیرد. در بخش ۴، نتیجه‌گیری و جمع‌بندی مباحث ارائه می‌شود.

1. Long-short term memory
2. Duan
3. Wu
4. Moghar
5. Nike
6. Chimmula and Zhang
7. Atashi
8. Seasonal autoregressive integrated moving average

## ۲- مبانی نظری و روش شناسی پژوهش

شبکه‌های عصبی بازگشتی می‌توانند اطلاعات زیادی از گذشته را در حافظه خود نگه دارند. از این رو، این شبکه‌ها در تحلیل داده‌های دنباله‌ای مانند سری‌های زمانی مورد استفاده قرار می‌گیرند و با استفاده از اطلاعات گذشته موجود در حافظه آنها، پیش‌بینی‌های دقیقی ارائه می‌دهند. RNNها توسط روملهارت<sup>۱</sup> و همکاران (۱۹۸۶) گسترش یافتند و در سالهای اخیر به سبب افزایش توان محاسباتی رایانه‌ها، محبوبیت بسیار زیادی در بین محققین حوزه‌های مختلف و کاربران علم‌داده پیدا کرده‌اند. فرض کنید ورودی شبکه عصبی یک بردار  $l$  تایی به صورت  $x = (x_1, x_2, \dots, x_l)$  و خروجی آن نیز یک بردار  $m$  تایی به صورت  $y = (y_1, y_2, \dots, y_m)$  باشد. بعد ورودی و خروجی شبکه می‌توانند نسبت به هم حالت‌های مختلفی داشته باشند. با این فرض که  $l = m$ ، معماری یک RNN معمولی شامل یک لایه پنهان در شکل ۱ رسم شده است. هر RNN از چندین سلول تشکیل شده است که در طول زمان از طریق وضعیت پنهان<sup>۲</sup> (یا حافظه پنهان) به صورت دنباله‌ای به هم وصل هستند. وضعیت پنهان در مرحله زمانی  $t$  ( $t = 1, \dots, l$ ) که با  $h_t$  نمایش داده می‌شود اطلاعات ذخیره شده در گام زمانی  $t$  ام است که به گام زمانی  $(t + 1)$  ام انتقال می‌یابد. در واقع در گام زمانی  $t$ ، سلول RNN ورودی  $x_t$  و همچنین وضعیت پنهان گام قبلی؛ یعنی  $h_{t-1}$  را دریافت کرده و وضعیت پنهان فعلی ( $h_t$ ) و خروجی  $\tilde{y}_t$  را تولید می‌کند. وضعیت پنهان و خروجی شبکه در گام زمانی  $t$  به صورت زیر است:


$$h_t = f(W_x x_t + W_h h_{t-1} + b_h),$$

$$\tilde{y}_t = g(W_o h_t + b_o)$$

که در آن پارامترهای  $W_x$ ،  $W_h$  و  $W_o$  به ترتیب وزن ورودی در مرحله  $t$  ام، وزن وضعیت پنهان یک گام قبل و وزن وضعیت پنهان گام فعلی و  $b_h$  و  $b_o$  پارامترهای اریبی می‌باشند. در واقع، این پارامترها (وزن‌ها و اریبی‌ها) ماتریس‌هایی هستند که بعد آنها براساس بعد ورودی و خروجی سلول تعیین می‌شود.  $f$  و  $g$  توابع فعال‌ساز مانند تابع تانژانت هذلولوی و تابع  $\text{ReLU}^3$  هستند. پارامترهای شبکه باید به گونه‌ای انتخاب شوند که خروجی شبکه؛ یعنی  $\tilde{y}_t$ ، دارای کمترین فاصله با  $y_t$  باشد. این امر با استفاده از داده‌ها به شبکه آموزش داده می‌شود. در حالت کلی، آموزش به معنای فرآیندی است که در آن مدل یاد می‌گیرد که با استفاده از مجموعه داده آموزشی، مقادیر مناسب پارامترها را به گونه‌ای بیابد که تابع خطای در نظر گرفته شده (مانند میانگین مربعات خطا) دارای مقدار کمینه باشد. پارامترهایی مانند  $W$ ها و  $b$ ها که مقادیر بهینه آنها با استفاده از مجموعه داده‌های آموزشی تعیین

1. Rumelhart  
2. Hidden state  
3. Rectified Linear Unit;  $\text{ReLU}(x) = \max(0, x)$

می‌شوند پارامترهای یادگیری<sup>۱</sup> نامیده می‌شوند. در RNN، از تمام اطلاعات ذخیره شده در وضعیت پنهان از گام‌های قبلی (اطلاعات مرتبط و نامرتب با گام فعلی) برای پیش‌بینی در گام فعلی استفاده می‌شود که این با وجود معماری موفق RNN می‌تواند منجر به محوشدگی یا انفجار گرادیان شود.



شکل ۱. معماری شبکه عصبی بازگشتی

برای رهایی از مشکل محوشدگی یا انفجار گرادیان در RNN معمولی، هوخایترو و اشمیت‌هوبر<sup>۲</sup> (۱۹۹۷) شبکه عصبی LSTM را معرفی کردند که خود نوعی از RNNها است و علاوه بر وضعیت پنهان که برای پیش‌بینی در هر گام استفاده می‌شود دارای وضعیت سلول<sup>۳</sup> نیز است. وضعیت سلول که حافظه داخلی نیز نامیده می‌شود، وظیفه‌ای مشابه وضعیت پنهان در RNN معمولی دارد با این تفاوت که در هر گام زمانی با حذف اطلاعات نامرتب از اطلاعات قبلی و اضافه کردن اطلاعات جدید به روزرسانی می‌شود. این شبکه عصبی توانایی بالایی در به خاطر سپردن وابستگی‌های طولانی مدت داده‌های دنباله‌ای دارد. نمودار شبکه عصبی LSTM در شکل ۲ نمایش داده شده است. هر سلول LSTM از سه بخش یا در اصطلاح دروازه تشکیل شده است که عبارتند از دروازه فراموشی<sup>۴</sup>، دروازه ورودی<sup>۵</sup> و دروازه خروجی<sup>۶</sup> که در شکل ۲ به ترتیب با  $G_f$ ،  $G_i$  و  $G_o$  نمایش داده شده‌اند. در یک سلول LSTM مربوط به گام زمانی  $t$ ام، محاسبات به صورت زیر انجام می‌پذیرد.


- 
4. Learning parameters
  1. Hochreiter and Schmidhuber
  2. Cell state
  3. Forget gate
  4. Input gate
  5. Output gate

$$\begin{aligned}
 f_t &= \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f), \\
 i_t &= \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i), \\
 \tilde{C}_t &= \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c), \\
 C_t &= f_t \odot C_{t-1} + i_t \odot \tilde{C}_t, \\
 o_t &= \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o), \\
 h_t &= o_t \odot \tanh(C_t), \\
 \tilde{y}_t &= g(W_ph_t + b_p)
 \end{aligned}$$

که در آن  $W_{xo}$  و  $W_{xc}$ ،  $W_{xi}$ ،  $W_{xf}$  به ترتیب وزن‌های ورودی‌های دروازه فراموشی، دروازه ورودی، وضعیت کاندید<sup>۱</sup> و دروازه خروجی،  $W_{ho}$  و  $W_{hc}$ ،  $W_{hi}$ ،  $W_{hf}$  به ترتیب وزن‌های وضعیت پنهان یک گام قبل در دروازه فراموشی، دروازه ورودی، وضعیت کاندید و دروازه خروجی و  $W_p$  وزن وضعیت پنهان فعلی است.  $b_c$ ،  $b_i$ ،  $b_f$ ،  $b_o$  و  $b_p$  پارامترهای آریبی در بخش‌های متناظر هستند.  $g$  یک تابع فعال‌ساز و  $\odot$  عملگر ضرب عنصر به عنصر می‌باشد. تابع‌های سیگموئید<sup>۲</sup> ( $\sigma()$ ) و تانژانت هذلولوی ( $\tanh()$ ) به صورت زیر تعریف می‌شوند:

$$\sigma: R \rightarrow [0, 1]; \quad \sigma(x) = \frac{1}{1 + e^{-x}}, \quad x \in R$$

$$\tanh: R \rightarrow [-1, 1]; \quad \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}, \quad x \in R$$



شکل ۱. نمودار شبکه عصبی LSTM

1. Candidate state
2. Sigmoid



در هر سلول LSTM، وظایفی برعهده هر کدام از دروازه‌ها است که ادامه شرح داده می‌شوند.

**دروازه فراموشی:** دروازه فراموشی مسئولیت تصمیم در مورد حذف اطلاعات نامرتبط از حافظه داخلی یا همان وضعیت سلول را دارد. در این دروازه با استفاده از وضعیت پنهان گام زمانی قبل و ورودی گام فعلی،  $f_t$  که عددی بین صفر و یک است تولید می‌شود و سپس در وضعیت سلول گام زمانی قبل ضرب می‌شود. ضرب عدد صفر به معنای حذف کل اطلاعات ذخیره در وضعیت سلول و ضرب عدد یک به معنای حذف نکردن هیچ اطلاعی از حافظه وضعیت سلول گام زمانی قبل است. بنابراین خروجی این دروازه به صورت  $f_t \odot C_{t-1}$  است.

**دروازه ورودی:** در این دروازه تصمیم گرفته می‌شود که چه بخشی از اطلاعات ورودی به سلول (شامل وضعیت پنهان گام زمانی قبل  $(h_{t-1})$  و ورودی سلول  $(x_t)$ ) در وضعیت سلول ذخیره شود. بنابراین ابتدا با استفاده از ورودی و وضعیت پنهان گام زمانی قبل،  $i_t$  که عددی بین صفر و یک است تولید می‌شود. سپس  $\tilde{C}_t$  که وضعیت کاندید نامیده می‌شود محاسبه می‌گردد. در واقع، وضعیت کاندید اطلاعات وارده شده به سلول در گام زمانی  $t$ ام است. با ضرب  $i_t$  در  $\tilde{C}_t$ ، مشخص می‌شود چه بخشی از وضعیت کاندید باید در وضعیت سلول ذخیره شود. ضرب عدد یک به معنای ذخیره کل وضعیت کاندید در وضعیت سلول و ضرب عدد صفر به معنای ذخیره نشدن هیچ بخشی از وضعیت کاندید در وضعیت سلول است. بنابراین خروجی این دروازه به صورت  $i_t \odot \tilde{C}_t$  است.

با جمع خروجی دروازه فراموشی و خروجی دروازه ورودی، وضعیت سلول در گام زمانی  $t$  به صورت

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t$$

به روزرسانی می‌شود.

**دروازه خروجی:** در این دروازه تصمیم گرفته می‌شود که چه بخشی از اطلاعات ذخیره شده در وضعیت سلول به عنوان خروجی سلول در نظر گرفته شود. برای این منظور ابتدا  $o_t$  تولید می‌شود که عددی بین صفر و یک است. سپس وضعیت پنهان به صورت  $h_t = o_t \odot \tanh(C_t)$  به روزرسانی می‌شود. در واقع، وضعیت پنهان بخشی از اطلاعات ذخیره شده در وضعیت سلول است که برای خروجی در گام زمانی  $t$  استفاده می‌شود. در نهایت خروجی سلول به صورت  $\tilde{y}_t = g(W_p h_t + b_p)$  محاسبه می‌شود. در این مقاله برای اجرای شبکه LSTM از کتابخانه متن-باز کراس<sup>۱</sup> در نرم افزار پایتون استفاده شده است که در آن حالت پیش فرض تابع فعال ساز  $g$  تابع خطی است.

برای جزئیات بیشتر در مورد شبکه‌های عصبی بازگشتی و LSTM، خوانندگان می‌توانند به ژرون<sup>۱</sup> (۲۰۲۳) مراجعه نمایند.

اکنون، فرض کنید  $\{x_t\}_{t=1}^T$  مقادیر مشاهده شده از یک سری زمانی باشند. هدف پیش‌بینی  $x_t$  برای  $t = T + 1$  است. با توجه به اینکه شبکه‌های عصبی جزء روش‌های یادگیری راهنماییده<sup>۲</sup> هستند، بنابراین برای آموزش شبکه عصبی بایستی داده‌های سری زمانی را به صورت نمونه‌های ورودی و خروجی به صورت جدول ۱ تبدیل نمود. مقدار مناسب  $l$  در جدول ۱ که بعد داده‌های ورودی به شبکه است به عنوان یکی از ابرپارامترهای مدل با استفاده از داده‌های بخش اعتبارسنج<sup>۳</sup> و معیار ریشه میانگین مربع خطا (RMSE<sup>۴</sup>) که در ادامه تعریف می‌شود، به دست می‌آید.

جدول ۱. تقسیم داده‌ها به دو بخش ورودی و خروجی

ورودی	خروجی
$x_1, x_2, \dots, x_l$	$x_{l+1}$
$x_2, x_3, \dots, x_{l+1}$	$x_{l+2}$
$\vdots$	$\vdots$
$x_{T-l-1}, x_{T-l}, \dots, x_{T-2}$	$x_{T-1}$
$x_{T-l}, x_{T-l+1}, \dots, x_{T-1}$	$x_T$

برای ارزیابی عملکرد شبکه LSTM، دقت پیش‌بینی آن را با مدل آماری SARIMA مقایسه می‌کنیم. برای این منظور، ۸۵ درصد ابتدایی از داده‌ها به عنوان مجموعه داده‌های آموزشی در نظر گرفته می‌شود. براساس این بخش از داده‌ها، شبکه برای یافتن مقادیر مناسب پارامترهای یادگیری آموزش داده می‌شود. ۱۵ درصد باقی مانده داده‌ها به عنوان داده‌های آزمون در نظر گرفته می‌شود. بنابراین شبکه LSTM با استفاده از مجموعه داده‌های آموزشی آموزش داده می‌شود. سپس دقت پیش‌بینی آن در بخش داده‌های آزمون با مدل رقیب (مدل آماری SARIMA که در پایان این بخش توضیح داده می‌شود) مورد مقایسه قرار می‌گیرد. برای انجام مقایسه، معیارهای میانگین قدرمطلق خطای درصدی (MAPE<sup>۵</sup>) و RMSE مورد استفاده می‌گیرند که به صورت زیر تعریف می‌شوند.

$$MAPE = \frac{1}{N_{test}} \sum_{t \in J_{test}} \left| \frac{x_t - \tilde{x}_t}{x_t} \right|$$

2. Géron

1. Surprised learning

2. Validation data

3. Root mean squared error

4. Mean absolute percentage error

$$RMSE = \sqrt{\frac{1}{N_{test}} \sum_{t \in \mathcal{T}_{test}} (x_t - \tilde{x}_t)^2}$$

که در آن  $\tilde{x}_t$  مقدار پیش‌بینی شده  $x_t$ ،  $\mathcal{T}_{test}$  اندیس‌های زمان مربوط به مجموعه داده‌های آزمون و  $N_{test}$  تعداد اعضای مجموعه  $\mathcal{T}_{test}$  است. در بحث استفاده از شبکه‌های عصبی، قبل از آموزش شبکه، مقدار مناسب ابرپارامترهای مدل مانند تعداد لایه‌ها، تعداد نرون‌ها در هر لایه، تعداد دوره‌ها، بعد ورودی نرون‌ها؛ یعنی  $l$ ، و ... باید تعیین شود. برای این منظور، مجموعه داده‌های آموزشی را به دو بخش مجزای مجموعه داده‌های آموزشی فروکاسته<sup>۲</sup> (۷۰ درصد ابتدایی از داده) و مجموعه داده‌های اعتبارسنج (باقی مانده داده‌های آموزشی که ۱۵ درصد از کل داده‌ها است) تقسیم می‌کنیم. مقدار مناسب ابرپارامترها براساس دقت پیش‌بینی مدل در بخش داده‌های اعتبارسنج با استفاده از کمینه کردن معیار RMSE انتخاب می‌شود.

مدل سری زمانی اتورگرسیو جمع‌بسته میانگین متحرک (ARIMA<sup>۳</sup>) یکی از پرکاربردترین روش‌های آماری برای پیش‌بینی داده‌های سری زمانی یک متغیره است. با این وجود این مدل برای داده‌های سری زمانی با مؤلفه فصلی مناسب نیستند. از این‌رو، مدل SARIMA معرفی شده است که در واقع تعمیمی از مدل غیر فصلی ARIMA است.

سری زمانی  $\{X_t\}$  را در نظر بگیرید و فرض کنید  $\{a_t\}$  یک فرایند نوفه سفید<sup>۴</sup> و  $B$  یک عملگر پسرو<sup>۵</sup> باشد به گونه‌ای که  $B^j X_t = X_{t-j}$ . گوییم سری  $\{X_t\}$  از مدل سری زمانی  $SARIMA(p, d, q) \times (P, D, Q)_s$  پیروی می‌کند هرگاه

$$\Phi_P(B^S)\phi_p(B)(1-B)^d(1-B^S)^D X_t = \theta_q(B)\Theta_Q(B^S)a_t$$

که در آن  $S$  پارامتر دوره فصلی است،

$$\Phi_P(B) = 1 - \Phi_1 B - \dots - \Phi_P B^P,$$

$$\phi_p(B) = 1 - \phi_1 B - \dots - \phi_p B^p,$$

به ترتیب عوامل اتورگرسیو و اتورگرسیو فصلی و

$$\theta_q(B) = 1 - \theta_1 B - \dots - \theta_q B^q,$$

$$\Theta_Q(B) = 1 - \Theta_1 B - \dots - \Theta_Q B^Q$$

- 
1. Epochs
  2. Reduced training data
  3. Autoregressive integrated moving average
  4. White noise process
  5. Backshift operator

به ترتیب عوامل میانگین متحرک و میانگین متحرک فصلی نامیده می شوند. برای به دست آوردن مقادیر مناسب پارامترهای مدل، از معیارهای انتخاب مدل مانند معیار اطلاع آکائیکه ( $AIC^1$ ) و معیار اطلاع بیزی ( $BIC^2$ ) استفاده می شود. مقادیر کمتر این دو معیار نشان دهنده برازش بهتر مدل به داده ها است. در این مقاله، برای یافتن پارامترهای مدل از کتابخانه متن باز *pmdarima* در نرم افزار پایتون استفاده می شود که در آن برای یافتن مقادیر مناسب پارامترها دو معیار  $AIC$  و  $BIC$  به کار برده می شوند. برای جزئیات بیشتر در مورد مدل  $SARIMA$  می توان به براکول و دیویس<sup>۳</sup> (۲۰۰۲) مراجعه نمود.

### ۳- یافته ها

در این بخش، به پیش بینی نرخ تورم استان کرمانشاه براساس داده های نرخ تورم گزارش شده توسط مرکز آمار ایران که به صورت ماهانه از اسفند ۱۳۹۱ تا خرداد ۱۴۰۲ ثبت و گزارش شده است پرداخته می شود. نمودار داده های نرخ تورم در بازه زمانی مذکور در شکل ۳ رسم شده است. لازم به ذکر است داده های موجود نرخ تورم، براساس تغییرات شاخص کل قیمت ها در دوازده ماهه منتهی به هر ماه نسبت به دوازده ماهه مشابه سال قبل خود محاسبه شده است.

همان گونه که در بخش ۲ بیان شد، برای ارزیابی عملکرد شبکه LSTM و مقایسه آن با مدل آماری  $SARIMA$ ، ابتدا داده ها را به دو مجموعه مجزای داده های آموزشی (۸۵ درصد داده ها؛ یعنی داده های نرخ تورم تا آذر ۱۴۰۰) و داده های آزمون (بازه زمانی دی ۱۴۰۰ تا خرداد ۱۴۰۲) تقسیم می کنیم. همچنین داده های مربوط به بازه زمانی خرداد ۱۳۹۹ تا آذر ۱۴۰۰ (۱۵ درصد کل داده ها) به عنوان مجموعه اعتبارسنج برای به دست آوردن مقدار مناسب ابرپارامترهای مدل در نظر گرفته می شود. مقادیر آغازین پارامترهای یادگیری به صورت تصادفی انتخاب می شوند که این منجر به متفاوت بودن پیش بینی ها در هر مرحله اجرای مدل روی مجموعه داده های آموزشی فروکاسته می شود. از این رو، مدل LSTM به ازای مقادیر مختلف ابرپارامترها روی مجموعه داده های آموزشی فروکاسته ۱۰ بار تکرار شده و میانگین  $RMSE$  های به دست آمده در جدول ۲ آورده شده اند. اکنون با استفاده از مقادیر انتخاب شده، مدل شبکه LSTM را روی کل مجموعه داده های آموزشی اجرا و سپس نرخ تورم در بازه زمانی مربوط به مجموعه داده های آزمون پیش بینی می شود. با توجه به اینکه مقادیر آغازین پارامترهای یادگیری تصادفی هستند، بنابراین در هر بار یادگیری شبکه توسط داده های آموزشی، مقادیری مختلف از پیش بینی ها به دست می آیند. از این رو، ۵۰ بار

6. Akaike Information Criterion  
7. Bayesian Information Criterion  
1. Brockwell and Davis

فرایند یادگیری و سپس محاسبه پیش‌بینی‌ها انجام می‌گیرد. در نهایت میانگین ۵۰ بار پیش‌بینی‌ها به‌عنوان مقادیر نهایی پیش‌بینی در نظر گرفته شده و معیارهای انتخاب مدل براساس آنها محاسبه می‌شوند. معیارهای محاسبه شده توان مدل در پیش‌بینی نرخ تورم در بازه زمانی مربوط به داده‌های آزمون را اندازه‌گیری می‌کنند. لازم به ذکر است که برای بهبود عملکرد و همگرایی شبکه عصبی، بازمقیاسیدن<sup>۱</sup> و مانا کردن داده‌ها قبل از آموزش شبکه یکی از راه‌کارهای رایج است (ژرون، ۲۰۲۳). از این‌رو، ابتدا یک مرحله تفاضل‌گیری را روی داده‌ها اعمال و سپس با استفاده از تبدیل  $\min \max$  که برای سری داده‌های  $\mathbf{w} = (w_1, \dots, w_d)$  به‌صورت

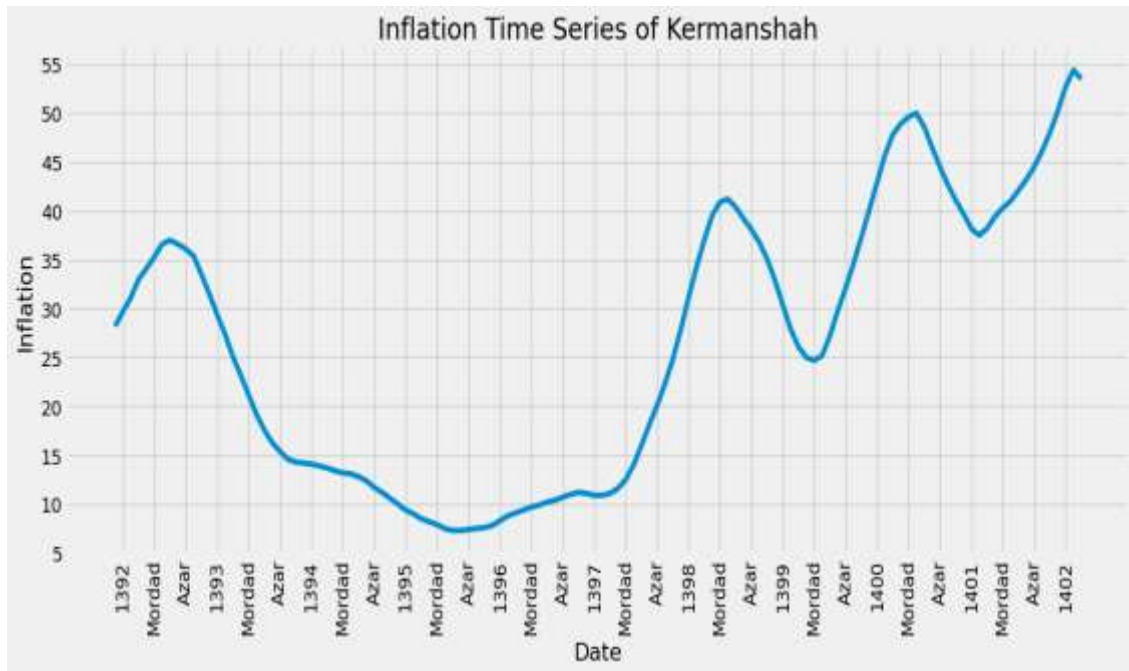
$$\min \max(\mathbf{w}) = \left( \frac{w_1 - \min \mathbf{w}}{\max \mathbf{w} - \min \mathbf{w}}, \dots, \frac{w_d - \min \mathbf{w}}{\max \mathbf{w} - \min \mathbf{w}} \right)$$

تعریف می‌شود، مقادیر سری را به اعدادی در بازه  $[0,1]$  تبدیل می‌کنیم.

به‌طور مشابه، مدل SARIMA به داده‌های آموزشی برازش داده می‌شود. سپس مقادیر پیش‌بینی شده در بازه زمانی مربوط به داده‌های آزمون به‌دست آمده و براساس آنها معیارهای ارزیابی مدل محاسبه می‌شوند. مقادیر به‌دست آمده از معیارهای ارزیابی برای دو مدل شبکه LSTM و مدل SARIMA، در جدول ۲ آمده است. با مقایسه معیارهای به‌دست آمده برای دو مدل، واضح است مدل شبکه LSTM دارای دقت پیش‌بینی بیشتر است. نمودار مقادیر مشاهده شده و پیش‌بینی شده در بازه زمانی مربوط به بخش داده‌های آزمون با استفاده از شبکه LSTM و مدل SARIMA در شکل‌های ۴ و ۵ رسم شده است.

اکنون برای پیش‌بینی نرخ تورم برای ماه‌های بعد از خرداد ۱۴۰۲، ابتدا با استفاده از کل داده‌ها مدل شبکه LSTM آموزش داده شده و سپس نرخ تورم پیش‌بینی می‌شود. به‌عنوان مثال، مقادیر پیش‌بینی شده نرخ تورم برای ماه‌های تیر، مرداد و شهریور ۱۴۰۲ به ترتیب ۵۰.۹۶، ۴۸.۲۴ و ۴۵.۶۳ به‌دست آمده است. این اعداد نشان‌دهنده کاهش بودن روند نرخ تورم در استان کرمانشاه است. همچنین، نمودار مقادیر پیش‌بینی شده نرخ تورم برای بازه زمانی تیر ۱۴۰۲ تا فروردین ۱۴۰۴ در شکل ۶ رسم شده است. براساس شکل، مشاهده می‌شود که در ابتدا نرخ تورم کاهش می‌یابد و سپس افزایشی پیش‌بینی می‌شود. واضح است با افزایش فاصله زمانی بین داده‌های آموزشی و زمان پیش‌بینی، عدم قطعیت افزایش یافته و دقت پیش‌بینی کمتر خواهد بود.

برای اجرای شبکه عصبی LSTM و SARIMA از زبان برنامه نویسی پایتون و به ترتیب کتابخانه های متن باز Keras و pmdarima استفاده شده است.



شکل ۳. نمودار نرخ تورم استان کرمانشاه در بازه زمانی اسفند ۱۳۹۱ تا خرداد ۱۴۰۲


جدول ۱. مقدار مناسب ابرپارامترهای مدل شبکه عصبی LSTM

ابریارامتر	مقادیر در نظر گرفته شده	مقدار مناسب با کمینه RMSE
تعداد لایه	1, 2, 3	1
تعداد نورون	1, 5, 10, 15, 20	5
اندازه دسته <sup>۱</sup>	3, 6, 9, 12, 16	6
تعداد دوره ها	1, 2, ..., 1000	1000
بعد ورودی ( $l$ )	1, 2, ..., 12	5


1. Batch size

جدول ۳. مقادیر محاسبه شده معیارهای ارزیابی دو مدل شبکه LSTM و SARIMA

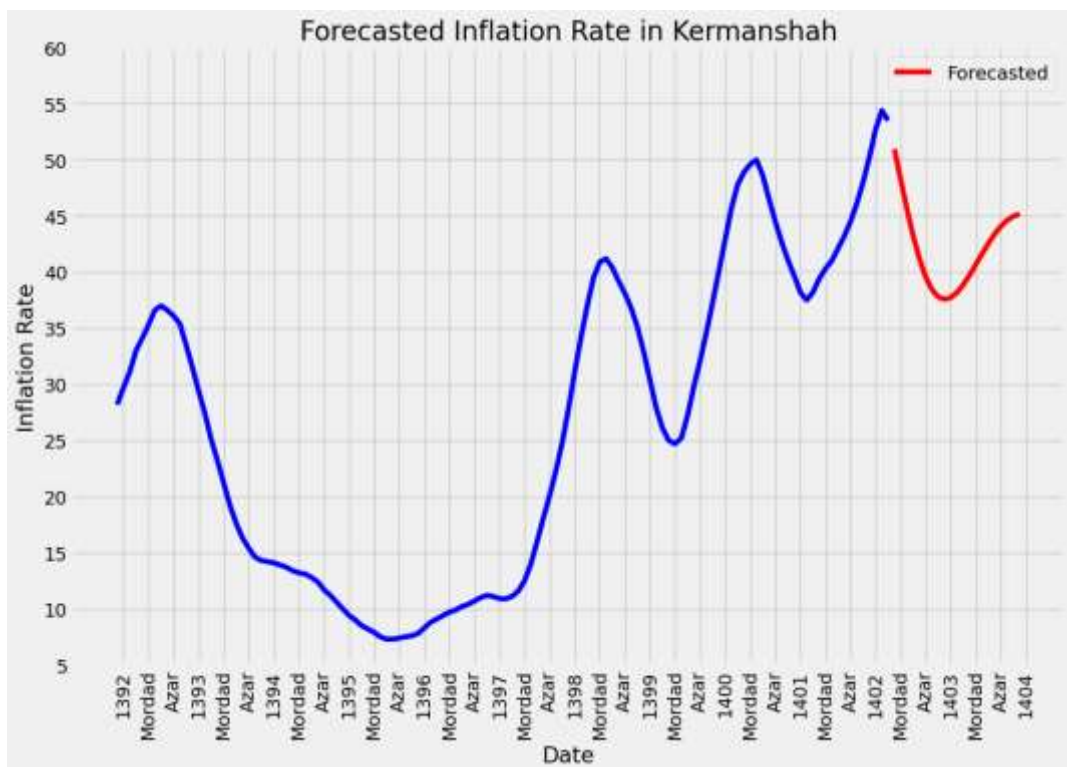
مدل	RMSE	MAPE
LSTM	4.008	0.081
SARIMA	6.167	0.126



شکل ۴. نمودار مقادیر پیش‌بینی شده در بازه زمانی مربوط به داده‌های آزمون با استفاده از شبکه LSTM



شکل ۵. نمودار مقادیر پیش‌بینی شده در بازه زمانی مربوط به داده‌های آزمون با استفاده از مدل SARIMA



شکل ۶. LSTM نمودار پیش‌بینی نرخ تورم کرمانشاه تا سال ۱۴۰۴ با استفاده از شبکه



#### ۴- بحث و نتیجه گیری

با توجه به اهمیت نرخ تورم در اقتصاد هر کشور و لزوم پیش‌بینی آن برای مقاصد مدیریتی و سیاست‌گذاری کلان، محققان همواره برآنند تا از روش‌هایی با دقت پیش‌بینی بالا برای این مهم استفاده کنند. شبکه‌های عصبی ابزاری قدرتمند برای پیش‌بینی داده‌های سری زمانی مانند نرخ تورم هستند. شبکه عصبی LSTM که خود نوعی از شبکه‌های RNN است توانایی بالایی در به‌خاطر سپردن وابستگی‌های طولانی مدت داده‌های دنباله‌ای دارد. از این‌رو، در این مقاله به پیش‌بینی نرخ تورم استان کرمانشاه با استفاده از شبکه عصبی LSTM پرداخته شده است. با استفاده از معیارهای ارزیابی دقت پیش‌بینی، این شبکه با مدل رایج آماری SARIMA مورد مقایسه قرار گرفته است. نتایج نشان می‌دهد، شبکه LSTM رقابت‌پذیر با مدل SARIMA است و می‌تواند دارای دقت پیش‌بینی بیشتر باشد.

با استفاده از شبکه LSTM و داده‌های نرخ تورم کرمانشاه که به‌صورت ماهانه از اسفند ۱۳۹۱ تا خرداد ۱۴۰۲ توسط مرکز آمار ایران به ثبت رسیده است، نرخ تورم مربوط به بازه زمانی تیر ۱۴۰۲ تا فروردین ۱۴۰۴ پیش‌بینی شده است. نمودار مربوط به مقادیر پیش‌بینی نشان می‌دهد که نرخ تورم در بازه‌ای چند ماهه کاهشی و سپس افزایشی خواهد شد. بدون شک، مقادیر پیش‌بینی آینده مربوط به زمان‌های دورتر دارای دقت کمتر خواهند بود. اما با این وجود، پیش‌بینی روند افزایشی نرخ تورم کرمانشاه در سال ۱۴۰۳ می‌تواند مورد توجه تصمیم‌گیرندگان و مدیران استانی قرار گیرد.

#### تعارض منافع

نویسنده مقاله اعلام می‌دارند که در مورد انتشار این مقاله تضاد منافع وجود ندارد. علاوه بر این، موضوعات اخلاقی شامل سرقت ادبی، رضایت آگاهانه، سوءرفتار، جعل داده‌ها، انتشار و ارسال مجدد و مکرر توسط نویسنده رعایت شده است.

#### تقدیر و تشکر

نویسنده مقاله از داور محترم که با پیشنهادهای ارزنده باعث بهبود مقاله شدند، کمال تقدیر و قدردانی را دارد. این مقاله در راستای طرح فرصت مطالعاتی داخل کشور اعضای هیات علمی مربوط به نویسنده مقاله در سازمان مدیریت و برنامه‌ریزی استان کرمانشاه است. ایشان از آن سازمان برای فراهم کردن شرایط جهت گذراندن دوره فرصت مطالعاتی و در اختیار قرار دادن داده‌های لازم کمال تقدیر و تشکر را دارد.

## فهرست منابع

- پژویان، جمشید و خسروی، تانیا (۱۳۹۱)، تأثیر تورم بر سرمایه گذاری بخش خصوصی. فصلنامه علمی پژوهشی دانش سرمایه گذاری، ۱(۴)، ۱۸-۱.
- شاکری، عباس و باقرپوراسکویی، الناز (۱۴۰۲)، بررسی ماهیت تورم در اقتصاد ایران: رویکرد همدوستی و موجکی. پژوهش های اقتصادی ایران، ۹۴، ۷۹-۴۷.
- مخلوقی، فاطمه و گشوارپور، عاتکه (۱۴۰۱)، پیش بینی نرخ ابتال و فوت ناشی از کووید-۱۹ در ایران با استفاده از شبکه عصبی حافظه طولانی کوتاه مدت. مجله انفورماتیک سلامت و زیست پزشکی، ۹(۱)، ۲۷-۳۹.
- Atashi, V., Gorji, H.T., Shahabi, S.M., Kardan, R., and Lim, Y.H. (2022). **Water level forecasting using deep learning time-series analysis: A case study of red river of the north.** *Water*, 14(12), 1971. ([https:// doi.org/10.3390/w14121971](https://doi.org/10.3390/w14121971))
- Brockwell, P.J., and Davis, R.A. (2002). *Introduction to time series and forecasting*. New York, NY: Springer New York.
- Chimmula, V.K.R., and Zhang, L. (2020). **Time series forecasting of COVID-19 transmission in Canada using LSTM networks.** *Chaos, solitons & fractals*, 135, 109864.
- Duan, Y., Yisheng, L.V. and Wang, F.Y. (2016). **Travel time prediction with LSTM neural network.** In *2016 IEEE 19th international conference on intelligent transportation systems (ITSC)* (pp. 1053-1058). IEEE.
- Géron, A. (2023). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*. O'Reilly Media, Inc.
- Hochreiter, S. and J. Schmidhuber (1997). **Long short-term memory.** *Neural computation* 9(8), 1735-1780.
- Moghar, A., and Hamiche, M. (2020). **Stock market prediction using LSTM recurrent neural network.** *Procedia Computer Science*, 170, 1168-1173.
- Rumelhart, D.E., Hinton, G.E. and Williams, R.J. (1986). **Learning representations by back-propagating errors.** *Nature* 323(6088), 533-536.

Wu, C.H., Lu, C.C., Ma, Y.F. and Lu, R.S. (2018). **A new forecasting framework for bitcoin price with LSTM.** In 2018 IEEE International Conference on Data Mining Workshops (ICDMW) (pp. 168-175). IEEE