

## **Predicting gasoline consumption in Iran using deep learning and classic methods of time series approaches**

**Neda Bayat\***

**Ali Rezaei\*\***

### **Abstract**

With the expansion of industries, population growth and development of the transportation sector in the world, energy demand has increased sharply and today plays a very important role in the economies of countries. Today, energy shortages are a serious issue to achieve economic development, which is why demand management is an attractive concern for countries and Gasoline forecasting is also important as one of the economic variables for planning and managing gasoline demand. In Iran, the transportation sector has a major share of energy consumption, 44% percent of which belongs to gasoline. The increasing trend of gasoline consumption in Iran, insufficient domestic production, significant growth of gasoline imports in recent years show the incremental importance of managing gasoline consumption in Iran, so, predicting the consumption process as accurately as possible can be very useful in achieving this. This study predicts gasoline consumption using monthly data by comparing the efficiency of three methods, neural networks with long short-term memory, recursive self-organizing maps, and the traditional method of seasonal autoregressive moving average. The results indicate that the use of 12-month time-frequency for data training had more accurate

\* Department of Economics, Qazvin Branch, Islamic Azad University, Qazvin, Iran (Corresponding Author), nedabbayat@gmail.com

\*\* Master of Mathematical Statistics, University of Allameh Tabataba'i, ali.rezaei7091@yahoo.com

Date received: 30/05/2020, Date of acceptance: 09/09/2020

Copyright © 2010, IHCS (Institute for Humanities and Cultural Studies). This is an Open Access article. This work is licensed under the Creative Commons Attribution 4.0 International License. To view a copy of this license, visit <http://creativecommons.org/licenses/by/4.0/> or send a letter to Creative Commons, PO Box 1866, Mountain View, CA 94042, USA.

results compared to other data frequencies, and the deep learning method of networks with long-term short-term memory was more efficient than the other two methods.

**Keywords:** Gasoline Consumption Predicting, Deep Learning, Long Short-Term memory, Recurrent Self-Organizing Map

JEL Classification: Q41, E17, Q47



## پیش‌بینی مصرف بنزین در ایران با استفاده از رهیافت‌های یادگیری عمیق و مدل‌های کلاسیک سری زمانی

ندا بیات\*

علی رضائی\*\*

### چکیده

با گسترش صنایع، افزایش جمعیت و توسعه بخش حمل و نقل در جهان تقاضای انرژی به شدت افزایش یافته و امروزه نقش بسیار مهمی را در اقتصاد کشورها بازی می‌کند. کمبود انرژی امروزه به عنوان مانعی جدی در دستیابی به توسعه اقتصادی مطرح است، به همین دلیل مدیریت تقاضای آن مورد توجه کشورها است و پیش‌بینی مصرف بنزین نیز به عنوان یکی از متغیرهای اقتصادی برای برنامه‌ریزی و مدیریت تقاضای بنزین حائز اهمیت است. در ایران بخش حمل و نقل سهم عمده‌ای از مصرف انرژی دارد که ۹۹/۷ درصد از آن متعلق به بنزین است. با توجه به روند افزایشی مصرف بنزین در ایران، کافی نبودن تولید داخل کشور، رشد قابل توجه واردات بنزین در سال‌های اخیر اهمیت مدیریت مصرف بنزین افزایش یافته است که پیش‌بینی هر چه دقیق‌تر روند مصرف آن می‌تواند در تحقق این امر بسیار مفید باشد. این مطالعه به پیش‌بینی مصرف بنزین با استفاده از داده‌های ماهانه با مقایسه عملکرد سه روش شبکه‌های عصبی با حافظه طولانی کوتاه‌مدت، نقشه‌های خودسازمانده بازگشتی و روش سستی میانگین متحرک خودرگرسیون جمع‌بسته فصلی پرداخته است. نتایج حاکی از این است که روش یادگیری عمیق

\* استادیار گروه اقتصاد، واحد قزوین، دانشگاه آزاد اسلامی، قزوین (نویسنده مسئول)،

nedabbayat@gmail.com

\*\* کارشناس ارشد آمار ریاضی، دانشگاه علامه طباطبائی، تهران، ali.rezaei7091@yahoo.com

تاریخ دریافت: ۱۳۹۹/۰۳/۱۰، تاریخ پذیرش: ۱۳۹۹/۰۶/۱۹

شبکه‌های عصبی با حافظه طولانی کوتاه‌مدت و تواتر ۱۲ ماهه برای آموزش داده‌ها کاراتر از دو روش دیگر است.

**کلیدواژه‌ها:** پیش‌بینی مصرف بنزین، یادگیری عمیق، شبکه‌های با حافظه طولانی کوتاه‌مدت، نقشه‌های خودسازمانده بازگشتی.

طبقه‌بندی: Q47.E17.Q41:JEL

## ۱. مقدمه

با گسترش صنعت و پدیده جهانی شدن، افزایش جمعیت و توسعه بخش حمل و نقل در جهان تقاضای انرژی به شدت افزایش یافته و امروزه نقش بسیار مهمی را در اقتصاد کشورها بازی می‌کند (سوگانتی و ساموئل، ۲۰۱۲، ص ۵). گزارش‌های آژانس بین‌المللی انرژی نشان می‌دهند که مصرف انرژی در ده سال اخیر، بیشتر از ۱۵ درصد رشد داشته است (آژانس بین‌المللی انرژی، ۲۰۱۹، ص ۷۳) و پیش‌بینی می‌شود که تقاضای آن تا سال ۲۰۴۰، حداقل ۱ درصد در سال رشد کند (کیم و چو ۲۰۱۹). علاوه بر این، برخی از مطالعات بر این باورند که سهم کشورهای در حال توسعه، به ویژه کشورهای واقع در آسیا، در افزایش مصرف آتی انرژی بیشتر از کشورهای توسعه‌یافته خواهد بود و عمده این انرژی نیز در تولید برق و بخش حمل و نقل مصرف خواهد شد (برودهد و کیلمن، ۲۰۰۸، ص ۷).

مقایسه داده‌های انرژی ایران و جهان نشان می‌دهند که مصرف سرانه انرژی در ایران ۱/۸ برابر متوسط سرانه مصرف انرژی در جهان و همچنین مصرف سرانه انرژی در بخش‌های کشاورزی، خانگی - تجاری و عمومی، حمل و نقل و صنعت به ترتیب ۳/۳، ۲/۲، ۱/۵ و ۱/۵ برابر متوسط جهانی است. نتیجه این مقایسه‌ها حاکی از بالا بودن هدر رفت انرژی در ایران است که لزوم مدیریت مصرف را خاطر نشان می‌سازد. بخش حمل و نقل نیز با سهمی معادل ۶۴/۹ درصد بزرگترین مصرف کننده فرآورده‌های نفتی است که ۹۹/۷ درصد مصرف بنزین در کشور را به خود اختصاص داده است. افزایش تولیدات خودرو، عدم خروج خودروهای قدیمی از چرخه حمل و نقل و ضعف فن آوری در تولید موتورهای کم مصرف، افزایش سفرهای برون‌شهری، تاخیر در اصلاح قیمت بنزین، عدم تولید کافی بنزین در داخل کشور و استمرار ضعف سیستم حمل و نقل عمومی در

سال‌های گذشته منجر به تقویت شکاف بین تولید و مصرف بنزین در کشور شده است. به‌طوری که آمارها نشان می‌دهند که مصرف بنزین در سال ۱۳۹۶، ۸ درصد نسبت به سال قبل رشد داشته و به بیشترین سطح رشد خود در سال‌های اخیر رسیده است (ترازنامه انرژی ایران، ۱۳۹۶). تامین این مقیاس از مصرف با توجه به محدودیت ظرفیت پالایشگاهی کشور، موجب افزایش واردات بنزین خواهد شد چنانچه در سال ۱۳۹۶، واردات با افزایش ۴/۳ درصدی به ۱۲/۶۳ میلیون لیتر در روز رسید. واردات بنزین سبب خواهد شد درآمدهای ارزی بجای تامین مخارج سرمایه‌ای صرف نیازهای مصرفی گردند. شرایط تحریم نیز باعث هر چه وخیم‌تر شدن این وضعیت گردیده و با توجه به تعداد محدود پالایشگاههای بنزین در داخل و مستهلک شدن آنها افزایش تولید داخل در کوتاه‌مدت بعید به نظر میرسد (مهرگان، ۱۳۸۸، ص ۲۳). به همین دلیل مدیریت تقاضای بنزین به یکی از دغدغه‌های اصلی دولت‌ها تبدیل شده است. بدیهی است مدیریت تقاضای بنزین بدون پیش‌بینی مقادیر احتمالی مصرف امکان‌پذیر نیست. چرا که پیش‌بینی (Prediction) فرایندی است که تصمیم‌گیری، برنامه‌ریزی و فرموله کردن سیاست‌های جدید را فراهم و آمادگی لازم برای روبرو شدن با تبعات ناشی از آن را ایجاد می‌کند (موسوی جهرمی و غلامی، ۱۳۹۵، ص ۱۲).

امروزه از روش‌های جدیدی برای پیش‌بینی متغیرهای اقتصادی از جمله مصرف انواع حامل‌های انرژی استفاده می‌شود. روش‌های هوش مصنوعی و یادگیری ماشین، ROSM (Recurrent Self-Organizing Map) از جمله این روش‌ها می‌باشند. روش‌های یادگیری عمیق (Long Short Term memory) یکی از جدیدترین تکنیک‌های زیر مجموعه روش‌های یادگیری ماشین هستند که توسط محققین در بسیاری از زمینه‌ها به کار می‌روند. این روش‌ها در مقایسه با روش‌های یادگیری مرسوم دارای ساختار پیچیده‌تری هستند که امکان بهینه‌سازی و جداسازی غیرخطی را فراهم می‌کنند (کونگ و همکاران، ۲۰۱۷، ص ۱۲) و در مقایسه با سایر روش‌های سنتی عملکرد بهتری دارند (فو و همکاران، ۲۰۱۶، ص ۱۵).

این مطالعه با هدف پیش‌بینی مصرف ماهانه بنزین تا سال ۱۴۰۶، سعی کرده با به‌کارگیری و مقایسه کارایی سه روش یادگیری ماشین، یادگیری عمیق LSTM و میانگین متحرک خودرگرسیون جمع‌بسته فصلی، SARIMA (Seasonal Autoregressive Moving Average)، پیش‌بینی قابل قبولی از مصرف بنزین را ارائه دهد. بیشتر مطالعات انجام شده در

این زمینه در ایران بر روش‌های سنتی اقتصادسنجی و یادگیری‌های ساده تمرکز داشته‌اند به‌همین دلیل این مطالعه، این نوآوری را دارد که از روش یادگیری عمیق نیز برای پیش‌بینی مصرف استفاده کرده و به مقایسه عملکرد این روش با روش‌های یادگیری ساده و مدل‌های سری زمانی سنتی پردازد. روش‌های شبکه عصبی بازگشتی از جمله LSTM نمونه بسیار قدرتمندی از روش‌های یادگیری عمیق هستند که دارای ساختار بازگشتی همراه با حافظه‌های بلندمدت و کوتاه‌مدت جهت افزایش کارایی بیشتر شبکه‌اند و برای مسائل بسیار پیچیده همچون ترجمه ماشینی و پردازش زبان، شرح تصاویر و تشخیص گفتار و پیش‌بینی متغیرهای اقتصادی استفاده می‌شوند. RSOM نیز از روش‌های یادگیری ماشین بر پایه رقابت نرون‌ها است که به صورت بازگشتی عمل کرده و دارای قدرت ماندگاری خطا در تاریخچه یادگیری خود است. از آنجا که پیش‌بینی هر چه دقیق‌تر می‌تواند در مدیریت عرضه و تقاضای بنزین، اتخاذ سیاست‌های مناسب در عرضه قیمت‌گذاری، سرمایه‌گذاری‌های زیرساختی، تهیه و تدوین برنامه‌های بلندمدت کاراتر از جمله تهیه سندهای چشم‌انداز اقتصاد کلان و همچنین لوایح بودجه بسیار موثر باشد. این پژوهش در پنج بخش ارائه شده است. بخش بعدی به بررسی پیشینه مطالعات انجام شده در رابطه با بنزین در جهان و ایران پرداخته است. بخش سوم متدولوژی تحقیق را مورد بحث قرار داده و در بخش چهارم و پنجم نیز به ترتیب، نتایج شبیه‌سازی و نتیجه‌گیری بیان شده‌اند.

## ۲. مروری بر مطالعات پیشین

اهمیت بسیار زیاد بخش حمل و نقل در توسعه کشورها از یک طرف و ضعف جدی حمل و نقل عمومی در اغلب کشورهای در حال توسعه از طرف دیگر، سبب شده مطالعات متعددی در جهان و همچنین ایران در رابطه با مصرف بنزین انجام شود. مطالعات انجام شده در حوزه بنزین در جهان را می‌توان در دو گروه عمده طبقه‌بندی کرد. گروه اول مطالعاتی هستند که تمرکز اصلی آن‌ها بر روی مدل‌سازی تقاضای بنزین با دو هدف اصلی برآورد کسش‌های قیمتی یا درآمدی و یا پیش‌بینی مقدار و قیمت آن بوده است و بیش‌ترین کاربرد آن‌ها نیز در مدیریت تقاضا و تعیین سیاست‌های قیمت‌گذاری و سوبسیددهی بهینه است. بسیاری از مطالعات این بخش برای مدل‌سازی خود فقط از داده‌های سری زمانی مصرف بنزین استفاده کرده‌اند و برخی دیگر علاوه بر خود سری، از متغیرهای

توضیحی مختلف دیگر در سطح خرد و کلان، مانند تولید ناخالص داخلی، قیمت بنزین، شاخص تورم، تعداد اتومبیل‌ها و سطح درآمد خانوارها برای مدل‌سازی استفاده کرده‌اند. از روش‌های مختلف خطی و غیرخطی برای مدل‌سازی در این مطالعات استفاده شده که نتایج متفاوتی نیز بدست آورده‌اند. گروه دوم مطالعاتی هستند که بیشتر در پی یافتن ارتباط میان متغیرهای اقتصادی مانند بیکاری، تولید ناخالص داخلی، رفاه، تولید بنزین، واردات بنزین و یا متغیرهای زیست محیطی مانند آلودگی هوا و میزان انتشار گازهای گلخانه‌ای با مصرف بنزین بوده‌اند. این مطالعات نیز بر نمونه‌های مختلف کشورها و با رهیافت‌های مختلف انجام شده‌اند و نتایج مختلفی داشته‌اند. در ادامه به برخی از این مطالعات انجام‌شده در جهان و ایران اشاره شده است.

## ۱.۲ مطالعات بنزین در جهان

دال (۲۰۱۲)؛ با بررسی ۱۰۰ مطالعه انجام شده در کشورهای پردرآمد و کم درآمد و با استفاده از تحلیل‌های آماری به بررسی الگوی کشش‌های قیمتی و درآمدی پرداخت و سعی در پاسخ به این سوال داشت که آیا الگوی کشش‌های درآمدی و قیمتی در کشورهای پردرآمد و کم‌درآمد ثابت هستند؟ نتایج نشان دادند که اگر چه مقادیر این کشش‌ها در کشورها با درآمدهای متفاوت، یکسان نیستند اما الگوهای پدیدار شدند که می‌توانند در سیاست‌گذاری و قیمت‌گذاری برای بنزین کاربرد داشته باشند و با اتکا به آن‌ها قیمت‌ها را جهت‌دهی و هدف‌گذاری کرد. لین و پرینس (۲۰۱۳)؛ به این مساله پرداختند که آیا نوسانات قیمتی بر کشش قیمتی تقاضای بنزین تاثیر دارند یا خیر؟ نتایج حاکی از این بود که در میان‌مدت نوسانات قیمتی باعث کاهش تقاضای مصرف‌کنندگان می‌شود. هم‌چنین تقاضای مصرف‌کنندگان وقتی نوسانات قیمتی در حد متوسط یا زیاد است درمقایسه با زمانی که نوسانات کم است، کم‌کشش‌تر است. تامبا و همکاران (۲۰۱۷)؛ به بررسی رابطه علیت بین رشد اقتصادی و مصرف بنزین در کامرون بر اساس داده‌های دوره ۱۹۷۵ تا ۲۰۱۴ پرداختند و از آزمون‌های ریشه واحد (unit root tests)، مدل خودرگرسیون برداری (autoregressive vector) و آزمون والد (Wald test) برای تعیین رابطه علیت استفاده کردند. نتایج نشان دادند که رابطه بلندمدت میان این دو متغیر وجود ندارد. هم‌چنین نتایج بیان‌کننده این بودند که یک رابطه دو طرفه کوتاه‌مدت میان مصرف بنزین و

رشد اقتصادی برقرار است. اسپانکن (۲۰۱۸)؛ به مدل‌سازی و پیش‌بینی مصرف بنزین کامرون تا سال ۲۰۲۰ پرداخت. ابتدا با استفاده از داده‌های ۱۹۹۴ تا ۲۰۱۰، کشش قیمتی و درآمدی بنزین را برآورد کرد و سپس با بکارگیری مدل رگرسیون پویا مصرف بنزین را پیش‌بینی کرد. نتایج نشان داد که قیمت تولید ناخالص داخلی و درآمد مهم‌ترین عوامل در مصرف بنزین هستند و مصرف بنزین با نرخ رشد سالانه ۷ درصد تا سال ۲۰۲۰ رشد خواهد کرد. خو و همکاران (۲۰۱۸)؛ نیز با بکار گرفتن ۵ نوع مدل متداول پیش‌بینی از جمله مدل‌های ARIMA - GARCH، هموارسازی نمایی (exponential smoothing)، سیستم‌گری (grey system)، شبکه عصبی و مدل ماشین‌های بردار پشتیبان (support vector machines models) به پیش‌بینی مصرف بنزین در چین پرداختند و نتایج نشان دادند که مدل ساده ARIMA بهترین پیش‌بینی از قیمت بنزین را در کوتاه‌مدت ارائه داده است. درحالی که برای دوره میان‌مدت و بلندمدت ماشین‌های بردار پشتیبان و شبکه‌های عصبی پیشخور کارآتر عمل کرده‌اند. آکلیلو (۲۰۲۰)؛ به مطالعه کشش‌های کوتاه‌مدت و بلندمدت قیمتی و درآمدی برای تقاضای بنزین و دیزل پرداخت. برای انجام این کار از رویکرد کرانه‌های خودرگرسیون برداری با وقفه توزیعی استفاده کرده و همچنین وجود رابطه بلندمدت را با استفاده از داده‌های ۱۹۷۸ تا ۲۰۱۳ مورد آزمون قرار داده است. نتایج این مطالعه نشان داد که کشش‌ها در ۲۸ کشور اتحادیه اروپا متفاوت هستند و مطابق با تئوری کشش‌ها، مقادیر بلندمدت آن‌ها بیشتر از مقادیر کوتاه‌مدت آن‌ها است. علاوه بر این کشش‌های درآمدی بنزین و دیزل چه در کوتاه‌مدت و چه در بلندمدت نسبت به کشش‌های قیمتی آن‌ها بسیار بیشتر است. همین نتیجه بیان می‌کند که اگر برای کاهش آلودگی بخواهند از استراتژی‌های قیمتی استفاده کنند، افزایش نرخ قیمت‌ها باید بیش‌تر از افزایش نرخ درآمدها باشد.

## ۲.۲ مطالعات بنزین در ایران

مطالعاتی نیز در ایران در رابطه با بنزین انجام شده‌اند که اغلب در دسته اول مطالعات قرار دارند و به مدل‌سازی و پیش‌بینی مصرف بنزین پرداخته‌اند و کشش‌های قیمتی و درآمدی را برآورد کرده‌اند. بیشتر این مطالعات از متغیرهای توضیحی مشترک و از داده‌های سالانه بنزین استفاده کرده‌اند. همچنین اغلب از روش‌های سستی اقتصادسنجی و انواع



شبکه‌های عصبی بهره‌گرفته‌اند. تفاوت حائز اهمیت این مطالعه با مطالعات پیشین این است که از روش‌های نوین یادگیری برای پیش‌بینی استفاده کرده و این امکان را فراهم آورده است که کارایی میان روش یادگیری ماشین، RSOM و یادگیری عمیق LSTM و سری زمانی مینگین متحرک خودرگرسیون فصلی را بتوان مقایسه کرد و با استفاده از مدل کارتر پیش‌بینی دقیق‌تری را ارائه داد. در ادامه برخی از این مطالعات انجام شده در ایران مورد بررسی قرار گرفته‌اند. عصاره و همکاران (۲۰۰۹)؛ با استفاده از دو روش الگوریتم بهینه‌سازی ذرات (particle swarm optimization) و الگوریتم ژنتیک به پیش‌بینی مصرف بنزین پرداختند. برای این کار از متغیرهای جمعیت، تولید ناخالص داخلی، واردات، صادرات و تولید بنزین و تعداد اتومبیل‌ها استفاده شد. برای هر سناریو الگوریتم بهینه‌سازی ذرات و الگوریتم ژنتیک، از دو مدل برآورد خطی و نمایی استفاده کردند و از سال ۲۰۰۶ تا ۲۰۳۰ مصرف بنزین پیش‌بینی شد که روش بهینه‌سازی ذرات با خطای ۱/۳٪ به نتایج بهتری رسید. کاظمی و همکاران (۲۰۰۹)؛ از شاخص‌های اقتصادی اجتماعی تولید ناخالص داخلی، جمعیت، تعداد اتومبیل‌ها، و روش‌های شبکه عصبی چندسطحی مبتنی بر یادگیری چند لایه تحت نظارت (supervised multi-layer perceptron) که توسط الگوریتم پس انتشار خطا (back propagation algorithm) آموزش داده شد به پیش‌بینی مصرف بنزین پرداختند. ارزیابی نتایج مدل حاکی از اعتبار برآوردها بود و مصرف بنزین نیز تا سال ۲۰۳۰ پیش‌بینی شد. ابریشمی و همکاران (۲۰۱۰)؛ در مطالعه خود از یک مدل هوشمند ترکیبی جدید متشکل از چهار روش مختلف برای پیش‌بینی بنزین استفاده کردند. نتایج این تحقیق نشان داد که این روش برای پیش‌بینی مصرف بنزین نتایج بهتری در مقایسه با تک‌تک روش‌ها حاصل کرده است. علاوه بر این وقتی از مدل گارچ برای پیش‌بینی نوسانات بنزین استفاده شد، نتایج مدل ترکیبی بهبود یافت. همچنین آزاده و همکاران (۲۰۱۵)؛ با استفاده از الگوریتم رگرسیون بردار پشتیبان (support vector regression algorithm) و روش‌های شبکه عصبی به پیش‌بینی سری زمانی هفتگی مصرف بنزین در بخش حمل و نقل ریلی پرداختند. نتایج پیش‌بینی حاکی از اهمیت دو عامل تعداد مسافران و میزان بار حمل شده به ازاء هر کیلومتر مصرف بنزین در صنعت حمل و نقل ریلی بود. نتایج نشان داد که روش رگرسیون بردار پشتیبان پیش‌بینی بهتری نسبت به روش‌های شبکه عصبی مصنوعی داشته است. فانی و نوروزی (۲۰۱۹)؛ به پیش‌بینی مصرف بنزین در شهر تهران با استفاده از شبکه‌های عصبی پرداختند و برای این منظور از داده‌های ماهانه در

بازه زمانی ۲۰۱۰ تا ۲۰۱۸ استفاده کردند و همچنین از متغیرهای قیمت سوخت، جمعیت، متوسط درآمد خانوارها، ضریب جینی، نرخ اتومبیل‌های هیبریدی به بنزینی، شاخص قیمت کالاها و خدمات، متوسط عمر اتومبیل‌ها برای مدل‌سازی بهره گرفتند. در این تحقیق افزایش قیمت سوخت با سه سناریو متفاوت خوشبینانه، بدبینانه، میانه در نظر گرفته شد و در نهایت نتایج تحقیق حاکی از افزایش تقاضای بنزین در تهران تا سال ۲۰۲۲ بوده است.

### ۳. روش تحقیق

در این بخش، پس از معرفی دقیق مسئله پیش‌بینی سری‌های زمانی، دو روش نوین یادگیری شبکه‌های خودسازمان‌ده بازگشتی (Recurrent Self-Organizing Map)، یادگیری عمیق شبکه‌های با حافظه طولانی کوتاه مدت که از خانواده شبکه‌های عصبی مصنوعی بازگشتی هستند و در این مطالعه استفاده شده‌اند و روش سنتی میانگین متحرک خودرگرسیون فصلی توضیح داده می‌شوند.

#### ۱.۳ مسئله پیش‌بینی سری‌های زمانی

بسیاری از داده‌های موجود در دنیای واقعی مانند داده‌های اقتصادی، داده‌های مربوط به قیمت سهام و ارز، داده‌های پیش‌بینی وضعیت آب و هوا و یا متن و گفتار به صورت سریال / سری (Sequential) و یا اصطلاحاً سری‌های زمانی (Time Series) هستند. ماهیت سریال بودن این داده‌ها بسیار حائز اهمیت است و اگر این ویژگی از این نوع داده‌ها گرفته شود، نتایج قابل اعتماد نبوده و ممکن است بسیار دور از واقعیت باشد. برای یک سری زمانی تک‌متغیره (Univariate Time Series) داده شده مانند  $y_1, y_2, \dots, y_T$  که آن‌ها را مشاهده (Observation) نیز می‌گویند، هدف پیش‌بینی یا تخمین (Estimation) جمله  $y_{T+1}$  از این سری است. به طور کلی، انجام این پیش‌بینی بر پایه این فرض استوار است که  $y_{T+1}$  را می‌توان به صورت یک تابع غیرخطی از  $k$  مشاهده قبلی خودش در نظر گرفت. به‌طور دقیق‌تر می‌توان رابطه زیر را برای محاسبه آن بیان نمود.

$$y_{T+1} = f(y_T, y_{T-1}, \dots, y_{T-k}) + \varepsilon_{T+1} \quad (1)$$

در این رابطه تابع  $f$  همان تابع پیش‌بینی است و  $\varepsilon_{T+1}$  یک مقدار جزء خطای وابسته به زمان  $T + 1$  است که برای جامعیت رابطه و جهت در نظر گرفتن خطا و یا عدم قطعیت آورده شده است. روش‌های بسیار زیاد سستی بر پایه رگرسیون و همچنین روش‌های بر پایه یادگیری و اخیراً یادگیری عمیق برای حل مسئله فوق ارائه شده است (برتو، ۲۰۰۷، ص ۱۳ و اسپانکویچ و اسنکر، ۲۰۰۹، ص ۱۷). با پیچیده‌تر شدن سری‌های زمانی و وابستگی بیش‌تر آن‌ها به عوامل محیطی، فرهنگی، روانشناسی و سیاسی، پیش‌بینی آن‌ها با استفاده از روش‌های سستی مانند ARIMA و GARCH که بر پایه رگرسیون و میانگین مقادیر هستند، مشکل بوده و ممکن است با خطای زیادی همراه باشند. از این‌رو روش‌های یادگیری و یادگیری عمیق (Deep Learning) بر پایه هوش مصنوعی محبوب‌تر و پرکاربردتر شده است. این روش‌ها بدون آن که رابطه صریح ریاضی برای تابع  $f$  بدست آورند، قادر هستند از روی الگوی موجود در سری، رفتار تابع را تقریب زده و به پیش‌بینی بپردازند. از میان روش‌های یادگیری مانند شبکه‌های عصبی مصنوعی، شبکه‌های عصبی سستی به دلیل آنکه از هیچگونه حافظه یا اثر خاصی مربوط به خطای گذشته استفاده نمی‌کنند، قادر به تولید نتیجه مطلوب نیستند. به این دلیل و جهت پیش‌بینی سری‌های زمانی، نوع بهبودیافته‌ای از شبکه‌های عصبی به نام شبکه‌های عصبی بازگشتی (Recurrent Neural Network) مطرح شده که در دو دهه اخیر با افزایش سرعت محاسبات و حافظه، این نوع از شبکه‌ها بهبود یافته و بر روی مسائل بسیاری به کار برده شده است (بیات و سالم، ۲۰۱۸، ص ۲۱، بیات، ۱۳۹۷، ص ۲۵، خان و یری، ۲۰۱۸، ص ۱۴). در این مقاله از دو نوع این شبکه‌های بازگشتی به نام نقشه‌های خودسازمانده بازگشتی و شبکه‌های با حافظه طولانی کوتاه‌مدت استفاده شده است، که در ادامه توضیح داده می‌شوند.

### ۲.۳ نقشه‌های خودسازمانده بازگشتی

نقشه‌های خودسازمانده بازگشتی (RSOM) گونه‌ای از شبکه‌های عصبی مصنوعی رقابتی هستند. این نقشه‌ها قادر هستند داده‌های با ابعاد بالاتر را با کمترین میزان ازدست‌دادن اطلاعات به یک شبکه دو بعدی تصویر نمایند. این توانمندی در این نقشه‌ها، آن‌ها را قادر می‌سازد تا برای اهداف پیش‌بینی و دسته‌بندی داده‌ها مورد استفاده قرار بگیرند (محمدی و همکاران، ۲۰۱۶، ص ۱۸ و بون و کروسیانو، ۲۰۰۲، ص ۱۲).

یک نقشه خودسازمانده، یک شبکه منظم دو بعدی  $G = \{w_1, w_2, w_3, \dots, w_n\}$  شامل  $n$  واحد رقابتی (Competitive Unit)  $w_i$  برای  $i = 1, 2, \dots, n$  را که در آن هر واحد رقابتی به شکل  $w_i = \langle w_i^1, w_i^2, w_i^3, \dots, w_i^k \rangle$  است، که در آن  $k$  بعد هر نمونه (Sample) از داده‌های مشاهده شده است و  $w_i^j$  وزن بعد  $j$ ام را نشان می‌دهد. یک نقشه خودسازمانده با مقادیر تصادفی اوزان تمام واحدهای رقابتی شروع به کار می‌کند و به صورت تکراری هر بار یک نمونه آموزشی مشاهده شده به آن ارائه شده و اوزان واحدهای رقابتی به شکلی که در ادامه توضیح داده می‌شود، بروز می‌گردند. این مرحله، مرحله آموزش (Training Phase) نام دارد. نمونه‌های آموزشی می‌توانند به شکل زیر در نظر گرفته شوند:

$$y_t = f(X_t) = f(y_{t-1}, y_{t-2}, \dots, y_{t-k}), \text{ for } t = k + 1, k + 2, \dots, T \quad (2)$$

بعد از ارائه یک نمونه آموزشی به شکل  $(X_t = \langle x_t^1, x_t^2, \dots, x_t^k \rangle, y_t)$ ، نزدیکترین واحد رقابتی به آن محاسبه شده و به عنوان واحد رقابتی برنده معرفی می‌شود. برای این کار از فاصله اقلیدسی یا منهن بر روی شبکه می‌تواند استفاده شود. سپس اوزان واحدهای رقابتی به گونه‌ای بروز می‌شوند که واحدهای رقابتی به نمونه آموزشی  $X_t$  نزدیک‌تر شوند. به صورت دقیق‌تر می‌توان نوشت:

$$z_i(t) = (1 - \alpha)z_i(t) + \alpha(X_t - w_i(t)), \quad (3)$$

$$z_b = \min_{1 \leq i \leq n} \{\|z_i(t)\|\}. \quad (4)$$

در این روابط  $0 < \alpha < 1$  نرخ نفوذ (Leaking Rate) بوده و برای کنترل میزان تاثیر خطاهایی که یک واحد رقابتی حاصل از ارائه تکرارهای قبل داشته است به کار می‌رود. مقدار  $(X_t - w_i(t))$  در واقع نشان‌دهنده فاصله واحد رقابتی  $w_i$  از نمونه آموزشی  $X_t$  است. این فاصله بر اساس متر منهن یا اقلیدسی می‌تواند محاسبه گردد و به طور کلی هدف از آن یافتن معیاری برای تخمین میزان نزدیکی داده  $X_t$  به واحد رقابتی  $w_i(t)$  است. مقدار  $z_i(t)$  میزان خطا برای واحد رقابتی  $i$ ام را نشان می‌دهد که در ابتدای مرحله آموزش شبکه برابر صفر در نظر گرفته می‌شود ( $z_i(t) = 0$ ). در نهایت واحد رقابتی برنده، که با  $b$  نمایش داده شده است، واحدی است که دارای کمترین خطا می‌باشد. پس از تعیین برنده،

اوزان واحدهای رقابتی و همینطور مقدار خروجی آن‌ها یعنی  $y_i(t+1)$  به شکل زیر به‌روز می‌شوند:

$$w_i^j(t+1) = w_i^j(t) + \gamma(t)h_{ib}(t)(x_t^j - w_i^j(t)), \quad (5)$$

$$y_i(t+1) = y_i(t) + \gamma(t)h_{ib}(t)(y_t - y_i(t)), \quad (6)$$

که  $\gamma(t) \in (0,1)$  ضریب یادگیری (Learning Coefficient)،  $h_{ib}(t)$  پارامتری برای کنترل میزان تاثیرپذیری واحد رقابتی  $i$  ام از واحد رقابتی برنده است. انتظار بر این است که هرچه فاصله یک نرون از واحد رقابتی برنده کمتر باشد، تغییرات در اوزان آن نیز بیشتر تاثیر بپذیرد. این دو پارامتر وابسته به زمان یا همون ترتیب ارائه نمونه‌های آموزشی به شبکه، می‌توانند تغییر کنند، در واقع در ابتدای مرحله آموزش و برای نمونه‌های آموزشی ابتدایی، این پارامترها بیشتر بوده و به مرور زمان و ارائه نمونه‌های آموزشی مقدار آن‌ها به‌عنوان نمونه می‌تواند به صورت زیر کاهش یابد:

$$\gamma(t) = \gamma_0 \exp\left(-\frac{t}{T}\right), \quad (7)$$

$\gamma_0$  یک مقدار پایه برای یادگیری بوده و  $T$  تعداد کل نمونه‌های آموزشی است. در مرحله آموزش می‌توان چندین بار تمام داده‌ها را از اولین داده آموزشی تا آخرین داده آموزشی به شبکه ارائه نمود و آن را آموزش داد. دقت شود، که این کار احتمال تاثیرپذیری آموزش را از مقداردهی اولیه اوزان واحدهای رقابتی، به شکل قابل قبولی کاهش می‌دهد. در نهایت هر واحد رقابتی یک مقدار خروجی  $y_i(T-k)$  خواهد داشت. در پایان این مرحله، آموزش نقشه خودسازمانده تمام شده و قادر خواهد بود به ازای یک نمونه آموزشی جدید  $(X_{T+1} = \langle y_T, y_T, \dots, y_{T-k+1} \rangle, ?)$  که همان  $k$  جمله پایانی سری زمانی است، جمله  $T+1$  ام را پیش‌بینی نماید. برای این کار ابتدا داده  $X_{T+1}$  به شبکه ارائه شده و سپس واحد رقابتی برنده محاسبه شده و مقدار خروجی این واحد رقابتی، به عنوان مقدار پیش‌بینی از  $y_{T+1}$  تعیین می‌شود. در نهایت برای کاهش اثر مقداردهی اولیه واحدهای رقابتی که به صورت تصادفی انجام می‌گردد و همچنین یادگیری دقیق‌تر شبکه خودسازمانده، روال آموزش شبکه را برای چندین بار متوالی تکرار می‌شود که به آن epoch گفته می‌شود.

از ویژگی‌های نقشه‌های خودسازمانده بازگشتی می‌توان به توانایی آن‌ها در کار کردن با داده‌های ناقص (برای مثال داده‌های سری زمانی مصرف بنزین در یک سال خاص در دسترس نباشد) و همین‌طور حساسیت بسیار کم آن‌ها به داده‌های نویزی (برای مثال داده‌های سری زمانی مصرف بنزین در برخی از سال‌ها همراه با خطا در اندازه‌گیری و یا گزارش آن باشد) اشاره داشت.

### ۳.۳ شبکه‌های با حافظه طولانی کوتاه‌مدت


شبکه‌های با حافظه طولانی کوتاه‌مدت (LSTM) نوع خاصی از نسخه تکامل یافته شبکه‌های عصبی بازگشتی هستند که برای امور پیش‌بینی سری‌های زمانی و تشخیص گفتار و پردازش تصویر کاربردهای فراوانی دارند. این شبکه‌ها از حافظه‌های بلندمدت تری برای تثبیت رویدادها و وابستگی‌های ضمنی میان متغیرها و خروجی، استفاده می‌نمایند. در شبکه‌های عصبی بازگشتی، هر نرون یا واحد پردازشی قادر به حفظ حافظه به منظور حفظ اطلاعات مرتبط با ورودی قبلی می‌باشد. این ویژگی در داده‌های سری که اطلاعات فعلی با اطلاعات گذشته ارتباط دارند، اهمیت پیدا می‌کند. این نوع از شبکه‌های عصبی، همان‌طور که از اسم آن‌ها پیداست به صورت بازگشتی عمل می‌کنند. یعنی فرایندی روی تک تک عناصر انجام می‌شود که خروجی آن وابسته به ورودی فعلی و فرآیندهای قبلی است که در آن خروجی از مرحله قبل (زمان  $t$ ) با ورودی در مرحله جدید (زمان  $t + 1$ ) ترکیب می‌شوند. شکل ساده و عمومی این نوع شبکه‌ها در شکل ۱ نمایش داده شده است و روابط مربوط به آن‌ها در ادامه آورده شده است.

$$h_t = f_1(w_1 \cdot x_t + w_2 \cdot h_{t-1} + b_h) \quad (۸)$$

$$y_t = f_2(w_3 \cdot x_t + b_0) \quad (۹)$$

توابع  $f_1$  و  $f_2$  توابع فعال‌سازی هستند، که برای  $f_1$  معمولاً توابع غیرخطی تانژانت هیپربولیک (Hyperbolic Tangent) و (rectified linear unit) RELU و برای  $f_2$  نیز معمولاً از سافت‌ماکس (SoftMax) استفاده می‌شود (گریوز (۲۰۱۳)). همان‌طور که اشاره شد حالت مخفی  $h_t$  را به عنوان حافظه شبکه نیز در نظر می‌گیریم که اطلاعاتی درباره آنچه در گام‌های

زمانی قبلی رخ داده است را در خود نگهداری می‌کند. در عمل این مکانیزم حافظه قادر به بهره‌برداری از گام‌های طولانی نیست. به عبارت دیگر  $h_t$  قادر نیست اطلاعات را از تعداد زیادی گام زمانی قبل تر حفظ کند و در نتیجه محدود به چند گام زمانی قبلی است. همچنین این نوع شبکه‌ها با مشکل محو شدن گرادیان (Gradient Vanishing) در ساختار خود روبه‌رو هستند (هچریتزر و اشمیدهابر، ۱۹۹۷، ص ۲۱). گرادیان به انتقال اطلاعات استفاده شده در دوره‌های قبلی (به ویژه در سری‌های زمانی طولانی) به دوره‌های اخیر دلالت دارد. حال در شبکه‌های عصبی بازگشتی، از آنجایی که از هیچ حافظه بلندمدت استفاده نمی‌شود و این شبکه‌ها در راستای بهینه‌سازی و تلاش در کاهش مقدار خطا در خروجی حرکت می‌کنند، باعث می‌شود که این اطلاعات مفید در طی زمان کوچک و کوچک‌تر شده و در نهایت تاثیر بسیار جزئی داشته باشند. این مشکل که به عنوان یک ضعف اساسی در این شبکه‌ها محسوب می‌شد، انگیزه‌ای شد که نوع تکامل یافته‌ای از آن‌ها یعنی شبکه‌های LSTM ارائه شود، که در ادامه به تشریح آن‌ها پرداخته شده است.



شکل ۱. شمای کلی شبکه‌های عصبی بازگشتی. در این شکل،  $x_t$  ورودی شبکه،  $h_n$  حالت داخلی یا حافظه شبکه و  $o_t$  نیز خروجی شبکه است.

همان‌طور که بیان شد شبکه‌های عصبی بازگشتی سستی در ذخیره‌سازی اطلاعات مرتبط با ورودی‌های گذشته به مدت طولانی ناتوان هستند. علاوه بر اینکه این ویژگی توانایی این شبکه‌ها در مدل‌سازی ساختارهای بلندمدت را تضعیف می‌کند، این فراموشی باعث می‌شود تا این نوع از شبکه‌ها در زمان تولید دنباله در معرض ناپایداری قرار گیرند. داشتن یک حافظه بلندمدت‌تر دارای اثر تثبیت‌کننده است و حتی اگر شبکه‌ها نتوانند از تاریخچه اخیر خود درک صحیحی پیدا کنند، باز با این وجود قادر هستند با نگاه در گذشته پیش‌بینی خود را کامل کنند. یک راه‌حل ایده‌آل استفاده از یک حافظه بلندمدت است، ایده‌ای که منجر به

معماری و ایجاد شبکه‌های LSTM شد (گریوز، ۲۰۱۳، ص ۱۴). در شبکه عصبی بازگشتی سستی، محتوا در هر گام زمانی از نو بازنویسی می‌شود ولی در یک شبکه عصبی بازگشتی LSTM شبکه قادر است نسبت به حفظ حافظه فعلی از طریق دروازه‌های (Gate) معرفی شده تصمیم‌گیری کند. به‌طور شهودی اگر واحد LSTM ویژگی مهمی در دنباله ورودی در گام‌های ابتدایی را تشخیص دهد بسادگی می‌تواند این اطلاعات را طی مسیر طولانی منتقل کند. بر خلاف روش‌های پیشین که صرفاً جمع متوازن سیگنال‌های ورودی را محاسبه کرده و سپس از یک تابع فعال‌سازی عبور می‌داد، هر واحد LSTM از یک حافظه  $C_t$  در زمان  $t$  بهره می‌برد. خروجی  $h_t$  فعال‌سازی واحد LSTM و  $f_1$  فعال‌سازی واحد  $C_t$  هستند که در آن دروازه خروجی بوده که کنترل‌کننده میزان محتوایی است که از طریق حافظه ارائه می‌شود. سلول حافظه  $C_t$  نیز با فراموشی نسبی حافظه فعلی و اضافه کردن محتوای حافظه جدید به‌صورت  $\hat{C}_t$  بروز رسانی می‌شود. آن میزان از حافظه فعلی که باید فراموش شود توسط دروازه فراموشی  $G_f$  کنترل می‌شود و آن میزانی از محتوای حافظه جدید که باید به سلول حافظه اضافه شود توسط دروازه بروز رسانی  $G_u$  انجام می‌گیرد. توابع فعال‌سازی  $f_1$  و  $f_2$  و  $f_3$  به ترتیب سیگموئید (Sigmoid) و تانژانت هیپربولیک و سافت‌ماکس در نظر گرفته می‌شوند. بنابراین معادلات زیر را خواهیم داشت (گریوز، ۲۰۱۳، ص ۱۵):

$$G_{f(t)} = f_1(w_f[h_{(t-1)}, x_{(t)}] + b_f) \quad (10)$$

$$G_{u(t)} = f_1(w_u[h_{(t-1)}, x_{(t)}] + b_u) \quad (11)$$

$$G_{o(t)} = f_1(w_o[h_{(t-1)}, x_{(t)}] + b_o) \quad (12)$$

$$\hat{C}_t = f_2(w_c[h_{(t-1)}, x_{(t)}] + b_c) \quad (13)$$

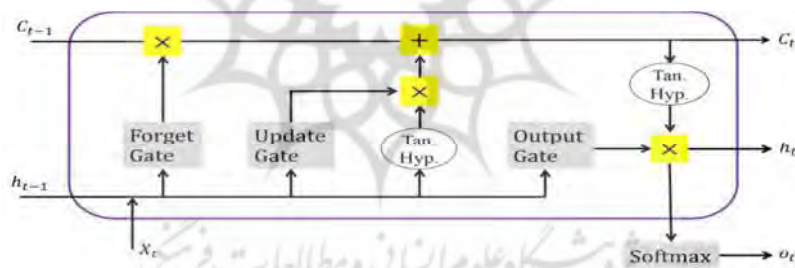
$$C_{(t)} = G_{f(t)} \cdot C_{(t-1)} + G_{u(t)} \cdot \hat{C}_t \quad (14)$$

$$h_{(t)} = G_{o(t)} \cdot f_2(C_{(t)}) \quad (15)$$

$$y_{(t)} = f_3(w_y \cdot h_{(t)} + b_y) \quad (16)$$



در پیاده‌سازی این روابط عموماً از بردارهای یک بعدی و ماتریس‌ها استفاده می‌شود و تمام عملگرهای استفاده شده در این آنها، مانند ضرب و جمع، عملگرهای ماتریسی هستند. در این شبکه اصطلاحاً سه دروازه وجود دارد که همگام با افزایش زمان (پارامتر  $t$ ) پارامترهای آنها نیز بروز شده و از طریق آن شبکه نسبت به کنترل جریان داده درون خود اقدام می‌کند. این سه دروازه عبارتند از: دروازه فراموشی (Forget Gate)، دروازه بروز رسانی (Update Gate) و دروازه خروجی (Output Gate). علاوه بر این سه دروازه، یک سلول حافظه (Memory Cell) نیز وجود دارد که نماد  $C$  نشان داده شده است. دروازه فراموشی وظیفه کنترل جریان اطلاعات از گام زمانی قبلی را دارد. این دروازه مشخص می‌کند آیا اطلاعات حافظه از گام زمانی قبل مورد استفاده قرار گیرد یا خیر و در صورت تایید به چه میزان باشد. دروازه بروز رسانی، وظیفه کنترل جریان اطلاعات جدید را بر عهده دارد. این دروازه مشخص می‌کند آیا در گام زمانی فعلی باید از اطلاعات جدید استفاده شود یا خیر و اگر بلی به چه میزان. دروازه خروجی نیز مشخص می‌کند چه میزان از اطلاعات گام زمانی قبل با اطلاعات گام زمانی فعلی به گام زمانی بعد منتقل شود. در نهایت با اطلاعات حاصل از سلول حافظه بروز رسانی می‌گردد.



شکل ۲. یک واحد از معماری حافظه طولانی کوتاه مدت

شبکه‌های LSTM یکی از کاراترین مدل‌ها برای یادگیری داده‌های سریال و وابسته به زمان هستند. همچنین از آنجایی که برخی از داده‌ها همانند سری‌های زمانی مصرف که ممکن است وابسته به ماه‌های مختلف سال حالت دوره‌ای داشته باشند، ایجاب می‌کنند که توالی‌های طولانی مدت برای یک مدل‌سازی موفق در نظر گرفته شود، امری که این شبکه‌ها به خوبی از عهده آن برمی‌آیند. همچنین شبکه‌های LSTM قادر هستند پیش‌بینی را برای

چندین متغیر ورودی و همبستگی چند مقدار خروجی انجام دهند، بدون آن که اندازه مدل تغییر چشمگیری داشته باشد (گریوز، ۲۰۱۳، ص ۱۷).

### ۴.۳ روش میانگین متحرک خودرگرسیون فصلی

از آنجایی که برای مقایسه نتایج پیش‌بینی علاوه بر روش‌های یادگیری عمیق، روش خودرگرسیون میانگین متحرک فصلی نیز بکار گرفته شده است، در این بخش به صورت خلاصه این روش نیز مرور می‌شود. سری زمانی مانا  $\{X_t\}$  را که در معادله‌ی تفاضلی

$$\phi_p(B)\Phi_p(B^s)X_t = \theta_q(B)\Theta_q(B^s)Z_t \quad (17)$$

صدق می‌کند، سری زمانی میانگین متحرک خودرگرسیون فصلی با دوره تناوب  $s$  می‌نامیم و به صورت  $X_t \sim SARMA(p, q)(P, Q)_s$  نشان می‌دهیم. در این معادله  $\{Z_t\}$  یک نوفه سفید با توزیع نرمال صفر و واریانس ثابت است،  $\phi_p(B)$  و  $\theta_q(B)$  عملگرهای خودرگرسیون و میانگین متحرک عادی‌اند و عملگرهای  $\Phi_p(B^s)$  و  $\Theta_q(B^s)$  عملگرهای خودرگرسیون و میانگین متحرک فصلی‌اند. (باکس و پیروز، ۱۹۷۰، ص ۵)

مدل‌های SARMA به‌عنوان حالت خاصی از مدل‌های ARMA، مدل‌های فصلی ضریبی نیز نامیده می‌شوند. زمانی که با داده‌های نامانا مواجه باشیم و نیازمند یک مرحله تفاضلی کردن داده‌ها باشیم مدل SARMA تبدیل به مدل میانگین متحرک جمع‌بسته خودرگرسیون فصلی می‌شود و می‌نویسیم  $X_t \sim SARIMA(p, d, q)(P, D, Q)_s$  که در پیش‌بینی‌های حاصل از یک مدل SARIMA پارامتر  $D$  دامنه‌ی موج سینوسی و فصلی را کنترل می‌کند.

یک سری زمانی فاقد هریک از شرایط مانایی از جمله تنوع رفتار توابع میانگین و اتوکواریانس نامانا نامیده می‌شود. در مقایسه با نمودار سری‌های زمانی مانا که تمایل به نوسان حول سطحی ثابت با دامنه‌ای ثابت دارند، تغییر در سطح یا دامنه‌ی نوسان، از مشخصه‌های نمودارهای سری‌های زمانی نامانا است. معمولاً در تحلیل چنین سری‌هایی نخست با استفاده از تبدیل‌های مناسب، آن‌ها را به سری‌هایی با میانگین و واریانس ثابت تبدیل کرده، سپس از مدل‌ها و روش‌های تحلیل سری‌های مانا استفاده می‌کنند. یکی از روش‌های پرکاربرد برای حذف روند در سری زمانی و تثبیت‌کننده‌ی میانگین و واریانس،

تفاضلی کردن است، برای این منظور عملگر تفاضلی مرتبه‌ی اول، به این صورت تعریف می‌شود (باکس و جنکینز، ۱۹۷۰، ص ۱۴۲).

$$\forall X_t = X_t - X_{t-1} = (1 - B)X_t \quad (18)$$

زمانی که سری‌های زمانی SARIMA بعد از تفاضلی کردن، رفتار متناوبی با دوره‌ی تناوب  $s$  از خود نشان دهند، همبستگی‌های زیاد بین عناصر سری زمانی در تاخیر  $s$  علاوه‌بر همبستگی‌های معمول خواهد بود. ساختار این همبستگی‌ها بر خلاف روش‌های ARMA بسیار متنوع است ولی می‌توان با کمک مقادیر خودهمبستگی و خودهمبستگی جزئی به علاوه روش‌های آزمون خطا و مقایسه مدل‌های مختلف، به مدل مناسب دست یافت.

روش‌های شناسایی، برازش و ارزیابی مدل‌های SARIMA شبیه روش‌های مربوط به مدل‌های ARIMA است. به‌طور خلاصه، در ابتدا برای تعیین مرتبه‌های  $d$  و  $D$  رفتار خودهمبستگی‌های جزئی را ارزیابی می‌کنیم. نزولی میرا نیاز به تفاضلی کردن عادی را نشان می‌دهد و نزولی آهسته و متناوب نیاز به تفاضلی کردن فصلی را. اگر این تشخیص‌ها امکان‌پذیر نباشد یا بیش از یک مدل شناسائی شود، می‌توان از شاخص‌های خطا و ملاک‌های اطلاع برای تشخیص مدل نهایی از بین چند مدل تشخیصی استفاده کرد.

## ۴. نتایج تحلیلی

### ۱.۴ نتایج تحلیلی دو روش یادگیری عمیق با حافظه طولانی کوتاه‌مدت

در این بخش، از دو روش یادگیری نقشه‌های خودسازمانده بازگشتی (RSOM) و روش یادگیری عمیق با حافظه طولانی کوتاه‌مدت (LSTM) برای پیش‌بینی مصرف بنزین در کشور استفاده شد. داده‌های مورد استفاده در این تحقیق ۱۹۲ داده ماهانه مصرف بنزین در کشور مربوط به دوره زمانی از ابتدای سال ۱۳۸۱ تا انتهای سال ۱۳۹۶ می‌باشد که از تراژنامه انرژی ایران استخراج شده‌اند. این مقادیر متوسط مصرف روزانه در ماه‌های مختلف را بیان می‌دارند که نمودار آن‌ها در شکل ۳ نشان داده شده است. برای ارزیابی دو روش اول، ابتدا داده‌ها به دو قسمت داده‌های آموزش و داده‌های تست تقسیم می‌شوند. داده‌های آموزش ۸۷/۵ درصد کل داده‌ها، یعنی ۱۴ سال ابتدایی و داده‌های تست ۱۲.۵ درصد کل داده‌ها یعنی دو سال پایانی در نظر گرفته شده‌اند. برای دو رویکرد اول مشاهدات در

بازه [0,1] نرمال شده و مورد استفاده قرار گرفته‌اند. این نرمال‌سازی، خطای الگوریتم‌های یادگیری را با کاهش حساسیت آن‌ها نسبت به مقیاس‌پذیری داده‌ها کاهش داده و باعث بهبود در فرآیند یادگیری می‌شود.



شکل ۳. کل داده‌های ماهانه مصرف بنزین در کشور از سال ۱۳۸۱ تا ۱۳۹۶، میلیون لیتر  
منبع: محاسبات تحقیق

جهت مقایسه نتایج روش‌ها دو معیار ریشه میانگین مربع خطاها (RMSE) و میانگین قدرمطلق درصدی خطاها (MAPE) که در ادامه روابط آن‌ها آورده شده است، استفاده شده‌اند.

$$RMSE = \sqrt{\frac{\sum_{t=1}^T (y_t - \hat{y}_t)^2}{T}} \quad (18)$$

$$MAPE = \frac{1}{T} \sum_{t=1}^T \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (19)$$

در این روابط  $T$  تعداد کل داده‌های تست،  $y_t$  مقدار دقیق و  $\hat{y}_t$  مقدار پیش‌بینی شده توسط الگوریتم برای داده تست  $t$ ام است. از آنجایی که الگوی مصرف بنزین متأثر از شرایط آب و هوایی و فصلی و ایام تعطیلی است، برای بکارگیری روش‌های RSOM و LSTM از ۳ دوره زمانی مختلف  $k=12,3,6$  ماهه در آموزش شبکه‌ها استفاده شده است و نتایج به صورت جداگانه آورده شده‌اند. مقدار  $k$  همانطور که در رابطه (۱) آورده شده است، به این معنی است که مقدار یک جمله در سری زمانی مصرف بنزین بر اساس  $k$  جمله قبل از خودش به شبکه‌های یادگیرنده آموزش داده می‌شود. همچنین مقادیر انتخاب شده برای پارامترهای هر کدام از این روش‌ها در جدول ۱ آورده شده است.

پیش‌بینی مصرف بنزین در ایران با استفاده از ... (ندا بیات و علی رضائی) ۷۹

لازم به ذکر است که این پارامترها با توجه به اندازه داده‌های آموزشی و همچنین بر پایه آزمون سعی و خطا انتخاب شده‌اند که به صورت بهینه برای هر روش تعیین می‌شوند.

جدول ۱. مقادیر پارامترهای استفاده شده در روش‌های LSTM و RSOM

منبع: محاسبات تحقیق


شبکه منظم دو بعدی $20 \times 20$	اندازه شبکه	روش نقشه‌های خودسازمانده بازگشتی (RSOM)
(1, 0.7, 40)	$(\gamma_0, \alpha, epoch)$	
20 نرون و یک لایه	تعداد لایه‌های مخفی و تعداد نرون‌ها	روش حافظه طولانی کوتاه-مدت LSTM
Epoch=30 تعداد batch برابر 2	Epoch اندازه batch	

همچنین از آنجایی که شبکه‌های یادگیری بر پایه یادگیری‌های تصادفی عمل می‌کنند، برای اطمینان بیشتر از نتایج گزارش شده، هر کدام از این روش‌ها برای ۲۵ بار اجرا و برای هر بار اجرا معیارهای RMSE و MPEA محاسبه شده و بهترین، بدترین و مقدار میانگین آن‌ها گزارش شده است. در جداول ۲، ۳ و ۴ به ترتیب نتایج برای هر دو روش RSOM و LSTM برای  $k=3$ ،  $k=6$  و  $k=12$  ارائه شده‌اند. همچنین شکل‌های ۴، ۵ و ۶، نمودارهای پیش‌بینی این روش‌ها را برای ۲۴ ماه پایانی داده‌های در دسترس نشان می‌دهند. این نمودارها مربوط به اجرای میانه (سیزدهمین بهترین RMSE از میان بیست و پنج اجرا) انتخاب و نمایش داده شده‌اند.

جدول ۲. معیارهای مقایسه از ۲۵ اجرا روش‌های LSTM و RSOM برای  $k = 3$

منبع: محاسبات تحقیق

	RMSE				MAPE			
	Min	Max	Mean	Stdev.	Min	Max	Mean	Stdev.
RSOM	۷/۰۷۷۰۷۱	۱۰/۴۲۷۳۳	۷/۹۱۵۶۲۹	۰/۷۵۷۹۵۲	۶/۴۶۰۹۲۵	۹/۲۲۱۱۶۴	۸/۱۲۸۱۹۵	۰/۶۸۷۰۳۵
LSTM	۴/۵۰۵۵۴۹	۶/۴۱۳۳۱۵	۵/۲۴۷۲۵۶	۰/۴۸۱۰۷۵	۴/۴۲۳۰۹	۶/۵۸۳۴۸۸	۵/۴۷۹۸۸۲	۰/۶۳۳۵۰۱




شکل ۴. نمودارهای پیش‌بینی شده از روش‌های RSOM و LSTM برای  $k = 3$ . این نمودار مربوط به اجرای میانه نسبت به معیار RMSE می‌باشند.

منبع: محاسبات تحقیق

جدول ۳. معیارهای مقایسه از ۲۵ اجرا روش‌های RSOM و LSTM برای  $k = 6$

منبع: محاسبات تحقیق

	RMSE				MAPE			
	Min	Max	Mean	Stdev.	Min	Max	Mean	Stdev.
RSOM	۵/۹۱۰۷۳۴	۷/۹۴۷۳۲۹	۶/۸۳۱۳۲۳	۰/۵۵۸۴۷۶	۵/۸۶۵۰۹۹	۷/۵۶۱۴۴۶	۶/۸۶۹۲۶۴	۰/۴۵۴۰۶۹
LSTM	۳/۲۲۳۲۸	۴/۸۴۷۱	۳/۹۸۱۴۲۷	۰/۵۰۰۸۸۴	۳/۳۷۹۶۰۷	۶/۰۸۰۸۱۱	۴/۲۳۳۱۲۵	۰/۵۴۹۱۵۹



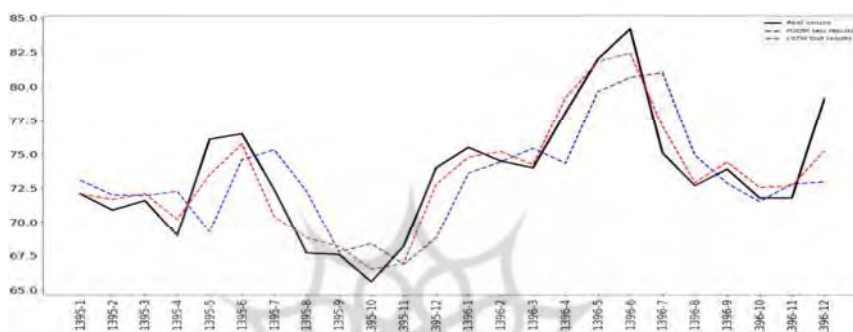
شکل ۵. نمودارهای پیش‌بینی شده از روش‌های RSOM و LSTM برای  $k = 6$ . این نمودار مربوط به اجرای میانه نسبت به معیار RMSE می‌باشند.

منبع: محاسبات تحقیق

جدول ۴. معیارهای مقایسه از ۲۵ اجرا روش‌های RSOM و LSTM برای  $k = 12$

منبع: محاسبات تحقیق

	RMSE				MAPE			
	Min	Max	Mean	Stdev.	Min	Max	Mean	Stdev.
RSOM	۴/۱۴۲۳۴۳	۵/۸۸۶۱۶۵	۵/۱۷۷۱۸۱	۰/۴۷۱۲۴۵	۴/۶۳۱۶۷۲	۶/۰۸۶۱۱۵	۵/۳۹۹۸۸۵	۰/۴۵۴۲۵۹
LSTM	۲/۶۶۷۸۰۵	۴/۵۶۱۲۹۷	۳/۴۶۱۷۳۶	۰/۵۳۹۲۵۱	۲/۵۴۱۱۵۹	۴/۷۱۷۰۱۷	۳/۵۵۱۱	۰/۵۵۶۷۹۵

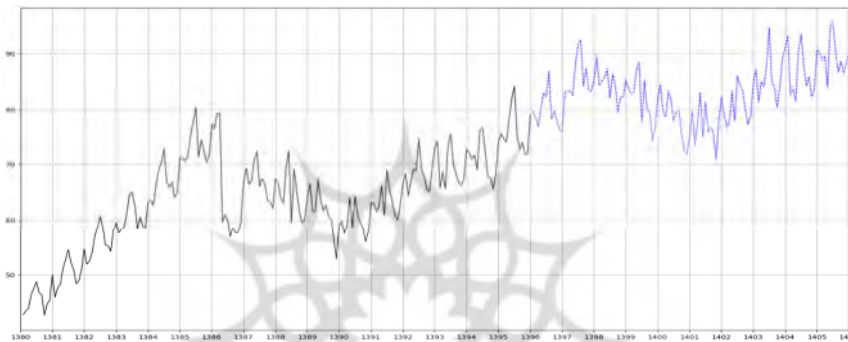


شکل ۶. نمودارهای پیش‌بینی شده از روش‌های RSOM و LSTM برای  $k = 12$  این نمودار مربوط به اجرای میانه نسبت به معیار RMSE می‌باشند.

منبع: محاسبات تحقیق

هر دو روش RSOM و LSTM در زبان برنامه‌نویسی پایتون کد شده و روش SARIMA در نرم افزار R و بر روی یک کامپیوتر شخصی با مشخصات CPU Intel(R) Core(TM) i5-2500k @ 3.30GHz and 4 GB RAM اجرا شده‌اند. متوسط اجرای روش RSOM حدود 21 ثانیه و متوسط اجرای روش LSTM حدود 39 ثانیه زمان‌بر است. هر چند RSOM سریع‌تر از LSTM است، اما همانطور که از جداول فوق می‌توان نتیجه‌گیری کرد، روش یادگیری عمیق LSTM عملکرد بهتری را در هر دو معیار خطا داشته است. هم‌چنین همان‌طور که از نتایج فوق مشخص است، هر دو الگوریتم یادگیری عمیق LSTM و یادگیری RSOM برای حالت  $k = 12$  در مقایسه  $k = 3$  و  $k = 6$  نتایج دقیق‌تری را به‌دست آورده‌اند. به این ترتیب الگوی مصرف بنزین در هر ماه متأثر از میزان مصرف در همان ماه از سال قبل می‌باشد. این نتیجه فارغ از این که چه روش یادگیری برای پیش‌بینی الگوی مصرف بنزین به کار می‌رود، بدست آمده است و نشان می‌دهد که در نظر گرفتن

بازه‌های زمانی ۱۲ ماهه در مصرف بنزین منجر به پیش‌بینی دقیق‌تری می‌شود. بعد از انجام تست‌های فوق، از آنجایی که الگوریتم یادگیری عمیق در حالت  $k=12$  قادر به ایجاد مدلی با کم‌ترین خطا بوده است، برای پیش‌بینی ماهانه مصرف بنزین مورد استفاده قرار گرفت. برای این کار ابتدا روش LSTM را با بهترین تنظیمات بدست آمده از اجراهای فوق بر روی تمام داده ۱۹۲ داده در دسترس اجرا نموده و پس از مرحله یادگیری، با کمک آن به پیش‌بینی مصرف بنزین در ۱۰ سال آتی پرداخته شده است. شکل ۷ نتایج بدست آمده را نشان می‌دهد.



شکل ۷. نتایج پیش‌بینی ماهانه مصرف بنزین با استفاده از روش LSTM برای ۱۰ سال (از ۱۳۹۷ تا ۱۴۰۶)  
منبع: محاسبات تحقیق

با توجه به تاثیرپذیری مصرف بنزین از شرایط آب و هوایی و محیطی و ایام تعطیل، برای بکارگیری روش‌های RSOM و LSTM از ۳ دوره زمانی مختلف  $k=3, 6, 12$  ماهه در آموزش شبکه‌ها استفاده شد. نتایج نشان دادند که  $k=12$  در مقایسه با دو گزینه دیگر نتایج دقیق‌تری را داشته و علاوه بر این با استناد به دو معیار خطای ریشه میانگین مربع خطاها و میانگین درصد خطاها، روش LSTM عملکرد بهتری را داشت. در نتیجه با توجه به برتری نتایج، این روش برای پیش‌بینی داده‌های ماهانه بنزین تا سال ۱۴۰۶ بکار گرفته شد و نتایج پیش‌بینی بیانگر این است که از ۱۳۹۷ تا سال ۱۴۰۶ تقاضای بنزین رشدی ۱۰ تا ۱۵ درصد را همراه خواهد داشت به عبارتی در حالت خوشبینانه در طی سالهای ۱۳۹۶ تا ۱۴۰۶، به میزان مصرف بنزین ۱۰ درصد افزوده خواهد شد و در بدترین حالت ۱۵ درصد رشد خواهد کرد. نکته جالب این است که این رشد نوسانات فصلی داشته و در هر سال



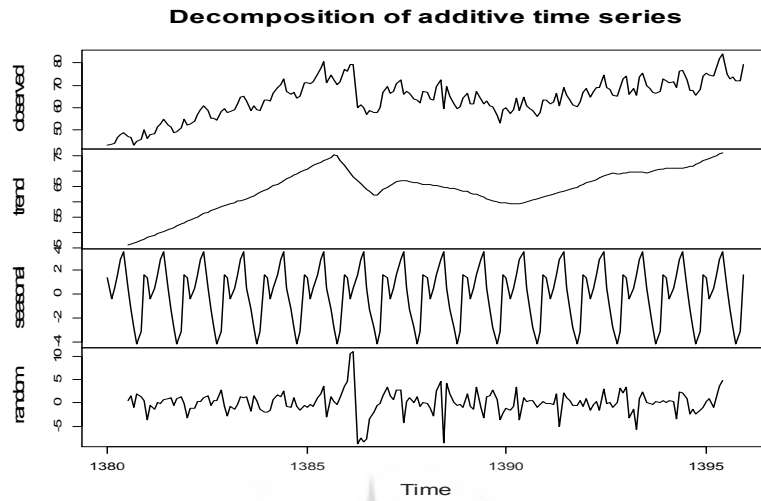
افت‌وخیزهای مستمری را دنبال می‌کند. به طور میانگین نرخ رشد بنزین در هر سال ۱ تا ۱.۵ درصد می‌باشد، که این مقدار ۵۰ درصد بیشتر از میانگین پیش‌بینی شده رشد مصرف انرژی جهانی است.

## ۲.۴ نتایج تحلیلی روش میانگین متحرک خودرگرسیون فصلی

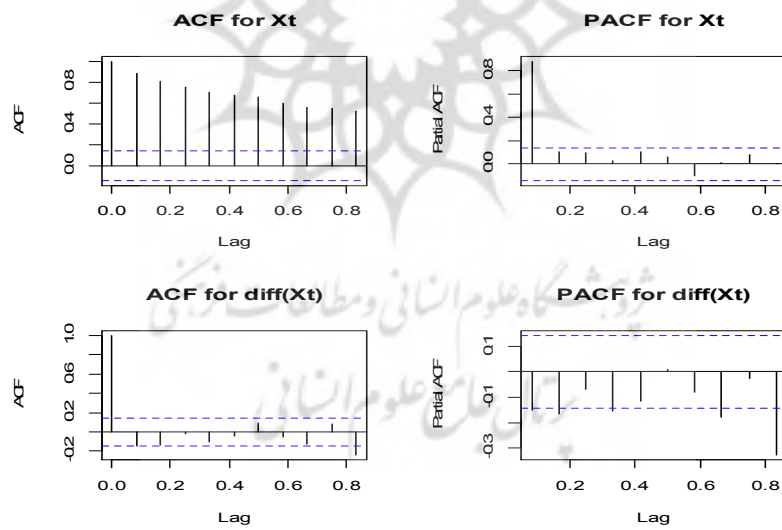
در این بخش به تحلیل و مدل‌سازی مشاهدات به روش میانگین متحرک خودرگرسیون فصلی می‌پردازیم. مشابه رویکرد اکثر روش‌های اقتصادسنجی کلاسیک در گام نخست مانایی مشاهدات را مورد بررسی قرار می‌دهیم. برای این کار ابتدا آزمون ریشه‌ی واحد به روش زیوت-اندرو را انجام می‌دهیم. آماره آزمون این روش برابر با  $-5/646$  است که موید این مسئله است که در سطح معنی‌داری  $0/05$ ، ریشه‌ی واحد وجود دارد و مشاهدات نامانا هستند و نیازمند یک مرحله تفاضلی شدن هستند.

در ادامه به منظور تشخیص مدل و پارامترهای مناسب آن به رسم نمودارهای تجزیه‌شده مشاهدات و نمودارهای خودهمبستگی و خودهمبستگی جزئی مشاهدات می‌پردازیم. در نمودارهای تجزیه‌شده مشاهدات، وجود روند و تغییرات فصلی به وضوح مشاهده می‌شود که این خود موید استفاده از روش SARMA است.

همچنین در نمودار تجزیه‌شده مشاهدات، وجود روند و تغییرات فصلی به وضوح مشاهده می‌شود و با این تفاسیر برازش مدل با یک مرتبه تفاضلی کردن مشاهدات یعنی SARIMA اجتناب‌ناپذیر است. به‌علاوه در نمودارهای خودهمبستگی و خودهمبستگی جزئی مشاهدات اصلی، روند نزولی بسیار کند است که کمکی به تشخیص پارامترهای مدل نمی‌کند، بنابراین این نمودارها را برای مشاهدات تفاضلی رسم می‌کنیم. مقادیر نمودارهای خودهمبستگی و خودهمبستگی جزئی برای مشاهدات تفاضلی شده بعد از تاخیر اول بسیار ناچیز شده‌اند که این وضعیت عدد یک را برای پارامترهای اتورگرسیون و میانگین متحرک مناسب نشان می‌دهند. البته این تشخیص تقریبی بوده و به‌منظور دقت بیش‌تر نتایج، نتایج چندین مدل SARIMA را مورد مقایسه قرار داده و مدلی که کم‌ترین خطا را دارد انتخاب می‌کنیم.



شکل ۸. نمودار تجزیه شده مشاهدات به ۳ حالت روند، فصلی و تصافی  
منبع: محاسبات تحقیق



شکل ۹. نمودارهای خودهمبستگی و خودهمبستگی جزئی برای داده‌های اصلی و داده‌های تفاضلی شده  
منبع: محاسبات تحقیق

با توجه به بررسی‌های فوق، برای مدل SARIMA، ۴ مدل با پارامترهای ارائه‌شده در جدول ذیل تشخیص داده شده‌اند که به مقایسه این مدل‌ها می‌پردازیم. برای مقایسه آن‌ها از دو شاخص RMSE و MAPE استفاده شده است که با توجه به آن‌ها، مدل  $SARIMA(1,1,1)(0,0,0)_{12}$  کمترین مقادیر را در این شاخص‌ها داشته و به عنوان مدل بهینه انتخاب می‌شود.

جدول ۵. معیارهای مقایسه ۴ مدل مختلف میانگین متحرک اتورگرسیو فصلی  
منبع: محاسبات تحقیق

MAPE	RMSE	مدل / شاخص
۴/۳۰۶۷۹۱	۳/۶۴۴۶۲۸	$SARIMA(1,1,0)(0,0,0)_{12}$
۴/۲۶۰۸۶۳	۳/۵۱۹۵۳۲	$SARIMA(1,1,1)(0,0,0)_{12}$
۴/۳۳۹۲۷	۳/۶۲۳۹۰۹	$SARIMA(0,1,1)(0,0,0)_{12}$
۱۱/۳۴۳۰۷	۸/۵۶۷۲۶۱	$SARIMA(0,0,0)(0,0,0)_{12}$

#### ۳.۴ مقایسه سه رویکرد

با توجه به بررسی‌های فوق، از دو رویکرد LSTM و RSOM برای  $k=12$  به مدل‌های بهینه با کمترین خطا دست یافتیم و در رویکرد SARIMA مدل  $SARIMA(1,1,1)(0,0,0)_{12}$  با کمترین خطا دست یافتیم و در رویکرد LSTM و RSOM مدل  $SARIMA(1,1,1)(0,0,0)_{12}$  با کمترین خطا دست یافتیم. حال در جدول (۶) به مقایسه این سه مدل پرداخته و مدل مناسب را با توجه به شاخص‌های RMSE و MAPE انتخاب می‌کنیم. از آن‌جا که کم‌ترین مقدار برای این دو شاخص، مربوط به الگوریتم LSTM است، این روش به‌عنوان روش منتخب از بین سه روش این پژوهش انتخاب می‌شود. به‌طور کلی نتیجه می‌گیریم که به ترتیب روش‌های LSTM، SARIMA و RSOM دقت مناسب‌تری در پیش‌بینی مشاهدات پژوهش حاضر دارند.

جدول ۶. معیارهای مقایسه سه مدل بهینه از سه رویکرد مختلف  
منبع: محاسبات تحقیق

SARIMA	RSOM	LSTM	شاخص / روش
۳/۵۱۹۵۳۲	۵/۱۷۷۱۸۱	۳/۴۶۱۷۳۶	RMSE
۴/۲۶۰۸۶۳	۵/۳۹۹۸۸۵	۳/۵۵۱۱	MAPE

## ۵. نتیجه گیری

با گذر زمان نقش انرژی در تمامی اقتصادها پررنگ‌تر شده است. توسعه جوامع، رشد جمعیت و ارتقاء سطح رفاه یکی از اصلی‌ترین دلایل افزایش مصرف انرژی می‌باشد. بخش حمل و نقل در ایران یکی از بزرگترین مصرف‌کننده‌های انرژی است که به دلیل ضعف جدی در بخش عمومی، متکی بر مصرف بنزین می‌باشد. هر ساله به دلیل افزایش استفاده از وسایل نقلیه شخصی، افزایش تولید خودروهای جدید و خارج نشدن اتومبیل‌های قدیمی از ناوگان حمل و نقل، کم مصرف نبودن موتورهای اتومبیل‌های تولیدشده، فرسودگی و عدم توسعه لازم سیستم حمل و نقل عمومی و افزایش میزان مسافرت‌ها... تقاضای بنزین در حال افزایش است و از طرف دیگر به دلیل عدم وجود توان تولیدی لازم پالایشگاه‌های کشور شکاف بین تولید و مصرف زیاد شده و از طریق واردات از بین می‌رود. به همین دلیل در سال‌های اخیر بسیاری از مسئولان و محققان درصدد پیش‌بینی روند مصرف بنزین برآیند. روش‌های یادگیری ماشین در سال‌های اخیر به عنوان روش‌هایی نسبتاً جدید برای پیش‌بینی متغیرهای اقتصادی به کار می‌روند. روش یادگیری عمیق نیز به عنوان یکی از مدرن‌ترین روش‌های زیر مجموعه یادگیری ماشین در سال‌های اخیر مورد توجه قرار گرفته است. این روش‌ها علاوه بر دارا بودن تمام مزیت‌های شبکه‌های عصبی مصنوعی، با کمک ساختار بازگشتی و حافظه‌هایی برای ذخیره رویدادهای محلی و عمومی و استفاده ترکیبی از آنها، به طور موثری برای پیش‌بینی متغیرهای اقتصادی به کار گرفته می‌شوند. در این تحقیق با هدف پیش‌بینی مصرف بنزین به صورت ماهانه، از سه روش یادگیری نقشه‌های خودسازمانده بازگشتی، یادگیری عمیق با حافظه کوتاه‌مدت و روش سنتی میانگین متحرک خودرگرسیو فصلی استفاده شده است. مقایسه نتایج این سه روش حاکی از این است که با توجه به دو معیار MAPE و RMSE روش یادگیری عمیق با حافظه طولانی کوتاه مدت، LSTM، بهتر از دو روش رقیب در این

پژوهش عمل کرده و روش میانگین متحرک خودرگرسیو فصلی نیز بهتر از روش یادگیری نقشه‌های خودسازمانده بازگشتی (RSOM) عمل کرده است. پیش‌بینی‌ها برطبق بهترین روش در این پژوهش یعنی LSTM حاکی از رشد تقریبی ۱۵ درصدی در کل بازه پیش‌بینی است که الگوی نوسانات فصلی نیز دارد. این نرخ رشد مصرف بنزین نشان از این دارد که به طور متوسط سالانه ۱/۵ درصد در سال مصرف بنزین رشد خواهد کرد که بالاتر از میزان پیش‌بینی شده مصرف انرژی در جهان توسط آژانس بین‌المللی انرژی است. در صورت تحقق این مقدار از مصرف کشور نیازمند افزایش پتانسیل تولید داخل و بهینه‌سازی مصرف سوخت اتومبیل‌ها در راستای کاهش میزان واردات بنزین و اقداماتی جدی در راستای ارتقاء سیستم حمل و نقل عمومی و سیاست‌های قیمت‌گذاری مناسب که منجر به تصحیح الگوی مصرف گردند، می‌باشد.

## کتاب‌نامه

- ندا بیات (۱۳۹۷). پیش‌بینی نرخ ارز با استفاده از نقشه‌های خود سازمان ده بازگشتی. فصلنامه علمی پژوهشی اقتصاد و تجارت نوین، شماره ۴، ۵۵-۸۴.
- مهرگان، نادر، قربانی، وحید (۱۳۸۸)، "تقاضای کوتاه مدت و بلند مدت بنزین در بخش حمل‌ونقل" پژوهشنامه حمل و نقل، سال ششم، شماره ۴، صص ۳۷۹-۳۶۷.
- موسوی جهرمی، یگانه و غلامی الهام (۱۳۹۵)، "مدل ترکیبی شبکه عصبی با الگوی ARIMA جهت پیش‌بینی مالیات بر ارزش افزوده بر مصرف بنزین در ایران" فصلنامه پژوهش‌های اقتصادی (رشد و توسعه پایدار)، شماره دوم، صص ۹۹-۱۱۶.
- معاونت امور برق و انرژی، دفتر برنامه‌ریزی و اقتصاد کلان برق و انرژی، ترازنامه انرژی ایران سال‌های ۱۳۸۱-۱۳۹۶.

- Abrishami, H., Mehrara, M., Ahrari, M., & Varahrami, V. (2010). A Hybrid Intelligent System for Forecasting Gasoline Price. *Iranian Economic Review*, 15(27), 13-31.
- Aklilu, A. Z. (2020). Gasoline and diesel demand in the EU: Implications for the 2030 emission goal. *Renewable and Sustainable Energy Reviews*, 118, 109530
- Assari, M. R., Ghanbarzadeh, A., Behrang, M. A., & Assareh, E. (2009, June). Estimating gasoline demand in Iran using different soft computing techniques. In *2009 7th IEEE International Conference on Industrial Informatics* (pp. 106-112). IEEE.

- Barreto, G. A. (2007). Time series prediction with the self-organizing map: A review. In *Perspectives of neural-symbolic integration* (pp. 135-158). Springer, Berlin, Heidelberg.
- Box, G.E.P.; Jenkins, G.M. (1970). *Time series analysis: forecasting and control*, Holden-Day, San Francisco.
- Box, G. E., & Pierce, D. A. (1970). Distribution of residual autocorrelations in autoregressive-integrated moving average time series models. *Journal of the American statistical Association*, 65(332), 1509-1526.
- Bayat, N., & Salem, A. A. (2018). Modeling Electricity Expenditures using BSOM based on Techno-Socio Economic: A Case Study of Urban Households of Iran's Provinces. *Iranian Economic Review*.
- Boné, R., & Crucianu, M. (2002). Multi-step-ahead prediction with neural networks: a review. *9emes rencontres internationales: Approches Connexionnistes en Sciences*, 2, 97-106.
- Broadhead, J., & Killmann, W. (2008). *Forests and Energy: Key Issues* (No. 154). Food & Agriculture Org.
- Dahl, C. A. (2012). Measuring global gasoline and diesel price and income elasticities. *Energy Policy*, 41, 2-13.
- Fani, M., & Norouzib, N. (2019). Using Social and Economic Indicators for Modeling, Sensitivity Analysis and Forecasting the Gasoline Demand in the Transportation Sector. *Iranian Journal of Energy-A*, 4.
- Fu, R., Zhang, Z., & Li, L. (2016, November). Using LSTM and GRU neural network methods for traffic flow prediction. In *2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC)* (pp. 324-328). IEEE.
- Graves, A. (2013). Generating sequences with recurrent neural networks. *arXiv preprint arXiv:1308.0850*.
- Kazemi, A., Ganjavi, H. S., Menhaj, M., Mehregan, M., Taghizadeh, M., & Asl, A. F. (2009, December). A multi-level artificial neural network for gasoline demand forecasting of Iran. In *2009 Second International Conference on Computer and Electrical Engineering* (Vol. 1, pp. 61-64). IEEE.
- Kazemi, A., Shakouri, H. G., Menhaj, M. B., Mehregan, M. R., & Neshat, N. (2010). A hierarchical artificial neural network for transport energy demand forecast: Iran case study. *Neural Network World*, 20(6), 761.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Khan, S., & Yairi, T. (2018). A review on the application of deep learning in system health management. *Mechanical Systems and Signal Processing*, 107, 241-265.
- Kim, T. Y., & Cho, S. B. (2019). Predicting residential energy consumption using CNN-LSTM neural networks. *Energy*, 182, 72-81.

- Kong, W., Dong, Z. Y., Jia, Y., Hill, D. J., Xu, Y., & Zhang, Y. (2017). Short-term residential load forecasting based on LSTM recurrent neural network. *IEEE Transactions on Smart Grid*, 10(1), 841-851.
- Lin, C. Y. C., & Prince, L. (2013). Gasoline price volatility and the elasticity of demand for gasoline. *Energy Economics*, 38, 111-117.
- Mohammadi, K., Shamshirband, S., Petković, D., & Khorasanizadeh, H. (2016). Determining the most important variables for diffuse solar radiation prediction using adaptive neuro-fuzzy methodology; case study: City of Kerman, Iran. *Renewable and Sustainable Energy Reviews*, 53, 1570-1579.
- Sapnken, E. F. (2018). Modeling and forecasting gasoline consumption in Cameroon using linear regression models.
- Sapankevych, N. I., & Sankar, R. (2009). Time series prediction using support vector machines: a survey. *IEEE Computational Intelligence Magazine*, 4(2), 24-38.
- Suganthi, L., & Samuel, A. A. (2012). Energy models for demand forecasting—A review. *Renewable and sustainable energy reviews*, 16(2), 1223-1240.
- Tamba, J. G., Nsouandélé, J. L., & Lélé, A. F. (2017). Gasoline consumption and economic growth: Evidence from Cameroon. *Energy Sources, Part B: Economics, Planning, and Policy*, 12(8), 685-691.
- Xu, F., Sepehri, M., Hua, J., Ivanov, S., & Anyu, J. N. (2018). Time-Series Forecasting Models for Gasoline Prices in China. *International Journal of Economics and Finance*, 10(12), 1-43.

<https://www.iea.org/data>

<https://www.iea.org/reports/world-energy-statistics-2019>