The University of Tehran Press

Journal of Sustainable Energy Systems

Online ISSN: 2980-8693

Home Page: https://ses.ut.ac.ir

Energy consumption Forecast modeling using artificial intelligence method (A case study in Hamadan province)

Younes Noorollahi[1*] | Amin Sharbati[2] | Ahmad Hajinezhad[3]

1. Corresponding Author, Professor, Department of Sustainable Energy Systems Engineering, Faculty of Energy Engineering and Sustainable Resources, University of Tehran, Tehran, Iran. Email: noorollahi@ut.ac.ir
2. Phd. Student, School of Energy Engineering and Sustainable Resources, College of Interdisciplinary Science and Technologies, University of Tehran, Tehran, Iran. Email: sharbati.amin@ut.ac.ir
3. Associate Professor, Department of Sustainable Energy Systems Engineering, University of Tehran, Tehran, Iran. Email: Hajinezhad@ut.ac.ir

ARTICLE INFO

Article type:
Research Paper

Article History:
Received 23 May 2024
Revised 24 June 2024
Accepted 27 Augusr 2024
Published Online 04 October 2024

Keywords:
Forecasting of energy consumption pattern,
Hamadan province,
Multilayer perceptron model,
Artificial neural networks,
Fuzzy logic.

ABSTRACT

In this research, artificial intelligence has been used to predict energy consumption in cold regions (case study of Hamadan province). In this regard, artificial neural network models and fuzzy logic are used to predict the current trend of energy consumption. To achieve this goal, the multilayer perceptron model has been used by testing several possible architectures as well as fuzzy logic in order to select the best generalization capability. Real recorded input and output data affecting long-term energy consumption have been used in the training, validation and testing process. In this article, the developed model of neural networks is used to predict the energy consumption of Hamedan province during the years 1400 to 1409. The data is extracted annually from the energy balance sheet of the Ministry of Energy from 1380 to 1399. The output results are also compared with the fuzzy logic method. Also, the simulation results show us that the electricity demand will reach about 3318 gigawatt hours by 1409. The proposed approach can be useful in the effective implementation of energy policies, as accurate energy consumption forecasting affects investment, revenue analysis, and market research management while maintaining security of supply.

Cite this article: Noorollahi, Y.; Sharbati, A. & Hajinezhad, A. (2024). Energy consumption Forecast modeling using artificial intelligence method (A case study in Hamadan province). *Journal of Sustainable Energy Systems*, 3 (4), 341-360. DOI: http//doi.org/10.22059/ses.2024.383569.1104

© Younes Noorollahi, Amin Sharbati, Ahmad Hajinezhad
DOI: http//doi.org/10.22059/ses.2024.383569.1104

Publisher: University of Tehran Press.

Introduction

Control and identification of large national and regional systems is one of the important issues that requires the government to find solutions to achieve it. To achieve this goal, data must be extracted carefully. In other words, identifying and knowing the amount of energy consumption in the country is one of the main challenges for governments, and knowing its exact amount in future periods and periods can lead to control and useful use of benefits. Forecasting energy consumption depends on the amount of demand, weather and climate factors, economic and other activities that can significantly affect the amount of demand in the short term. If the forecasts are done accurately, as a result, it will save in the field of operational and executive costs, development of facilities, transfer and maintenance, and finally taking appropriate decisions according to the current conditions of the country [1].

Energy consumption has increased dramatically over the past decades worldwide due to population growth and economic development. Energy is considered as an important factor in the economic and social development of a country and as a result the wealth of the people. Long-term consumption forecasts are important and necessary in capacity development studies, energy supply strategy, investment, income analysis and market research management. However, a large number of uncertainties that are characteristic of long-term forecasts sometimes cover the next thirty years [2].

Materials and methods

In this part of the studied area, its potentials and energy consumption are investigated. Then the algorithms and data used in neural networks, which is one of the most popular models, and fuzzy logic to predict energy consumption will be discussed and discussed.

Conclusion and Recommendations

In this article, two scenarios are considered to predict energy consumption in MATLAB software. It describes the method of artificial neural network and fuzzy logic to predict ten future periods of energy consumption in Hamadan province. Based on the data related to the past and the prediction of these values for the studied ten-year period, we have entered the data in the input of the software and made the prediction for the ten-year horizon. Real recorded input and output data that undoubtedly affect energy consumption have been used in the training, validation and testing process. Predictions have been made for the years 1400 to 1409, and the obtained results are close to the real results. According to the historical data which is yearly, therefore the forecast will be yearly for the next ten periods. Further, after receiving the input data to the software and allocating 70% of the data for training, 30% of the data was also used for the testing process. From several transfer functions investigated, the only one that gives us better results is the tansig function because it gives us a better MSE. Transfer functions are functions in the end layers of each neuron that are responsible for mapping the output information of the neuron on acceptable values to display the output. Here, the tansigmoid activator or transfer function is used, which limits the infinite values of the input in a limited way in the range of negative one to positive one, and finally it is trained with Lunberg-Margaret algorithm. The simulation results show us that the electricity demand will increase until 1409 and will reach about 3318 gigawatt hours. In some other energy carriers, according to the government's policies regarding the maximum use of renewable energy, the import of electric cars, the replacement of worn-out cars, and the ongoing measures regarding the optimization of energy consumption, we will have an increasing trend with a gentle slope. In the field of natural gas, neural networks give us a better prediction according to the value of R^2. On the other hand, in gasoline consumption, both fuzzy methods and neural networks have provided us with good accuracy to predict the future. The proposed approach can be useful in the effective implementation of energy policies; Because in the past, no serious action has been taken to predict energy consumption with artificial intelligence, therefore accurate energy consumption forecasting affects investment, quality of life, income generation analysis, market research management and at the same time maintains security of supply. The evolution of the generated artificial neural network model can make it an important tool in the studies of facilities and regulations in Iran, which provides an accurate forecast for Iran's long-term energy consumption. Planning and policy making in the field of energy has a high importance and status. In this regard, forecasting the current trend of energy consumption for the coming years can contribute significantly to the analysis of supply and demand forecasts.

انتشارات دانشگاه تهران

فصلنامهٔ سیستم‌های انرژی پایدار

سایت نشریه: https://ses.ut.ac.ir

شاپا الکترونیکی: ۸۶۹۳-۲۹۸۰

مدل‌سازی پیش‌بینی مصرف انرژی با استفاده از روش هوش مصنوعی (مطالعهٔ موردی در استان همدان)

یونس نورالهی[۱*] | امین شربتی[۲] | احمد حاجی‌نژاد[۳]

۱. نویسندهٔ مسئول، استاد، دانشکدهٔ مهندسی انرژی و منابع پایدار، دانشکدگان علوم و فناوری‌های میان‌رشته‌ای، دانشگاه تهران، تهران، ایران. رایانامه: noorollahi@ut.ac.ir

۲. دانشجوی دکتری دانشکدهٔ مهندسی انرژی و منابع پایدار، دانشکدگان علوم و فناوری‌های میان‌رشته‌ای، دانشگاه تهران، تهران، ایران. رایانامه: Sharbati.amin@ut.ac.ir

۳. دانشیار دانشکدهٔ مهندسی انرژی و منابع پایدار، دانشکدگان علوم و فناوری‌های میان‌رشته‌ای، دانشگاه تهران، تهران، ایران. رایانامه: hajinezhad@ut.ac.ir

اطلاعات مقاله

نوع مقاله:
پژوهشی

تاریخ‌های مقاله:
تاریخ دریافت: ۱۴۰۳/۰۳/۰۳
تاریخ بازنگری: ۱۴۰۳/۰۴/۰۴
تاریخ پذیرش: ۱۴۰۳/۰۶/۰۶
تاریخ انتشار: ۱۴۰۳/۰۸/۱۴

کلیدواژه:
پیش‌بینی الگوی مصرف انرژی،
استان همدان،
مدل پرسپترون چندلایه،
شبکه‌های عصبی مصنوعی،
منطق فازی.

چکیده

در این پژوهش از هوش مصنوعی برای پیش‌بینی مصرف انرژی در مناطق سردسیر (مطالعهٔ موردی استان همدان) استفاده شده است. در این راستا از مدل‌های شبکه‌های عصبی مصنوعی و منطق فازی به منظور پیش‌بینی روند جاری مصرف انرژی استفاده می‌شود. برای دستیابی به این هدف، از مدل پرسپترون چندلایه با آزمایش چندین معماری ممکن و همچنین، منطق فازی استفاده شده است تا بتوان بهترین قابلیت تعمیم را انتخاب کرد. داده‌های ورودی و خروجی ثبت‌شدهٔ واقعی که بر مصرف طولانی‌مدت انرژی تأثیر می‌گذارند، در فرایند آموزش، اعتبارسنجی و تست استفاده شده‌اند. مدل توسعه‌یافتهٔ شبکه‌های عصبی برای پیش‌بینی مصرف انرژی استان همدان طی سال‌های ۱۴۰۰ تا ۱۴۰۹ استفاده می‌شود. داده‌ها به صورت سالانه از ترازنامهٔ انرژی وزارت نیرو و از سال ۱۳۸۰ تا ۱۳۹۹ استخراج شده است. نتایج خروجی با روش منطق فازی نیز مقایسه می‌شود. همچنین، نتایج شبیه‌سازی به ما نشان می‌دهد تقاضای برق تا سال ۱۴۰۹ به حدود ۳۳۱۸ گیگاوات ساعت خواهد رسید. رویکرد پیشنهادی می‌تواند در اجرای مؤثر سیاست‌های انرژی مفید باشد، زیرا پیش‌بینی دقیق مصرف انرژی بر سرمایه‌گذاری، تحلیل درآمد، و مدیریت تحقیقات بازار تأثیر می‌گذارد و در عین حال امنیت عرضه را حفظ می‌کند.

استناد: نورالهی، یونس؛ شربتی،امین و حاجی‌نژاد، احمد (۱۴۰۳). مدل‌سازی پیش‌بینی مصرف انرژی با استفاده از روش هوش مصنوعی (مطالعهٔ موردی در استان همدان). *فصلنامهٔ سیستم‌های انرژی پایدار*، ۳ (۴) ۳۴۱-۳۶۰. DOI: http//doi.org/10.22059/ses.2024.383569.1104

© یونس نورالهی، امین شربتی، احمد حاجی‌نژاد **ناشر:** مؤسسه انتشارات دانشگاه تهران.
DOI: http//doi.org/10.22059/ses.2024.383569.1104

۱. مقدمه

کنترل و شناسایی سیستم‌های بزرگ ملی و منطقه‌ای یکی از موضوعات مهمی است که حاکمیت را ملزم به پیدا کردن راه‌حل‌هایی برای دستیابی به آن می‌کند. برای رسیدن به این هدف، داده‌ها باید بادقت استخراج شوند. به بیان دیگر، شناسایی و اطلاع از میزان مصرف انرژی در کشور یکی از چالش‌های اصلی برای دولت‌ها است و اطلاع از میزان دقیق آن در بازه‌ها و دوره‌های آینده می‌تواند موجب کنترل و به‌کارگیری مفید از منافع شود. پیش‌بینی مصرف انرژی به میزان تقاضا، عوامل آب‌وهوایی و اقلیمی، اقتصادی و دیگر فعالیت‌ها بستگی دارد که می‌تواند تأثیر به‌سزایی بر مقدار تقاضا در کوتاه‌مدت بگذارند. اگر پیش‌بینی‌ها با دقت انجام شود، صرفه‌جویی‌هایی در زمینهٔ هزینه‌های عملیاتی و اجرایی، توسعهٔ تأسیسات، انتقال و نگهداری و در نهایت اخذ تصمیمات مناسب با توجه به شرایط فعلی کشور خواهد داشت [۱].

مصرف انرژی طی دهه‌های گذشته در سراسر جهان به دلیل افزایش جمعیت و توسعهٔ اقتصادی به طرز چشم‌گیری افزایش یافته است. انرژی به عنوان یک عامل مهم در توسعهٔ اقتصادی و اجتماعی یک کشور و در نتیجه، ثروت مردم محسوب می‌شود. پیش‌بینی‌های بلندمدت مصرف امری مهم بوده و در مطالعات توسعهٔ ظرفیت‌ها، استراتژی تأمین انرژی، سرمایه‌گذاری، تجزیه‌وتحلیل درآمد و مدیریت تحقیقات بازار ضروری است. با این‌حال، تعداد زیادی از عدم قطعیت‌ها که مشخصهٔ پیش‌بینی‌های بلندمدت هستند، گاهی تا ۳۰ سال آینده را نیز پوشش می‌دهند [۲].

بر اساس افق زمانی، پیش‌بینی مصرف انرژی را می‌توان در سه گروه عمده پیش‌بینی کوتاه‌مدت، میان‌مدت و بلندمدت دسته‌بندی کرد. در پیش‌بینی کوتاه‌مدت استفاده از عوامل فصلی، آب‌وهوا و داده‌های تاریخی میزان مصرف انرژی را از یک ساعت تا یک هفتهٔ آینده استفاده می‌کنند. از پیش‌بینی‌های میان‌مدت برای برنامه‌ریزی برای تعمیرات و نگهداری تا یکسان استفاده می‌شود و از پیش‌بینی‌های بلندمدت برای احداث نیروگاه‌ها و خطوط انتقال و توسعهٔ تأسیسات برای مصرف انرژی استفاده می‌کنند [۳].

قبل از ظهور فناوری هوش مصنوعی، پیش‌بینی مصرف انرژی عمدتاً از مدل‌های مرسوم، از جمله مدل‌های سری زمانی، مدل‌های رگرسیون و مدل‌های خاکستری استفاده می‌کنند. تحقیقات اخیر ثابت کرده است که اگر پارامترها و عوامل وزن را بتوان به‌درستی انتخاب کرد، مدل‌های معمولی می‌توانند دقت پیش‌بینی قابل مقایسه با مدل‌های هوش مصنوعی در پیش‌بینی مصرف انرژی ایجاد کنند [۴].

مدل‌های مرسوم به داده‌های تاریخی زیادی نیاز ندارند و می‌توانند رابطهٔ صریح بین مصرف انرژی و عوامل مؤثر بر آن، مانند تأخیر، دما، تولید ناخالص داخلی[1] و جمعیت ایجاد کنند. به‌خلاف مدل‌های مرسوم، مدل‌های پیش‌بینی مبتنی بر هوش مصنوعی بر رابطهٔ صریح بین مصرف انرژی و عوامل تأثیرگذار آن تکیه نمی‌کنند، بلکه از مقدار زیادی داده‌های تاریخی برای پیش‌بینی یاد می‌گیرند. این مدل‌ها مانند شبکه‌های عصبی مصنوعی[2] و رگرسیون بردار پشتیبان[3]، توانایی قوی در برخورد با مسائل غیرخطی دارند و بنابراین به طور گسترده در پیش‌بینی مصرف انرژی، به‌ویژه در پیش‌بینی کوتاه‌مدت استفاده می‌شوند [۷]. مدیریت تقاضای انرژی در حال تبدیل شدن به یک موضوع مهم است؛ زیرا دنیای آینده به تصمیم امروز وابسته است. مدیریت بهینهٔ منابع انرژی در بین برنامه‌ریزان و سیاست‌گذاران انرژی امری ضروری شده است. طی زمان‌های اخیر، با تغییرات شدید شرایط آب‌وهوایی، توجه به استفاده از منابع انرژی تجدیدپذیر معطوف شده است. منابع انرژی تجدیدپذیر پایدار، دوستدار طبیعت، غیرآلاینده و تجدیدپذیر هستند. یک رویکرد مدیریت یکپارچهٔ انرژی برای توسعهٔ پایدار هر کشور ضروری است [۵].

مصرف انرژی یکی از حوزه‌های مهم تحقیقاتی در جهان است. نیاز روزافزون به افزایش بهره‌وری انرژی و بهبود استفاده از منابع انرژی، نیاز به مدیریت بهتر انرژی و مدل‌های پیش‌بینی را به همراه دارد؛ بنابراین، پیش‌بینی مصرف انرژی برای تخمین مصرف انرژی بسیار مهم شده است، زیرا مزایای زیست‌محیطی و به‌ویژه اقتصادی را به همراه دارد. پیش‌بینی، بخشی

1. Gross Domestic Product
2. Artificial Neural Networks
3. Support Vector Regression

جدایی‌ناپذیر از فرایندهای تصمیم‌گیری تجاری است. نیازهای روبه‌رشد برای بهره‌وری بیشتر انرژی و استفادهٔ بهتر از منابع انرژی، نیاز به مدیریت انرژی و مدل‌های پیش‌بینی بهتر را نشان می‌دهد [۶].

شبکه‌های عصبی مصنوعی یک راه جایگزین برای مقابله با مشکلات پیچیده و نامشخص ارائه می‌دهند. آن‌ها می‌توانند از مثال‌ها بیاموزند؛ به این معنا که قادر به مدیریت داده‌های ناقص هستند، می‌توانند با مسائل غیرخطی کنار بیایند و پس از آموزش می‌توانند پیش‌بینی‌ها و تعمیم‌ها را با سرعت بالا انجام دهند. آن‌ها در کاربردهای متنوعی در کنترل، رباتیک، تشخیص الگو، پیش‌بینی، پزشکی، سیستم‌های قدرت، تولید، بهینه‌سازی، پردازش سیگنال و علوم اجتماعی/روانی استفاده شده‌اند. آن‌ها به‌ویژه در مدل‌سازی سیستم، مانند اجرای نقشه‌های پیچیده و شناسایی سیستم مفید هستند. در تمامی این مدل‌ها، از معماری چندلایهٔ پنهان استفاده شده است. خطاهای گزارش‌شده هنگام استفاده از این مدل‌ها به‌خوبی در محدوده‌های قابل قبول هستند که به‌وضوح نشان می‌دهد شبکه‌های عصبی مصنوعی می‌توانند برای مدل‌سازی در زمینه‌های دیگر تولید و استفاده شوند. اقدامات سایر محققان در زمینهٔ انرژی نیز گزارش شده که شامل استفاده از شبکه‌های عصبی مصنوعی در سیستم‌های گرمایش، تهویهٔ مطبوع، خورشیدی، مدل‌سازی و کنترل سیستم‌های تولید برق، پیش‌بینی بار و تبرید است [۸].

سیاست‌های فعلی اتحادیهٔ اروپا از طریق ۱۰ شاخص کلیدی که به عنوان ورودی به مدل شبکهٔ عصبی مصنوعی به منظور پیش‌بینی انتشار CO_2 تا سال ۲۰۵۰ ارائه می‌شوند، توصیف می‌شوند. علاوه بر این، مدیریت انتشار CO_2 با تغییر مقادیر شاخص‌ها (یعنی تغییر سیاست‌ها) امکان‌پذیر است. این امکان ارزیابی و برنامه‌ریزی کاهش انتشار CO_2 را به کارآمدترین روش از طریق اصلاح سیاست‌های انرژی و اقتصاد و استراتژی‌های انرژی و اقتصاد فراهم می‌کند. هوش مصنوعی با تأکید بر شبکهٔ عصبی مصنوعی به دلیل ساختار و جهانی بودن آن در کاربردهای مختلف دنیای واقعی بسیار محبوب شده است. مطالعات متعدد نتایج خوبی نشان داده‌اند و این روش به روشی تبدیل شده است که اغلب در پیش‌بینی‌ها استفاده می‌شود. داشتن اطلاعات و ارزیابی خط مشی فعلی به منظور بهبود آن از اهمیت حیاتی برخوردار است. مطالعات تا کنون شاخص‌های خاصی را مشخص کرده‌اند که به طور قابل توجهی بر بخش انرژی مانند جمعیت، تولید ناخالص داخلی، ساختار اقتصاد و میانگین دمای جهانی هوا تأثیر می‌گذارد [۹].

برانکو ورشویچ و همکاران مدلی از سیستم انرژی اتحادیهٔ اروپا را با استفاده از شبکه‌های عصبی مصنوعی تحلیل می‌کنند. این مدل بر اساس پیش‌بینی انتشار CO_2 تا سال ۲۰۵۰ با در نظر گرفتن سیاست انرژی فعلی اتحادیهٔ اروپا است. نتایج نشان می‌دهد شبکه‌های عصبی مصنوعی این سیستم را به‌خوبی مدل‌سازی می‌کنند و این مدل توانایی پیش‌بینی رفتار انتشار CO_2 را دارد. این برنامه‌ها در سند نقشهٔ راه انرژی ۲۰۵۰ کمیسیون اروپا مشخص شده است. چندین ساختار از شبکه‌های عصبی مصنوعی به منظور انتخاب بهترین برای مدل‌سازی سیستم‌های انرژی مورد تجزیه‌وتحلیل قرار گرفت و مشخص شد که مدل با ساختار Cascade Forward Back Propagation با شاخص‌های خاص متعدد می‌تواند چنین سیستم‌های انرژی را مدل‌سازی کند و انتشار CO_2 را با دقت قابل قبولی پیش‌بینی کند [۱۰].

فناوری فتوولتائیک خورشیدی در حال تبدیل شدن به یکی از فناوری‌های امیدوارکنندهٔ انرژی‌های تجدیدپذیر است. در کار حاضر، یک مدل مبتنی بر منطق فازی تعمیم‌یافته برای پیش‌بینی کوتاه‌مدت انرژی خورشیدی با استفاده از داده‌های اندازه‌گیری تابش خورشیدی توسعه داده شده است. داده‌های ساعتی تابش خورشیدی (بر حسب وات بر مترمربع) برای ماه اکتبر ۲۰۱۴ اندازه‌گیری شده و به عنوان ورودی و خروجی اندازه‌گیری‌شده واقعی استفاده شده است. برای جلوگیری از مشکلات همگرایی، داده‌های ورودی و خروجی در محدودهٔ ۰/۱ تا ۰/۹ نرمال شده است. نتایج به‌دست‌آمده با داده‌های اندازه‌گیری‌شده مقایسه و دقیق هستند. عملکرد مدل بر اساس میانگین درصد خطای مطلق که ۱/۰۵۲ درصد است و در محدوده‌های مطلوب قرار دارد [۱۱].

شبکه‌های عصبی مصنوعی که گاهی اوقات مدل‌هایی برای یادگیری عمیق نیز نامیده می‌شوند، به طور گسترده برای پیش‌بینی طیف وسیعی از متغیرها استفاده می‌شوند. در حالی که این روشی مناسب برای کنار گذاشتن اصول اعمال‌شده در توسعهٔ انواع دیگر مدل‌ها است. برای پرداختن به این مسائل، این مقاله مقدماتی بر تعدادی از نظریه‌های رایج در مورد استفاده از شبکه‌های عصبی مصنوعی را بررسی می‌کند و روش‌های پیشرفته‌ای برای توسعهٔ شبکه‌های عصبی مصنوعی را تشریح می‌کند [۱۲].

نوراللهی و همکاران به بررسی مدل‌سازی مصرف انرژی الکتریکی برای ساختمان‌های مسکونی در ایران پرداخته‌اند. آن‌ها همچنین رفتار مصرف‌کنندگان که به‌شدت بر کنترل منابع و تقاضا در شبکهٔ برق تأثیر می‌گذارد را بررسی کرده‌اند. از طرفی، درک صحیح و مدل‌سازی الگوی رفتاری سمت تقاضا گامی اساسی برای توسعهٔ شبکهٔ هوشمند و دستیابی به سیستم‌های انرژی پایدار است و از سوی دیگر، اطلاعات مصرف انرژی برای برنامه‌ریزی و مدیریت شبکه‌های توزیع و تخصیص منابع ضروری است؛ بنابراین دستیابی به مدلی برای پیش‌بینی مصرف انرژی در سطح مشترکان یک گام اساسی است و می‌توان از آن برای مطالعات مختلف استفاده کرد و روشی از پایین به بالا و با در نظر گرفتن تعداد ساکنان و نحوهٔ استفاده از تجهیزات مختلف به منظور به دست آوردن مصرف توسعه داده شده است که نتایج به‌دست‌آمده نشان می‌دهد برای مشترکان مسکونی اثربخشی مدل پیشنهادی با مقادیر واقعی اندازه‌گیری شده است [۱۳].

رودریگز و همکاران به بررسی روشی برای توصیف و پیش‌بینی تقاضای برق مصرف‌کنندگان بزرگ، به‌ویژه شهرها پرداختند. پیش‌بینی تقاضا به مصرف‌کنندگان اجازه می‌دهد تا مشارکت خود را در بازارهای برق بهبود دهند و مصرف برق خود را مدیریت کنند. این روش یک طبقه‌بندی بر اساس انواع مختلف نقاط عرضه همراه با شبکه‌های عصبی مصنوعی را در نظر می‌گیرد تا پیش‌بینی‌های ساعتی را با استفاده از پارامترهای شناخته‌شده مانند روز، دما، آخرین ساعت مصرف برق و زمان طلوع و غروب خورشید به دست آورد. این روش برای شهر والنسیا طی سال‌های ۲۰۱۷ و ۲۰۱۸ مورد استفاده قرار گرفته است. نتایج به‌دست‌آمده پیش‌بینی‌های فراوانی را با حداکثر میانگین درصد مطلق خطا ۳/۸ درصد در روز ارائه می‌کند [۲۱].

دنیل آلبا و همکاران به مروری بر برخی از روندها در شبکه‌های عصبی مصنوعی برای مدل‌سازی و شبیه‌سازی با سری‌های زمانی پرداختند. همچنین، با معرفی مختصر برخی از مفاهیم و اصطلاحات اساسی مربوط به تجزیه‌وتحلیل سری‌های زمانی و با تشریح برخی از محبوب‌ترین معماری‌های شبکهٔ عصبی مصنوعی که برای اهداف پیش‌بینی سری‌های زمانی در نظر گرفته شده‌اند، شروع می‌کند؛ از جمله شبکه‌های عصبی پیش‌خور، شبکه‌های تابع پایهٔ شعاعی، شبکه‌های عصبی بازگشتی. سپس، برخی از کاربردهای مدل‌سازی شبکهٔ عصبی مصنوعی با سری‌های زمانی اخیر را بیان کردند. هدف از پژوهش یادشده، ارائهٔ دیدگاه مناسب در مورد نحوهٔ استفاده از شبکه‌های عصبی مصنوعی برای مدل‌سازی سری‌های زمانی و وظایف پیش‌بینی است [۲۳].

برنامه‌ریزی و سیاست‌گذاری در زمینهٔ انرژی دارای اهمیت و جایگاه بالایی است. در همین راستا، پیش‌بینی روند جاری مصرف انرژی جهت دوره‌های آینده، به تجزیه‌وتحلیل پیش‌بینی عرضه و تقاضا کمک بسزایی می‌کند، به طوری که می‌تواند بر هزینه‌های مختلف انرژی تمرکز کند. تا کنون سیاست‌های مختلفی ارائه شده که هریک از آن‌ها پیش‌بینی و دیدگاه‌های متفاوتی را بررسی می‌کند. اما هیچ‌یک از این مدل‌ها بهترین مدل تلقی نمی‌شود. اما کمک شایانی به سیاست‌گذار در زمینهٔ پیش‌بینی انرژی و تحلیل پیامدهای آن می‌کند؛ لذا مدل‌های هوش مصنوعی می‌تواند بر اجرای سیاست‌ها و برنامه‌های مختلف تأمین و عرضهٔ انرژی در یک منطقه مورد استفاده گرفته و در صورت لزوم در سطح ملی نیز مورد استفاده قرار گیرد.

۲. مواد و روش‌ها

در این بخش منطقهٔ مورد مطالعه، پتانسیل‌ها و مصرف انرژی آن مورد بررسی قرار می‌گیرند. سپس، الگوریتم‌ها و داده‌های مورد استفاده در شبکه‌های عصبی که از محبوب‌ترین مدل‌ها است و همچنین، منطق فازی برای پیش‌بینی مصرف انرژی مورد بررسی و بحث قرار خواهند گرفت.

۲– ۱. منطقهٔ مورد مطالعه

استان همدان با مساحت ۲۰۱۷۳ کیلومتر مربع از مناطق سردسیر و بادخیز کشور محسوب می‌شود و وجود برخی دشت‌ها در این استان باعث وزش بادهای شدید با میانگین وزش باد ۴ متر بر ثانیه می‌شود. مصرف انرژی طی سال‌های ۱۳۸۰ تا ۱۳۹۹ استان همدان که برگرفته از ترازنامهٔ انرژی وزارت نیرو است، به صورت افزایشی بوده به طوری که مصرف بنزین از سال ۱۳۸۰ تا ۱۳۹۹ از ۲۸۳ میلیون لیتر به ۴۷۳ میلیون لیتر، مصرف گاز طبیعی از ۱۹۷۰ میلیون مترمکعب به ۳۴۵۹میلیون مترمکعب، مصرف نفت کوره از ۶۰۰ میلیون لیتر به ۱۱۴۷ میلیون لیتر و مصرف نفت گاز از ۵۴۶ میلیون لیتر به ۶۹۷ میلیون لیتر رسیده است. این

در حالی است از سال ۱۳۸۰ تا ۱۳۹۹تقاضای برق در این استان از ۱۷۰۰ گیگاوات ساعت به ۴۶۱۶گیگاوات ساعت رسیده است که این تقاضا شامل بخش خانگی، عمومی، تجاری و صنعتی، کشاورزی و در بخش روشنایی است (شکل ۱). ادامهٔ روند استفاده از سوخت‌های فسیلی برای تأمین انرژی حرارتی و الکتریکی بی‌شک این استان را با چالش‌های تأمین انرژی روبه‌رو خواهد کرد، به طوری که در حال حاضر در فصل تابستان با چالش تأمین الکتریسیته و خاموشی‌های فراوان و در فصل زمستان نیز با کمبود گاز طبیعی مواجه شده و در برخی موارد نیز به تعطیلی صنایع بزرگ و یا الزام به تأمین سوخت دوم در واحدهای صنعتی منجر شده است.

میانگین مصرف بارش طی سال در استان همدان به طور میانگین ۲۷۸ میلی‌متر بوده که برگرفته از نرم‌افزار RET Screen است که در ماه‌های ژوئن تا سپتامبر میزان بارش‌ها به‌شدت کاهش می‌یابد. همچنین، میزان دمای هوا در ماه‌های مختلف سال در استان همدان در شکل ۲ نمایش داده شده که بیشترین میزان دمای هوا در ماه آگوست است.

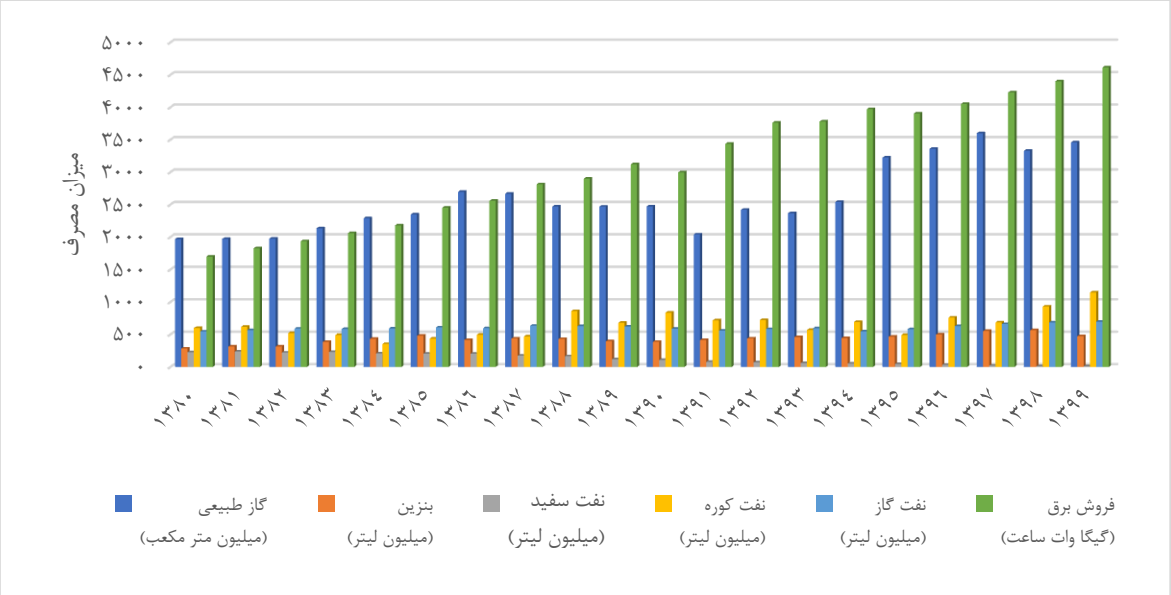

شکل ۱. نمودار مصرف حامل‌های انرژی در استان همدان

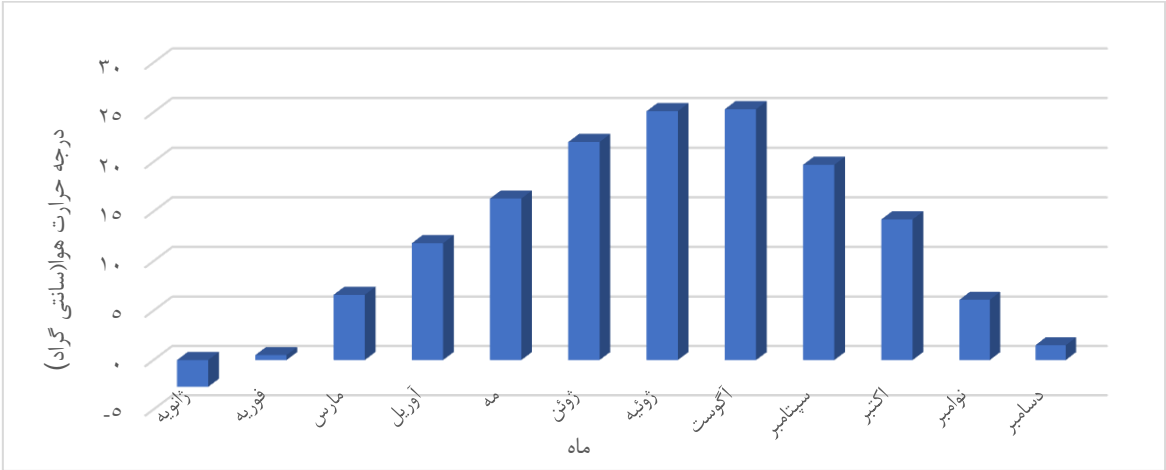

شکل ۲. نمودار میزان دمای هوای سالیانه در استان همدان

شکل ۳ نقشهٔ استان همدان را نمایش می‌دهد. این استان دارای ۹ شهرستان همدان، رزن، فامنین، ملایر، نهاوند، تویسرکان، بهار، اسدآباد و کبودرآهنگ است. شهرستان‌های استان همدان با استان‌های قزوین، زنجان، کردستان، کرمانشاه، لرستان و مرکزی هم‌جوار است.

شکل ۳. نقشهٔ استان همدان

۲-۲. پارامترهای مستقل تحقیق

در این مقاله الگوریتم‌های شبکه‌های عصبی و فازی در محیط متلب پیاده‌سازی شده‌اند. در این پیش‌بینی داده‌ها به صورت سالانه استخراج شده و به عنوان ورودی انتخاب شده‌اند. داده‌ها به صورت سالانه و از ترازنامهٔ انرژی وزارت نیرو از سال‌های ۱۳۸۰-۱۳۹۹ تهیه شده است. داده‌های بررسی‌شده شامل میزان مصرف انواع حامل‌های انرژی از جمله بنزین، نفت گاز، نفت کوره، نفت سفید، گاز طبیعی و تقاضای برق در استان همدان است. برای افزایش دقت مدل پیش‌بینی، پردازش روی تمامی داده‌ها انجام شده و با توجه به کیفیت داده‌ها و مشکلات آن‌ها، نرمال‌سازی انجام شده است. هوش مصنوعی، شامل منطق فازی[1] و شبکه‌های عصبی مصنوعی، به منظور پیش‌بینی مصرف انرژی الکتریکی در ایران مورد استفاده در استان همدان قرار گرفت. مدل‌های ANN و Fuzzy Logic برای پیش‌بینی مصرف خالص انرژی استان همدان تا سال ۱۴۰۹ توسعه یافته‌اند. از منطق فازی نیز برای پیش‌بینی بلندمدت در تولید نتایج استفاده شد.

در کار فعلی، مصرف انرژی درازمدت برای سال‌های آینده پیش‌بینی می‌شود. با بهره‌برداری از سرعت محاسباتی ANN، توانایی مدیریت توابع غیرخطی پیچیده، استحکام و کارایی زیاد حتی در مواردی که اطلاعات کامل برای مسئلهٔ مورد مطالعه وجود ندارد. برای این منظور، از مدل پرسپترون چندلایه[2] و منطق فازی استفاده شده است. از جمله دلایل انتخاب استان همدان برای این پژوهش به مواردی همچون شرایط اقلیمی، آب‌وهوایی و عدم بررسی و مدل‌سازی انرژی در این استان می‌توان اشاره کرد. بنابراین، هدف اصلی در این مقاله، پیش‌بینی مصرف انرژی در این استان است که در صورت تحقق این موضوع، می‌توان به اهداف دیگری همچون بررسی روش‌های مدل‌سازی و پیش‌بینی مصرف انرژی، بررسی عوامل مؤثر بر پیش‌بینی و در نهایت، طبقه‌بندی پیش‌بینی‌ها بر اساس افق‌های زمانی اشاره کرد. داده‌های ورودی و خروجی ثبت‌شدهٔ واقعی که برگرفته از ترازنامهٔ انرژی وزارت نیرو است و بر مصرف طولانی‌مدت انرژی تأثیر می‌گذارد در فرایند آموزش، اعتبارسنجی و تست استفاده شده است. مدل شبکه‌های عصبی توسعه‌یافته برای پیش‌بینی مصرف انرژی در سال‌های ۱۴۰۰ تا ۱۴۰۹ استفاده شده که نتایج مطلوبی را تولید می‌کند.

1. Fuzzy logic
2. Multi layer Perceptron

رویکرد پیشنهادی می‌تواند در اجرای مؤثر سیاست‌های انرژی بسیار مفید باشد و در مدیریت تحقیقات بازار نیز تأثیر می‌گذارد و در عین حال، امنیت عرضه را حفظ می‌کند. علاوه بر این، رویکرد پیشنهادی می‌تواند ابزار دقیقی برای مشکل پیش‌بینی مصرف انرژی بلندمدت در ایران باشد که تا به امروز به طور مؤثر با آن مواجه نشده است.

۳. شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی مدل‌های هوش مصنوعی مدرنی هستند که توابع غیرخطی، مرتب‌سازی داده‌ها، تشخیص الگو، بهینه‌سازی، پیش‌بینی، مدل‌سازی، شناسایی سیستم، مدیریت و شبیه‌سازی را به‌خوبی حل می‌کنند. آن‌ها بهترین نتایج را برای مسائلی می‌دهند که در آن‌ها غیرخطی بودن و قابل‌پیش‌بینی نبودن وجود دارد و هیچ تعریف روشن و ارتباط مستقیمی بین ورودی‌ها و خروجی‌ها وجود ندارد. همچنین، بر اساس یادگیری از مثال‌ها هستند نه بر اساس قوانین واضح تعریف‌شده مانند سایر روش‌ها (منطق فازی، رگرسیون خطی و غیره). شبکه‌های عصبی از داده‌های تاریخی استفاده می‌کنند و خود مدل را (طی دورهٔ آموزشی) اصلاح و تطبیق می‌دهند تا خروجی‌های دقیقی را ارائه دهند که با داده‌های واقعی مطابقت دارد. این روش برای تعریف یک سیستم، امکان تعمیم را فراهم می‌کند و نتیجه‌گیری بسیاری را در مورد سیستم مورد مطالعه امکان‌پذیر می‌کند و حساسیت به تغییرات داده‌های ورودی را کاهش می‌دهد که بزرگ‌ترین مزیت شبکه‌های عصبی نسبت به مدل‌های ریاضی است [۹].

یک شبکهٔ عصبی مصنوعی از تعدادی پردازشگر بسیار ساده و بسیار به‌هم‌پیوسته به نام نورون تشکیل شده است که مشابه نورون‌های مغزی است. نورون‌ها توسط پیوندهای وزنی به هم متصل می‌شوند که سیگنال‌ها را از یک نورون به نورون دیگر منتقل می‌کنند. هر پیوند دارای وزن عددی مرتبط با آن است. وزن‌ها ابزار اصلی حافظهٔ بلندمدت در شبکهٔ عصبی مصنوعی هستند. آن‌ها قدرت یا اهمیت هر ورودی نورون را بیان می‌کنند. یک شبکهٔ عصبی از طریق تنظیمات مکرر این وزن‌ها آموزش می‌بینند و یاد می‌گیرند.

ویژگی بارز این شبکه‌ها این است که دانش انباشته‌شده طی آموزش را در نظر می‌گیرند و به رویدادهای جدید به مناسب‌ترین حالت پاسخ می‌دهند و تجربهٔ به‌دست‌آمده طی فرایند آموزش را ارائه می‌دهند. در این کار از یک مدل شبکهٔ عصبی معمولی به نام مدل پرسپترون چندلایه استفاده شده است. MLP یک شبکهٔ عصبی پیشاور با یک لایهٔ ورودی از نورون‌ها، حداقل یک لایهٔ میانی یا پنهان و یک لایهٔ خروجی از نورون‌های محاسباتی است. لایهٔ ورودی سیگنال‌های ورودی را از دنیای خارج می‌پذیرد و این سیگنال‌ها را به همهٔ نورون‌های لایهٔ پنهان توزیع می‌کند. لایهٔ پنهان ویژگی‌ها را تشخیص می‌دهد. وزن نورون‌ها در لایه‌های پنهان، ویژگی‌های موجود در الگوهای ورودی را نشان می‌دهند و در نهایت، لایهٔ خروجی الگوی خروجی کل شبکه را ایجاد می‌کند [۱۰].

برای شبکه‌های عصبی مصنوعی پرسپترون چندلایه که پرکاربردترین شبکهٔ عصبی مصنوعی برای پیش‌بینی هستند، شکل عملکردی مدل تبدیل رابطهٔ ورودی‌ها به خروجی با نحوهٔ اتصال ورودی‌های مدل به خروجی‌های مدل از طریق گره‌های مخفی و توابع انتقال تعیین می‌شود (شکل ۴).

استفاده از معادلات برای یک پیکربندی شبکهٔ خاص (یعنی تعداد ورودی‌ها، خروجی‌ها و لایه‌ها و گره‌های پنهان) به یک رابطهٔ ریاضی خاص بین ورودی‌ها و خروجی‌های مدل منجر می‌شود که تابعی از تعدادی مجهول است. در نتیجه، روشی که در آن شکل عملکردی به دست می‌آید ممکن است با سایر رویکردهای مدل‌سازی متفاوت باشد. شبکه‌های عصبی مصنوعی اساساً مشابه سایر مدل‌های مورد استفاده برای پیش‌بینی هستند [۱۱].

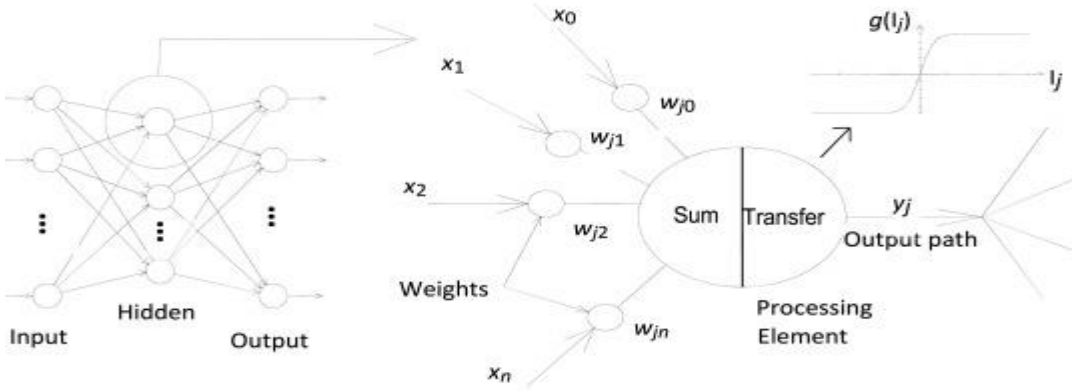

شکل ٤. ساختار معمولی (چپ) و عملکرد یک پرسپترون چندلایه [۱۱]

برای آموزش شبکه باید تعداد مناسبی از داده‌ها انتخاب شود تا شبکه بتواند ویژگی‌های اساسی مسئله را بیاموزد. بیش از صد الگوریتم یادگیری مختلف در دسترس است، اما محبوب‌ترین آن‌ها، پس‌انتشار است. در یک شبکهٔ عصبی پس‌انتشار، الگوریتم یادگیری دارای دو فاز است. ابتدا یک مجموعه دادهٔ ورودی آموزشی به لایهٔ ورودی شبکه ارائه می‌شود. سپس، شبکه مجموعه داده‌های ورودی را از لایه‌ای به لایهٔ دیگر منتشر می‌کند تا زمانی که مجموعه داده‌های خروجی توسط لایهٔ خروجی تولید شود. اگر این مجموعه داده با خروجی مورد نظر متفاوت باشد، یک خطا محاسبه می‌شود و سپس، به طور معکوس در شبکه از لایهٔ خروجی به لایهٔ ورودی منتشر می‌شود. وزن‌ها با انتشار خطا اصلاح می‌شوند [۱۱]. مدل‌های شبکه‌های عصبی مصنوعی بر اساس معماری آن‌ها، یعنی ساختار شبکه، تابع انتقال و الگوریتم یادگیری تعیین می‌شوند. در شبکه‌های پس‌انتشار، معماری MLP به طور کلی با استفاده از ترکیب‌های متنوع از تعداد لایه‌های پنهان و تعداد گره‌ها در یک لایهٔ پنهان، توابع انتقال مختلف و الگوریتم‌های یادگیری تصمیم می‌گیرد تا مناسب‌ترین مدل ANN انتخاب شود. معماری که بهترین قابلیت تعمیم را در بین تمام ترکیبات آزمایش‌شده دارد. به حداقل رساندن خطای مجموع مربع هنگامی است که فرایند آموزش کامل شده و وزن‌ها و بایاس هر نورون در شبکهٔ عصبی تنظیم شده است. گام بعدی بررسی نتایج آموزش با مشاهدهٔ نحوهٔ عملکرد شبکه در موقعیت‌هایی است که در آموزش با آن مواجه شده‌اند و در موقعیت‌هایی که قبلاً با آن‌ها مواجه نشده‌اند.

در این مطالعه از شبکه‌های عصبی مصنوعی MLP استفاده شده به دلیل اینکه نخست شبکه راه‌حل کوچک و سرعت محاسباتی سریع که امکان آموزش روی مجموعه داده‌های ورودی بزرگ را فراهم می‌کند؛ دوم تعمیم خودکار دانش که امکان تشخیص مجموعه داده‌ها را فراهم می‌کند؛ سوم به حداقل رساندن میانگین مجذور خطای مجموع در تمام مجموعه داده‌های آموزشی و در نهایت، آموزش تحت نظارت. این نوع از مدل ضعف‌هایی نیز دارد که باید هنگام ساخت یک MLP در نظر گرفته شود. این شامل تعداد لایه‌های پنهان، نوع تابع‌های انتقال، شرایط اولیه و انواع MLP پس‌انتشار در دسترس است. همچنین، باید زمان را نیز در نظر گرفت که تابعی مستقیم از اندازهٔ مجموعهٔ آموزشی و MLP انتخاب‌شده برای کار است.

۴. منطق فازی (Fuzzy Logic)

مدل‌های منطق فازی به عنوان یک روش پیش‌بینی جایگزین پیشنهاد شده‌اند، زیرا به ما اجازه می‌دهند اطلاعات را با حقایق و قوانینی که به صورت شفاهی توسط متخصصان فرمول‌بندی شده‌اند وارد کنیم و رفتار سیستم‌های پیچیده را با استفاده از عبارات توصیف کنیم. منطق فازی مبتنی بر تصمیم‌گیری یک انسان است. در این مقاله، پیش‌بینی مصرف انرژی با استفاده از منطق فازی و شبکهٔ عصبی مصنوعی انجام می‌شود. هم منطق فازی و هم شبکهٔ عصبی مصنوعی به طور گسترده برای اهداف پیش‌بینی استفاده می‌شوند. شبکهٔ عصبی مصنوعی مبتنی بر یادگیری ماشین است. برای توسعهٔ مدل مبتنی بر منطق فازی و شبکهٔ عصبی مصنوعی از برنامه‌های کاربردی مختلف ارائه‌شده در نرم‌افزار متلب استفاده شده است. داده‌های نرمال‌شده برای اهداف پیش‌بینی استفاده می‌شود. برای ارزیابی عملکرد میانگین، درصد خطای مطلق برای هر دو مورد محاسبه می‌شود.

۵. معیارهای اندازه‌گیری

برای یافتن شبکه‌ای با معماری مناسب از شاخص‌های میانگین مربع خطا [۱]، میانگین خطای مطلق [۲] و ضریب همبستگی [۳] استفاده می‌شود. این معیارها برای ارزیابی عملکرد نتایج الگوریتم‌های یادگیری مورد استفاده قرار می‌گیرند:

$$MSE = \frac{\sum_{i=1}^{N}(Q_i - T_i)^2}{N}$$ رابطهٔ (۱)

$$MAE = \frac{1}{N}\sum_{i=1}^{N}|Q_i - T_i|$$ رابطهٔ (۲)

$$RMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(Q_i - T_i)^2}$$ رابطهٔ (۳)

$$R = 1 - \frac{RSS}{TSS}$$ رابطهٔ (۴)

۶. مصرف انرژی

انرژی بخش مهمی از زندگی روزمرهٔ انسان را تشکیل می‌دهد. تقریباً در هر فعالیتی به انرژی نیاز است. با رشد اقتصادی، تقاضا برای انرژی به طور چشمگیری افزایش می‌یابد. بر اساس گزارش ادارهٔ اطلاعات انرژی آمریکا و آژانس بین‌المللی انرژی، مصرف انرژی در سراسر جهان به طور متوسط ۲/۵ درصد در سال افزایش می‌یابد و این یک پیش‌بینی متوسط را تشکیل می‌دهد. یک عامل بسیار مهم که بر مصرف انرژی نیز تأثیر می‌گذارد، آب‌وهوا است. افزایش سالانهٔ دمای محیط به دلایل بسیار واضح از جمله افزایش انتشار گازهای گلخانه‌ای، استفاده از سوخت‌های فسیلی و غیره تأثیر قابل توجهی در مصرف انرژی دارد، یعنی افزایش دما (تابستان‌های خیلی گرم) به استفادهٔ بیشتر از تهویهٔ مطبوع و سایر وسایل خنک‌کننده منجر می‌شود و در فصل‌های سرد سال نیز (زمستان‌های خیلی سرد) به استفادهٔ بیشتر از وسایل گرمایشی می‌انجامد. مطالعات اخیر به این نتیجه رسیده‌اند که حساسیت مصرف انرژی به دما در دوره‌های اخیر افزایش یافته است. با توجه به نگرانی در مورد گرم شدن کرهٔ زمین، این یافته‌ها از علاقهٔ مجدد سیاست‌گذاران به سؤالات مرتبط با انرژی حمایت می‌کند.

۷. طراحی مدل پیشنهادی

هدف از این مطالعه، توسعهٔ یک معماری شبکهٔ عصبی مصنوعی است که قادر به پیش‌بینی مصرف انرژی بلندمدت استان همدان است. داده‌هایی که در جدول ۱خلاصه شده‌اند، داده‌های ثبت‌شدهٔ واقعی را تشکیل می‌دهند. به طور خاص، مصرف حامل‌های انرژی از جمله بنزین، گاز طبیعی، نفت گاز، نفت کوره و نفت سفید از ترازنامهٔ انرژی وزارت نیرو تضمین شده است. داده‌ها به صورت سالیانه انتخاب شده‌اند. دلیل این انتخاب این بود که داده‌ها تنها به صورت سالیانه در ترازنامهٔ انرژی در دسترس است. همان‌طور که قبلاً بیان شد، هر مدل ANN با توجه به ساختار آن، تابع انتقال و الگوریتم یادگیری تعیین می‌شود که در تلاش برای یادگیری شبکه ویژگی‌های اساسی مسئلهٔ بررسی‌شده استفاده می‌شود.

جعبه‌ابزار شبکهٔ عصبی [۴] برای آموزش مدل‌های شبکهٔ عصبی توسعه‌یافته استفاده شد. داده‌های ورودی و خروجی ۲۰ سال گذشته (۱۳۹۹-۱۳۸۰) برای آموزش و اعتبارسنجی و تست مدل‌های شبکهٔ عصبی استفاده شد. پیش‌بینی برای ۱۰ دورهٔ آینده است. از طرفی، چون دیتاهای این مطالعه به صورت سالیانه است؛ لذا دوره‌های پیش‌بینی‌شده نیز به صورت سالیانه است. در هر تکرار ۷۰ درصد از داده‌ها به عنوان آموزش و ۳۰ درصد هم به عنوان تست برای این داده‌ها محاسبه شد. در نهایت، مقدار مصرف انرژی پیش‌بینی‌شده با مقادیر به‌دست‌آمده از موقعیت‌هایی که در آموزش با آن‌ها مواجه شده‌اند و مواردی که با آن‌ها مواجه نشده‌اند بررسی شد. هر یک از داده‌ها به پنج دورهٔ قبل خود وابسته هستند:

1. Mean Squared Error
2. Mean Absolute Error
3. R^2
4. Neural Network Toolbox

رابطهٔ (۵) $Input(k,):=x(Range-d)$

و مقدار خروجی:

رابطهٔ (۶) $Target=x(Range)$

عملکرد توابع انتقال یا فعال‌سازها به این شکل است که در لایهٔ انتهایی هر نورون توابعی وجود دارند که کار نگاشت اطلاعات خروجی نورون، روی مقادیر قابل قبول به جهت نمایش خروجی را به عهده دارند. توابع انتقال دسته گسترده‌ای از توابع را شامل می‌شود و برای هر شبکهٔ عصبی کاربرد مختص به خود را خواهد داشت. در اینجا از تابع انتقال tansig و purelin استفاده شده، زیرا نتایج مطلوب‌تری را در اختیار ما قرار می‌دهد.

با توجه به اینکه دیتاها به صورت سالیانه و از سال ۱۳۸۰ تا ۱۳۹۹ (بر اساس ترازنامهٔ انرژی) است؛ لذا تمامی دوره‌ها سالیانه در نظر گرفته می‌شود؛ بنابراین پیش‌بینی‌های انجام‌شده نیز تا سال ۱۴۰۹ بر اساس دوره‌های سالیانه است. نتایج حاصل از مدل‌سازی با استفاده از شبکه‌های عصبی و منطق فازی به شرح ذیل است.

جدول ۱. پیش‌بینی مصرف انرژی طی ۱۰ دورهٔ آینده با استفاده از شبکه‌های عصبی

سال	گاز طبیعی (میلیون مترمکعب)	بنزین (میلیون لیتر)	نفت سفید (میلیون لیتر)	نفت کوره (میلیون لیتر)	نفت گاز (میلیون لیتر)	فروش برق (گیگاوات ساعت)
۱۴۰۰	۳۱۳۵٫۶	۳۸۹٫۸	۳۱٫۲	۷۹۷٫۳	۶۲۵٫۷	۴۹۸۵٫۷
۱۴۰۱	۳۱۲۹٫۵	۳۸۸٫۷	۳۳٫۱	۵۳۱٫۸	۶۲۱٫۵	۴۹۶۹٫۲۳
۱۴۰۲	۳۱۵۱٫۶	۴۰۹٫۲	۳۳٫۹۵	۷۶۵٫۵	۶۲۲٫۲	۵۱۸۵٫۶۹
۱۴۰۳	۳۱۲۹٫۷	۴۷۳٫۳	۳۵٫۱۰	۵۴۰٫۲	۶۲۴٫۰	۴۳۷۳٫۹۹
۱۴۰۴	۲۰۸۰٫۷	۴۶۶٫۸	۴۸٫۲۸	۵۶۶٫۰	۵۷۱٫۵	۴۱۱۵٫۶۲
۱۴۰۵	۲۸۳۳٫۰	۴۴۵٫۶	۵۱٫۳۷	۵۹۹٫۸	۵۵۲٫۲	۳۳۹۳٫۳
۱۴۰۶	۳۱۵۶٫۷	۴۶۰٫۴	۶۰٫۸۸	۶۰۸٫۵	۵۹۱٫۴	۳۳۹۳
۱۴۰۷	۲۸۴۷٫۹	۴۵۳٫۵	۷۳٫۷۰	۷۲۷٫۲	۵۸۷٫۸	۳۵۲۱٫۲۵
۱۴۰۸	۳۰۶۵٫۴	۴۱۶٫۷	۸۱٫۴۴	۵۴۲٫۷	۵۶۷٫۵	۳۳۹۰٫۱
۱۴۰۹	۲۱۳۰٫۷	۳۸۷٫۰	۸۵٫۵۸	۷۶۲٫۵	۵۹۱٫۹	۳۳۱۸٫۶۶

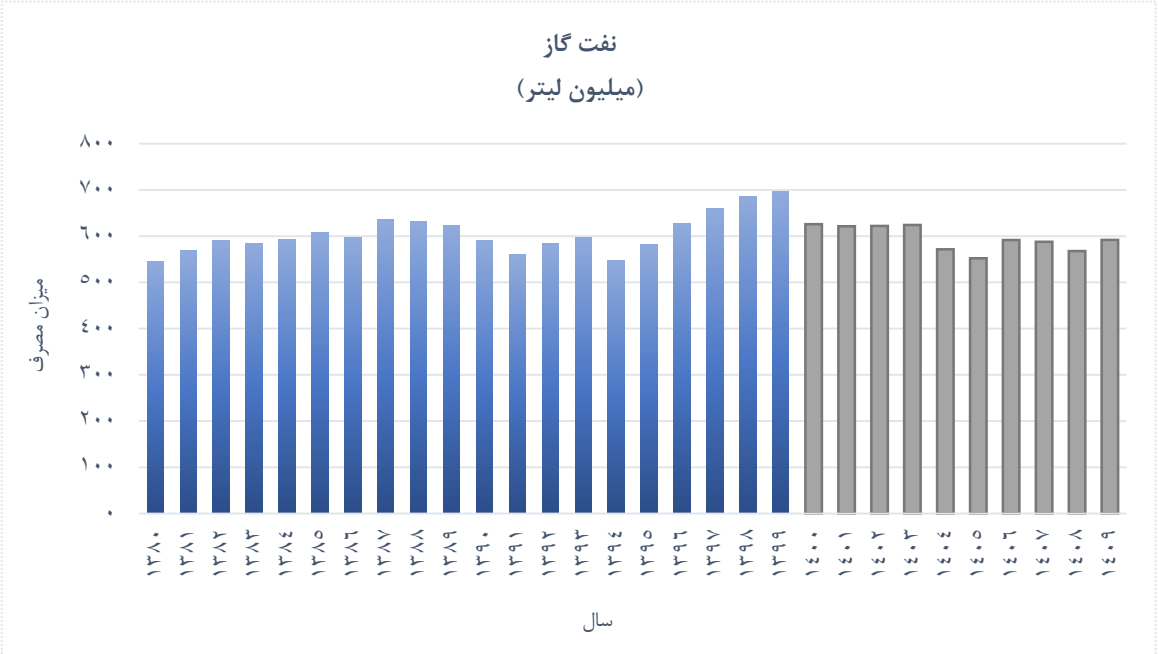

شکل ۵. نمودار پیش‌بینی مصرف نفت گاز

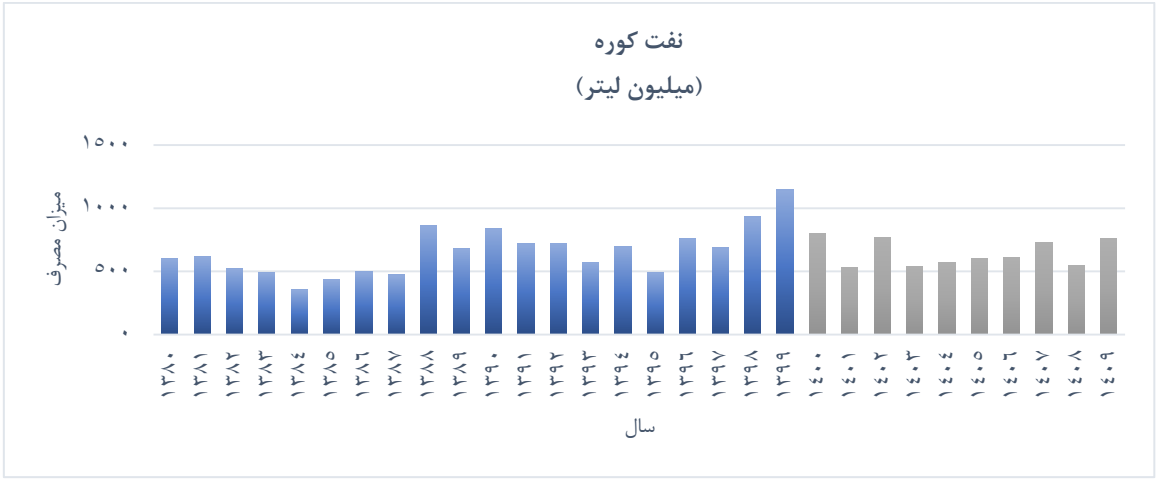

شکل ٦. نمودار پیش‌بینی مصرف نفت کوره

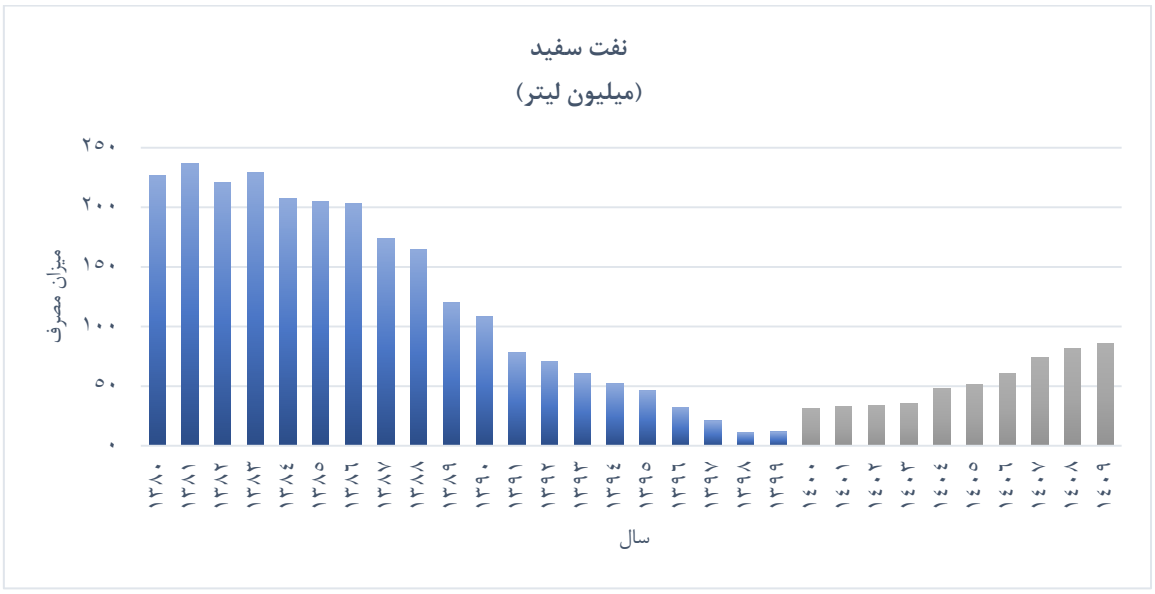

شکل ۷. نمودار پیش‌بینی مصرف نفت سفید

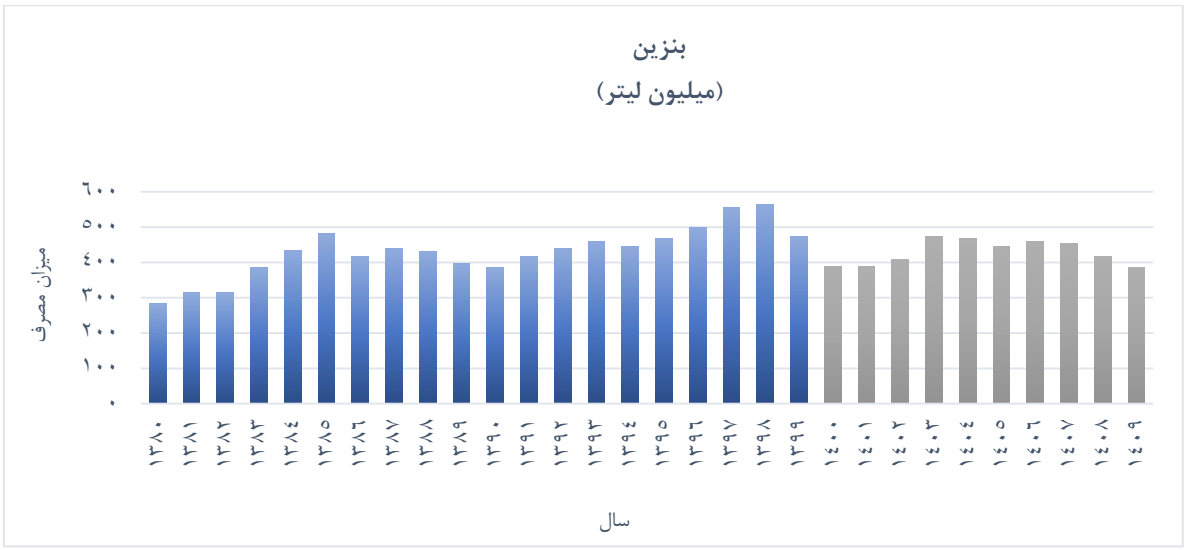

شکل ۸. نمودار پیش‌بینی مصرف بنزین

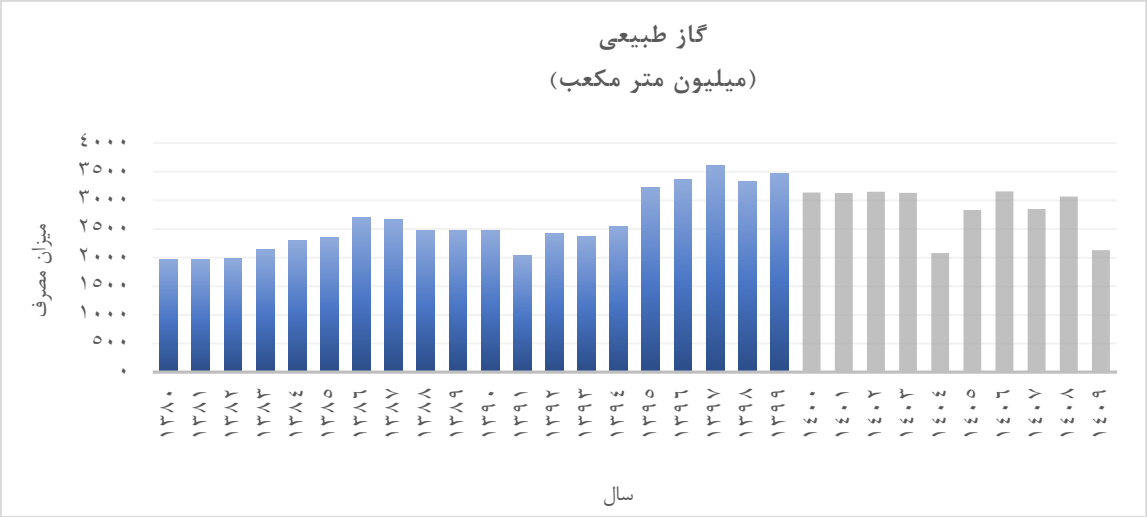

شکل ۹. نمودار پیش‌بینی مصرف گاز طبیعی

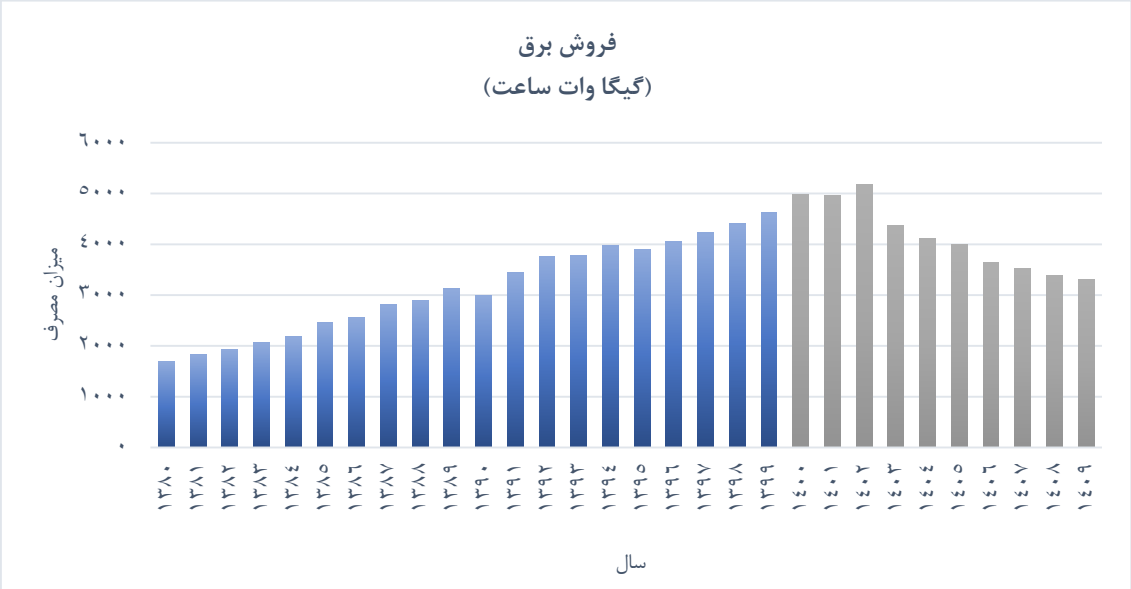

شکل ۱۰. نمودار پیش‌بینی تقاضای برق

جدول ۲. پیش‌بینی مصرف انرژی طی ۱۰ دورهٔ آینده با استفاده از منطق فازی

سال	گاز طبیعی (میلیون مترمکعب)	بنزین (میلیون لیتر)	نفت سفید (میلیون لیتر)	نفت کوره (میلیون لیتر)	نفت گاز (میلیون لیتر)	فروش برق (گیگاوات ساعت)
۱۴۰۰	۲۳۹۳٫۶	۵۷۲٫۵	۲۸٫۲۹	۶۸۷	۶۱۸٫۲	۴۶۱۳٫۹
۱۴۰۱	۲۴۱۵٫۸	۵۵۲٫۳	۳۲٫۳۹	۷۲۶٫۶	۶۳۵٫۲	۴۴۷۰٫۱
۱۴۰۲	۲۴۶۲٫۱	۵۴۸	۳۷٫۳۰	۴۸۱٫۲	۵۶۴٫۵	۴۴۷۲٫۴۴
۱۴۰۳	۲۵۲۸٫۹	۴۷۱٫۸	۴۰٫۱۷	۶۲۷٫۷	۶۰۵٫۷	۴۲۲۶٫۷۹
۱۴۰۴	۳۲۲۶٫۲	۴۶۶٫۸	۴۶٫۴	۴۹۲٫۵	۵۸۱٫۶	۳۹۰۵٫۶
۱۴۰۵	۲۵۴۱٫۵	۴۴۵٫۷	۵۲٫۱	۶۹۳٫۵	۵۴۷٫۴	۳۹۷۲٫۷
۱۴۰۶	۲۳۶۹٫۲	۴۶۰٫۵	۶۰٫۲	۵۷۱٫۶	۵۹۷	۳۷۸۱٫۱
۱۴۰۷	۲۴۲۲	۴۳۸٫۸	۷۰٫۸	۷۲۲٫۶	۵۸۳٫۱	۳۷۶۳٫۸
۱۴۰۸	۲۰۴۱	۴۱۶٫۲	۷۸٫۱	۷۱۷٫۷	۵۵۹٫۶	۳۴۳۷٫۹
۱۴۰۹	۲۴۷۱٫۵	۳۸۷	۱۰۸	۸۳۷	۵۹۰	۲۹۹۶٫۶

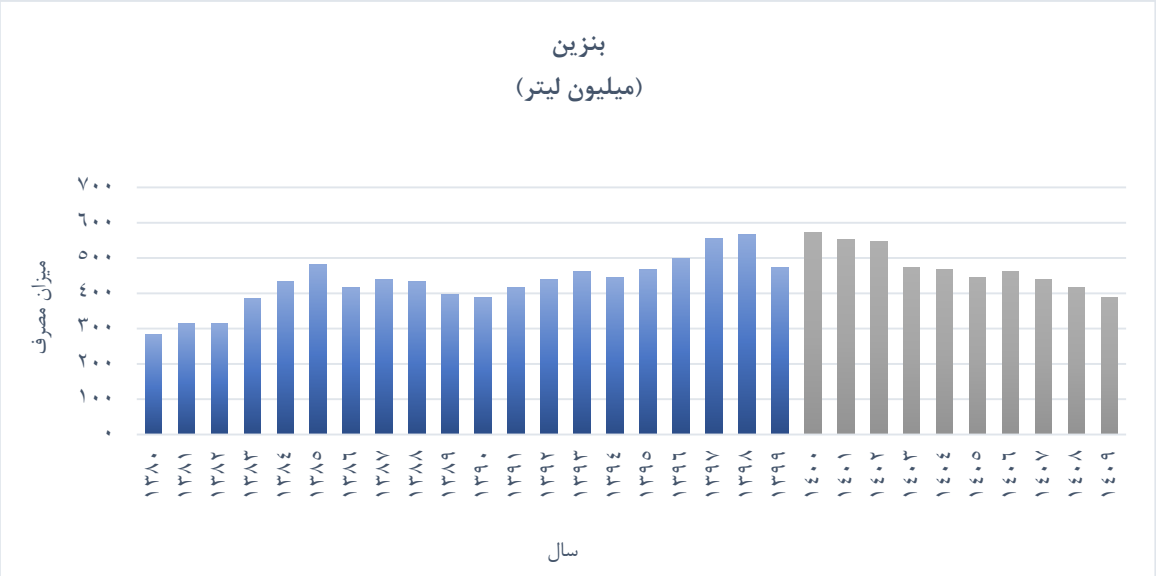

شکل ۱۱. نمودار پیش‌بینی مصرف بنزین

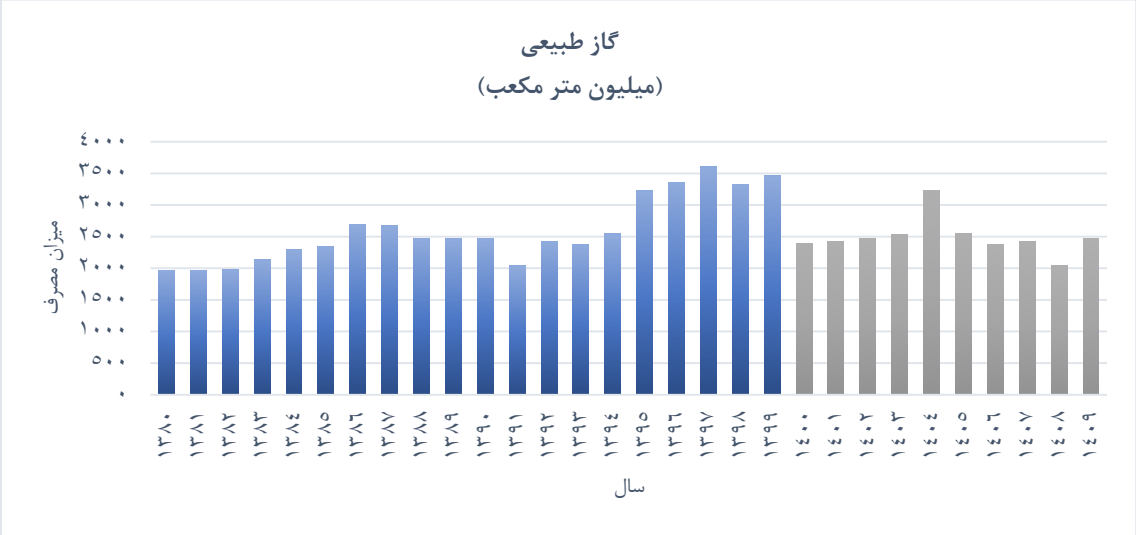

شکل ۱۲. نمودار پیش‌بینی مصرف گاز طبیعی

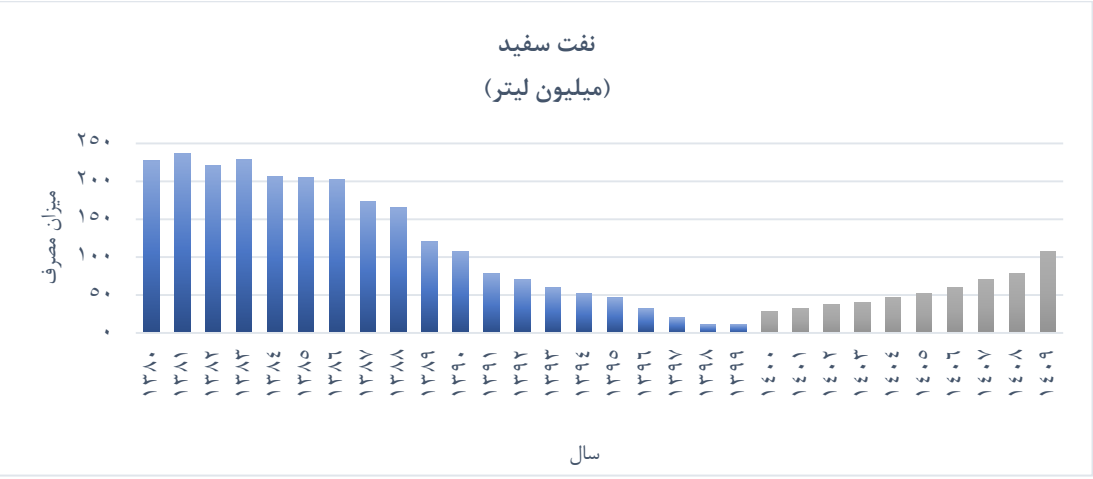

شکل ۱۳. نمودار پیش‌بینی مصرف نفت سفید

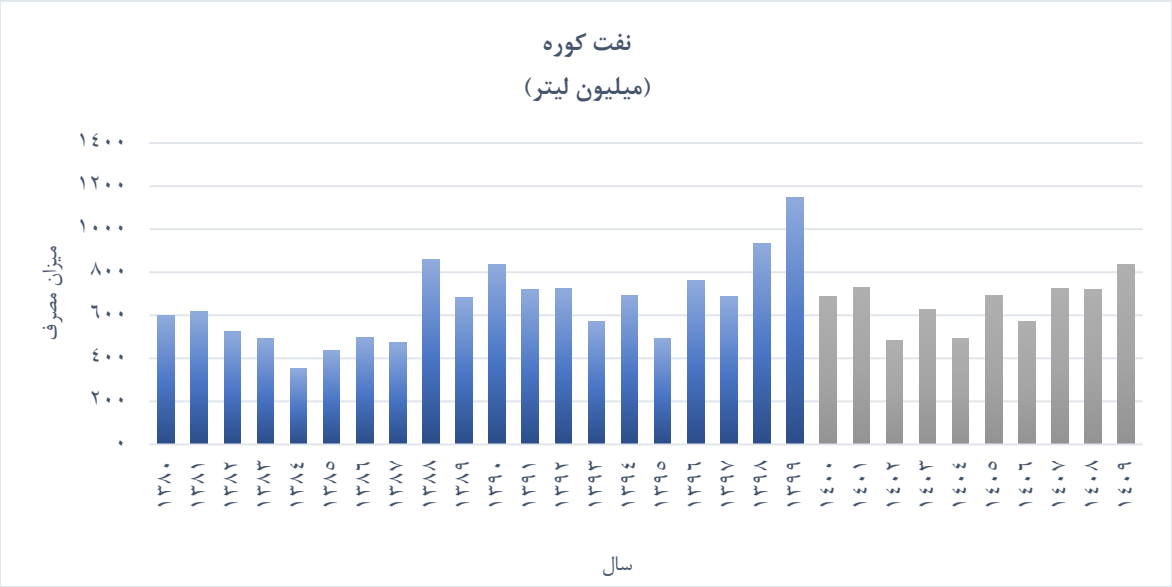

شکل ۱۴. نمودار پیش‌بینی مصرف نفت کوره

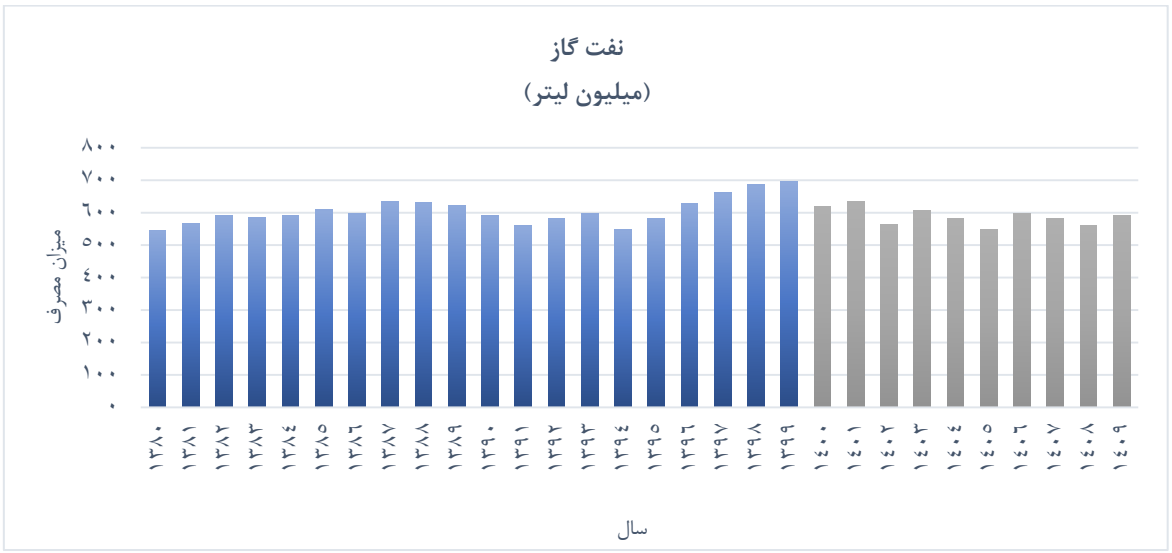

شکل ۱۵. نمودار پیش‌بینی مصرف نفت گاز

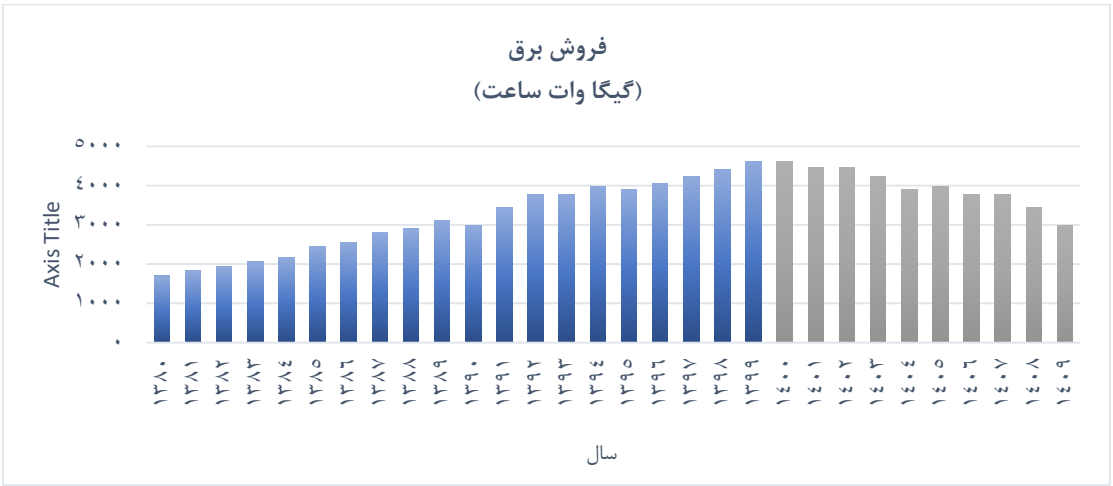

شکل ۱۶. نمودار پیش‌بینی تقاضای برق

همان‌طور که از نتایج مشخص است، میزان مصرف برخی از حامل‌های انرژی رو به افزایش و برخی نیز کاهشی است. برای مثال، مصرف گاز طبیعی از ۲۳۹۳ میلیون متر مکعب در سال ۱۴۰۰ به ۲۴۷۱ میلیون متر مکعب افزایش خواهد یافت که یکی از دلایل آن می‌تواند افزایش مشترکان جدیدی باشد که در بخش صنعت و خانگی اضافه خواهند شد. در بخش بنزین از ۵۷۲ میلیون لیتر در سال ۱۴۰۰ با شیبی کاهشی به ۳۸۷ میلیون لیتر در سال ۱۴۰۹ خواهیم رسید. میزان مصرف نفت سفید نیز روندی افزایشی خواهد داشت و از ۲۸ میلیون لیتر در سال ۱۴۰۰ به ۱۰۸ میلیون لیتر در سال ۱۴۰۹ می‌رسد. همچنین، نفت کوره از ۶۸۷ میلیون لیتر در سال ۱۴۰۰ با روندی افزایشی به ۸۳۷ میلیون لیتر در سال ۱۴۰۹ خواهد رسید. در بخش نفت گاز همانند بنزین روندی کاهشی داشته و از ۶۱۸ میلیون لیتر به حدود۵۹۰ میلیون لیتر در سال ۱۴۰۹ می‌رسد که یکی از دلایل آن را می‌توان به سیاست‌های دولت در زمینهٔ نوسازی ناوگان عمومی و شخصی، واردات و تولید خودروهای هیبریدی و برقی و همچنین، الزام به رعایت استانداردهای بین‌المللی در تولید خودروهای داخلی اشاره کرد. در نهایت، فروش برق نیز روندی کاهشی دارد و به حدود ۳۳۱۸ گیگاوات ساعت خواهیم رسید که یکی از دلایل آن می‌تواند مصوبهٔ دولت مبنی بر الزام به تأمین ۲۰ درصدی برق مورد نیاز وزارتخانه‌ها، شرکت‌های دولتی و نهادهای عمومی غیر دولتی، بانک‌ها و شهرداری‌ها توسط انرژی‌های تجدیدپذیر است.

در جدول ۳ نیز عملکرد نتایج الگوریتم‌های یادگیری شبکه‌های عصبی و منطق فازی مقایسه شده است. همان‌طور که از نتایج مشخص است و همچنین، با توجه به میانگین درصد خطا، عملکرد مدل در محدودهٔ مطلوبی قرار دارد.

جدول ۳. مقایسهٔ عملکرد نتایج الگوریتم‌های یادگیری شبکه‌های عصبی و منطق فازی

حامل انرژی	R^2		MSE		RMSE		MAPE	
	ANN	FUZZY	ANN	FUZZY	ANN	FUZZY	ANN	FUZZY
نفت گاز	۰/۷۷۸	۰/۶۶	۰/۰۴۱	۰/۰۵۵	۰/۲۰۴	۲۳۵	۰/۴۲۹	۰/۵۷۸
نفت کوره	۰/۶۱۶	۰/۷۲	۰/۰۵۳	۰/۰۴۱	۰/۲۳۲	۰/۲۰۳	۰/۹۳۰	۰/۶۰۱
نفت سفید	۰/۹۷	۰/۹۷	۰/۰۰۹	۰/۰۰۱	۰/۰۹	۰/۰۴۳	۰/۲۶	۰/۱۹
بنزین	۰/۸۰۴	۰/۸۷	۰/۹۳۴	۰/۰۲۲	۰/۳۰۵	۰/۱۵۰	۳/۹۶	۰/۱۳۱
گاز طبیعی	۰/۷۲۴	۰/۳۹۵	۰/۰۵۳۶	۰/۱۰۸	۰/۲۳۱	۰/۳۲۹	۰/۹۸۹	۰/۷۲

۸. نتیجه‌گیری

در این مقاله برای پیش‌بینی مصرف انرژی در نرم‌افزار متلب دو سناریو در نظر گرفته شده است. روش شبکهٔ عصبی مصنوعی و منطق فازی را برای پیش‌بینی ۱۰ دورهٔ آیندهٔ مصرف انرژی استان همدان توصیف می‌کند. بر اساس داده‌های مربوط به گذشته و پیش‌بینی این مقادیر برای بازهٔ ۱۰سالهٔ مورد مطالعه، داده‌ها را در ورودی نرم‌افزر وارد و پیش‌بینی را برای افق ۱۰ساله انجام داده‌ایم. داده‌های ورودی و خروجی ثبت‌شدهٔ واقعی که بدون شک بر مصرف انرژی تأثیر می‌گذارد در فرایند آموزش، اعتبارسنجی و تست استفاده شده‌اند. پیش‌بینی‌ها برای سال‌های ۱۴۰۰ تا ۱۴۰۹ انجام شده است که نتایج به‌دست‌آمده نزدیک به نتایج واقعی است. با توجه به داده‌های تاریخی که به صورت سالیانه است، پیش‌بینی انجام‌شده نیز برای ۱۰ دورهٔ آینده به صورت سالیانه خواهد بود. در ادامه، پس از در اختیار قرار گرفتن داده‌های ورودی به نرم‌افزار و تخصیص ۷۰ درصد داده‌ها برای آموزش، ۳۰ درصد داده نیز برای فرایند تست استفاده شد. از چندین تابع انتقال بررسی‌شده، تنها تابعی که نتایج مطلوب‌تری در اختیار ما قرار داد تابع tansig است، زیرا MSE مطلوب‌تری را به ما می‌دهد. توابع انتقال توابعی هستند در لایه‌های انتهایی هر نورون وظیفهٔ نگاشت اطلاعات خروجی نورون، روی مقادیر قابل قبول به جهت نمایش خروجی را به عهده دارند. در این اینجا از فعال‌ساز یا تابع انتقال tansigmoid استفاده شده که مقادیر نامحدود ورودی را به صورت محدود در بازهٔ منفی یک تا مثبت یک محدود می‌کند و در نهایت، با الگوریتم لونبرگ – مارگارت[1] تعلیم یافته است. نتایج شبیه‌سازی به ما نشان می‌دهد تقاضای برق تا سال ۱۴۰۹ رو به افزایش بوده و به حدود ۳۳۱۸ گیگاوات ساعت خواهد رسید. در برخی دیگر از حامل‌های انرژی نیز با توجه به سیاست‌های ابلاغی دولت در خصوص استفادهٔ حداکثری از انرژی‌های تجدیدپذیر، واردات خودروهای برقی، جایگزینی

1. Levenberg Marquardt Algorithm

خودروهای فرسوده و اقدامات در حال انجام در خصوص بهینه‌سازی مصرف انرژی روندی افزایشی با شیب ملایم خواهیم داشت. در زمینهٔ گاز طبیعی، شبکه‌های عصبی پیش‌بینی مطلوب‌تری را با توجه به مقدار R^2 به ما می‌دهد. از طرفی، در مصرف بنزین هر دو روش فازی و شبکه‌های عصبی با دقت مطلوبی پیش‌بینی آینده را در اختیار ما قرار داده‌اند. رویکرد پیشنهادی می‌تواند در اجرای مؤثر سیاست‌های انرژی مفید باشد، زیرا در گذشته برای پیش‌بینی مصرف انرژی با روش هوش مصنوعی اقدام جدی صورت نگرفته است. بنابراین، پیش‌بینی دقیق مصرف انرژی بر سرمایه‌گذاری، کیفیت زندگی، تحلیل درآمدزایی، مدیریت تحقیقات بازار تأثیر می‌گذارد و در عین حال، امنیت عرضه را حفظ می‌کند. تکامل مدل شبکه‌های عصبی مصنوعی تولیدشده می‌تواند آن را به ابزاری مهم در مطالعات تأسیسات و مقررات در ایران تبدیل کند که پیش‌بینی دقیقی برای مصرف انرژی بلندمدت ایران ارائه می‌دهد. برنامه‌ریزی و سیاست‌گذاری در زمینهٔ انرژی دارای اهمیت و جایگاه بالایی است. در همین راستا، پیش‌بینی روند جاری مصرف انرژی برای سال‌های آتی به تجزیه‌وتحلیل پیش‌بینی عرضه و تقاضا می‌تواند کمک بسزایی کند، به طوری که می‌تواند بر هزینه‌های مختلف انرژی تمرکز کند. تا کنون سیاست‌های مختلفی ارائه شده که هریک از آن‌ها پیش‌بینی و دیدگاه‌های متفاوتی را بررسی می‌کند، اما هیچ‌یک از این مدل‌ها بهترین مدل تلقی نمی‌شود، اما کمک شایانی به سیاست‌گذار در زمینهٔ پیش‌بینی انرژی و تحلیل پیامدهای آن می‌کند. لذا مدل‌های هوش مصنوعی می‌تواند بر اجرای سیاست‌ها و برنامه‌های مختلف تأمین و عرضهٔ انرژی در یک منطقه مورد استفاده قرار گرفته و در صورت لزوم در سطح ملی نیز مورد استفاده قرار گیرد. از طرفی، با توجه به نتایج حاصل‌شده از این مطالعه، پیشنهاد می‌شود که پروژه‌های مدل‌سازی بیشتری در زمینهٔ پیش‌بینی مصرف انرژی در این استان انجام شود و مورد توجه قرار گیرد. همچنین، با توجه به پایین بودن هزینهٔ سوخت‌های فسیلی و روند مصرف انرژی در گذشته و آینده در این استان، ادامهٔ روند فعلی مصرف انرژی باعث به وجود آمدن ناترازی در بخش‌های مختلف انرژی می‌شود.

منابع

[1] Simai, Mobina and Mirabadi. "Short-term forecast modeling of electricity consumption using artificial intelligence methods in Gilan province." Sustainable Energy Systems Quarterly.2023 1.3: 209-230.(persian)

[2] Nooralhi, Yousefi, Abbaspour and Siraj. "Modeling energy systems with the aim of increasing the share of renewals, a case study of Ahvaz city." Scientific-Promotional Journal of Iranian Energy.2019 23.4: 153-171.(persian)

[3] Ekonomou L. Greek long-term energy consumption prediction using artificial neural networks. Energy. 2010 Feb 1;35(2):512-7.

[4] Chapagain K, Kittipiyakul S, Kulthanavit P. Short-term electricity demand forecasting: Impact analysis of temperature for Thailand. Energies. 2020 May 15;13(10):2498.

[5] Rahman MM, Shakeri M, Tiong SK, Khatun F, Amin N, Pasupuleti J, Hasan MK. Prospective methodologies in hybrid renewable energy systems for energy prediction using artificial neural networks. Sustainability. 2021 Feb 23;13(4):2393.

[6] Suganthi L, Samuel AA. Energy models for demand forecasting—A review. Renewable and sustainable energy reviews. 2012 Feb 1;16(2):1223-40.

[7] Brito TC, Brito MA. Forecasting of Energy Consumption: Artificial Intelligence Methods. In2022 17th Iberian Conference on Information Systems and Technologies (CISTI) 2022 Jun 22 (pp. 1-4). IEEE.

[8] Wei N, Li C, Peng X, Zeng F, Lu X. Conventional models and artificial intelligence-based models for energy consumption forecasting: A review. Journal of Petroleum Science and Engineering. 2019 Oct 1;181:106187.

[9] Kalogirou SA. Applications of artificial neural-networks for energy systems. Applied energy. 2000 Sep 1;67(1-2):17-35.

[10] Đozić DJ, Urošević BD. Application of artificial neural networks for testing long-term energy policy targets. Energy. 2019 May 1;174:488-96.

[11] Chugh A, Chaudhary P, Rizwan M. Fuzzy logic approach for short term solar energy forecasting. In2015 Annual IEEE India Conference (INDICON) 2015 Dec 17 (pp. 1-6). IEEE.

[12] Maier HR, Galelli S, Razavi S, Castelletti A, Rizzoli A, Athanasiadis IN, Sànchez-Marrè M, Acutis M, Wu W, Humphrey GB. Exploding the myths: An introduction to artificial neural networks for prediction and forecasting. Environmental modelling & software. 2023 Jul 5:105776.

[13] Sepehr M, Eghtedaei R, Toolabimoghadam A, Noorollahi Y, Mohammadi M. Modeling the electrical energy consumption profile for residential buildings in Iran. Sustainable cities and society. 2018 Aug 1;41:481-9.

[14] Entezari A, Aslani A, Zahedi R, Noorollahi Y. Artificial intelligence and machine learning in energy systems: A bibliographic perspective. Energy Strategy Reviews. 2023 Jan 1;45:101017.

[15] Moosavian SF, Noorollahi Y, Shoaei M. Renewable energy resources utilization planning for sustainable energy system development on a stand-alone island. Journal of Cleaner Production. 2024 Jan 27:140892.

[16] Noorollahi Y, Sadeghi S, Yousefi H, Nohegar AJ. Landslide modelling and susceptibility mapping using AHP and fuzzy approaches. Int J Hydro. 2018;2(2):137-48.

[17] Noorollahi Y, Bigdelou P, Pourfayaz F, Yousefi H. Numerical modeling and economic analysis of a ground source heat pump for supplying energy for a greenhouse in Alborz province, Iran. Journal of Cleaner Production. 2016 Sep 10;131:145-54.

[18] Noorollahi Y, Itoi R, Yousefi H, Mohammadi M, Farhadi A. Modeling for diversifying electricity supply by maximizing renewable energy use in Ebino city southern Japan. Sustainable cities and society. 2017 Oct 1;34:371-84.

[19] Noorollahi Y, Jokar MA, Kalhor A. Using artificial neural networks for temporal and spatial wind speed forecasting in Iran. Energy Conversion and Management. 2016 May 1;115:17-25.

[20] Afzal S, Shokri A, Ziapour BM, Shakibi H, Sobhani B. Building energy consumption prediction and optimization using different neural network-assisted models; comparison of different networks and optimization algorithms. Engineering Applications of Artificial Intelligence. 2024 Jan 1;127:107356.

[21] Mateo-Barcos S, Ribó-Pérez D, Rodríguez-García J, Alcázar-Ortega M. Forecasting electricity demand of municipalities through artificial neural networks and metered supply point classification. Energy Reports. 2024 Jun 1;11:3533-49.

[22] Mfetoum IM, Ngoh SK, Molu RJ, Nde Kenfack BF, Onguene R, Naoussi SR, Tamba JG, Bajaj M, Berhanu M. A multilayer perceptron neural network approach for optimizing solar irradiance forecasting in Central Africa with meteorological insights. Scientific Reports. 2024 Feb 12;14(1):3572.

[23] Muñoz-Zavala AE, Macías-Díaz JE, Alba-Cuéllar D, Guerrero-Díaz-de-León JA. A Literature Review on Some Trends in Artificial Neural Networks for Modeling and Simulation with Time Series. Algorithms. 2024 Feb 7;17(2):76.