

Predicting CGS Pressure Using Machine Learning Case Study: Birjand

Mostafa Sabzekar,^{1*} Abbasali Rezapour,² Motahare Namakin³

¹ Department of Computer Engineering, Birjand University of Technology, Birjand, Iran,
sabzekar@birjandut.ac.ir

² Department of Civil Engineering, Birjand University of Technology, Birjand, Iran,
abbas.rezapoor@birjandut.ac.ir

³ Department of Computer Engineering, Ferdowsi University of Mashhad, Mashhad, Iran,
motahare.namakin@gmail.com

Keywords:

artificial intelligence,
machine learning,
deep learning,
gas pressure prediction,
CGS.

Original Research Article

Paper History:

Received: 21/10/2024

Revise: 19/03/2025

Accepted: 20/03/2025

Abstract: Today, natural gas stands as the dominant source of global energy supply. Iran holds the second-largest share of natural gas reserves, accounting for over seventeen percent of the world's total. However, it is concerning that gas consumption in Iran is three times the global average. To optimize planning in the natural gas supply sector, accurately assessing gas demand is crucial. Predicting natural gas consumption is vital for shaping energy policy and serves as a powerful tool for decision-makers, enabling them to effectively guide consumption and manage the balance between energy supply and demand. This paper addresses the challenge of predicting gas pressure at city gate stations (CGS) and analyzing its relationship with climate change. A significant issue faced in South Khorasan province during the colder months is the drop in pressure at these CGS, which stems from various factors, including the imbalance between gas production and consumption. Any estimates or forecasts regarding the pressure levels at these stations, which can serve as indicators of gas consumption, offer managers valuable insights to take proactive measures and mitigate potential crises. To tackle this problem, the study employs machine learning techniques. Data from CGS stations was sourced from the South Khorasan Province Gas Company, covering the years 2020 to 2024. Various scenarios were explored, including time series analysis, regression models, and the impact of temperature fluctuations on predictions, leading to the selection of the most effective approach. A notable strength of this research is the application of deep learning, a cutting-edge and highly promising machine learning methodology. Furthermore, this study marks the first instance of predicting CGS gas pressure. The findings underscore the significant influence of climate change factors on these predictions.

How to cite this article: Sabzekar, M., Rezapour, A., Namakin, M., "Predicting CGS Pressure Using Machine Learning Case Study: Birjand", Energy Engineering and Management, Vol. 14, No. 3, PP. 14-27, 2024, <https://doi.org/10.22052/EEM.2025.255658.1091>

© 2023 University of Kashan Press.

This is an open access article under the CC BY license (<http://creativecommons.org/licenses/by/4.0/>)



Extended Abstract

Introduction

Natural gas is now the primary source of energy supply, used in many countries as a clean and efficient energy source. The vast reserves of natural gas in Iran, its relatively low price, the welfare it provides to households due to the ease and continuity of access, lower environmental pollution, non-energy uses in the oil and petrochemical industries, and many other advantages highlight the important role of natural gas both at now and in the coming years, in particular, as one of the main energy suppliers for various consumption sectors of our country. However, in terms of consumption, our country ranks fourth in the world, with a consumption rate three times the global average and 13 times that of a country like Japan, which reflects the high consumption of this God-given energy resource. Studies indicate that among primary energy sources, natural gas consumption will experience the highest growth in the coming years with this growth being more significant in developing countries. Given the limited resources, the need for proper management of natural gas production and consumption is of great importance to prevent facing a future crisis. In order to plan better for the natural gas supply sector, understanding the level of gas demand in various sectors and forecasting future demand is of great importance. Predicting natural gas consumption plays a significant role in shaping energy policies and is a powerful means for decision-makers to plan appropriately, guide consumption, and control supply and demand parameters for energy. Due to the various factors that influence energy consumption trends and the high fluctuations associated with it, the need to use efficient and accurate models to forecast gas demand in the country is increasingly felt. Therefore, developing methods for accurately predicting gas consumption in the country is essential. Multiple factors are involved in forecasting gas consumption. Undoubtedly, one of the main factors in predicting the level of natural gas consumption is temperature. A recurring issue, especially in South Khorasan province, is the annual drop in gas pressure at city gate stations (CGS), which is the result of increased overall consumption with the impact of temperature being quite evident.

Materials and methods

In this research, we aim to use various machine learning tools to predict consumption by interpreting it through the inlet pressure of CGS stations and to examine the effect of temperature variations on it. One of the key strengths of this article is that no prior research has been conducted

on predicting the gas pressure at city gate stations (CGS), which in some way reflects gas consumption. Studies that predict gas consumption by subscribers often face issues of data quality and measurement validity. Besides, they face uncertainty in terms of accuracy due to human involvement in data collection. In contrast, the pressure and temperature data from CGS stations are available automatically without human intervention and are recorded minute by minute. Secondly, this paper explores various scenarios for prediction and identifies the best one. Additionally, deep learning, as one of the most recent approaches in the field of forecasting, has been employed. Finally, it is important to emphasize that in previous studies, the impact of past intervals on future predictions was considered equally, whereas in this paper a weighted combination of past periods is used.

Result

Based on the research findings, it was observed that considering temperature is effective in predicting pressure. Various prediction scenarios and different machine learning methods were examined, and the best scenario for training and testing the model was identified. Finally, predictions were made for time horizons of one week, one month, and one year. It is important to note that as the prediction window increased, model accuracy decreased. For example, weather forecasts for the next day were more accurate than for the following week.

Discussion and Conclusion

In this article, the issue of gas consumption prediction is addressed through the lens of predicting the inlet gas pressure at CGS stations and its relationship with climate changes. The reason for considering inlet gas pressure is that many studies have examined gas consumption by subscribers but have not concluded that gas pressure is independent of temperature. This is because, in the summer, when household consumption decreases, a larger share goes to industries. Conversely, in winter, with an increase in household consumption, the share for industries decreases. The initial question in this article was whether gas pressure is a function of weather changes. For future work, additional factors beyond climate changes could be considered as inputs to the learning system. It is well known that gas consumption depends on many factors, from technical to non-technical and even political ones. Considering these factors not only requires specific analyses but also presents machine learning with challenges that could be quite interesting.

پیش‌بینی فشار گاز ورودی ایستگاه‌های تقلیل فشار گاز برون‌شهری با استفاده از یادگیری ماشین (مورد مطالعاتی: شهرستان بیرجند)

مصطفی سبزه‌کار،^{۱*} عباسعلی رضاپور،^۲ مطهره نمکین^۳

^۱ دانشجویار گروه مهندسی کامپیوتر، دانشگاه صنعتی بیرجند، بیرجند، ایران، sabzekar@birjandut.ac.ir

^۲ استادیار گروه مهندسی عمران، دانشگاه صنعتی بیرجند، بیرجند، ایران، abbas.rezapoor@birjandut.ac.ir

^۳ دانشجوی دکتری گروه مهندسی کامپیوتر، دانشگاه فردوسی مشهد، مشهد، ایران، motahare.namakin@gmail.com

واژه‌های کلیدی:

هوش مصنوعی،

یادگیری ماشین،

یادگیری عمیق،

پیش‌بینی فشار گاز،

ایستگاه تقلیل فشار گاز برون‌شهری.

مقاله علمی پژوهشی

تاریخ دریافت: ۱۴۰۳/۰۷/۳۰

تاریخ بازنگری: ۱۴۰۳/۱۲/۲۹

تاریخ پذیرش: ۱۴۰۳/۱۲/۳۰

چکیده: امروزه گاز طبیعی بزرگ‌ترین منبع تأمین انرژی مورد نیاز در دنیاست. کشور ایران با دارا بودن سهم بیش از هفده درصدی از ذخایر گاز، رتبه دوم جهان را داراست اما متأسفانه همزمان میزان مصرف گاز در کشور سه برابر متوسط جهانی بوده که جای نگرانی بسیار دارد. به‌منظور برنامه‌ریزی هرچه بهتر در حوزه عرضه گاز طبیعی آگاهی از میزان تقاضای گاز در بخش‌های مختلف و پیش‌بینی وضعیت تقاضا در آینده از اهمیت زیادی برخوردار است. پیش‌بینی مصرف گاز طبیعی نقش قابل ملاحظه‌ای در تعیین خط‌مشی انرژی و یکی از ابزارهای قوی تصمیم‌گیرندگان در جهت برنامه‌ریزی صحیح هدایت مصرف و کنترل پارامترهای عرضه و تقاضای انرژی است. مسئله کلی که در این مقاله مورد بررسی قرار می‌گیرد، پیش‌بینی فشار گاز ورودی ایستگاه‌های تقلیل فشار گاز برون‌شهری و تحلیل ارتباط آن با تغییرات آب‌وهواست. یکی از مشکلاتی که در استان خراسان جنوبی هرساله در فصل سرد سال چالش‌های زیادی را ایجاد می‌نماید، افت فشار در ایستگاه‌های تقلیل فشار گاز برون‌شهری (CGS) است که به علل مختلف از جمله ناترازی بین تولید و مصرف گاز اتفاق می‌افتد. هرگونه برآورد و پیش‌بینی درخصوص میزان فشار این ایستگاه‌ها به‌عنوان تخمینی از میزان گاز مصرف‌شده، فرصتی ارزنده در اختیار مدیران قرار می‌دهد تا در جهت رفع بحران اقدامات پیش‌دستانه انجام دهند. در این مقاله از یادگیری ماشین به‌عنوان شاخه‌ای از هوش مصنوعی به‌منظور حل مسئله بهره گرفته شد. داده‌های اخذشده از ایستگاه‌های CGS از شرکت گاز استان خراسان جنوبی طی سال‌های ۱۳۹۹ تا ۱۴۰۲ مورد استفاده قرار گرفت. سناریوهای مختلف شامل تحلیل مسئله هم به‌صورت سری زمانی و هم رگرسیونی و همچنین تحلیل تغییرات دمایی برای پیش‌بینی معرفی گردید و بهترین سناریو انتخاب شد. همچنین از روش‌های مختلف پیش‌بینی برای حل مسئله بهره گرفته شد. یکی از مهم‌ترین نقاط قوت این پژوهش، استفاده از یادگیری عمیق به‌عنوان یکی از مهم‌ترین و امیدوارکننده‌ترین رویکردهای یادگیری ماشین است. به‌علاوه، برای اولین بار پیش‌بینی فشار گاز ایستگاه‌های تقلیل فشار گاز برون‌شهری صورت می‌پذیرد. نتایج حاکی از تأثیرگذاری عامل تغییرات آب‌وهوا بر پیش‌بینی دارد.

۱. مقدمه

مهم‌ترین عوامل در پیش‌بینی مصرف گاز، دماست. نتایج تحقیقات [۷] نشان می‌دهد که اگرچه کاهش دما باعث افزایش مصرف گاز در بخش خانگی می‌شود، مصرف کلی گاز ممکن است با افزایش دما کاهش نیابد. در فصول گرم، مصرف خانگی کاهش یافته و عمده گاز به نیروگاه‌ها و صنایع اختصاص می‌یابد، درحالی‌که در فصول سرد این روند معکوس می‌شود. برخی پژوهش‌ها مانند [۸] تأثیر دما را برای تمامی سال‌ها یکسان در نظر گرفته و آن را به‌عنوان یک سری زمانی ساده بررسی کرده‌اند. در استان خراسان جنوبی، یکی از چالش‌های سالانه، افت فشار گاز در ایستگاه‌های تقلیل فشار برون‌شهری (CGS)^۱ است که عمدتاً ناشی از افزایش مصرف و تغییرات دماست. در این پژوهش، با بهره‌گیری از ابزارهای یادگیری ماشین، مصرف گاز براساس فشار ورودی CGS‌ها پیش‌بینی شده و تأثیر تغییرات دمایی بر این روند تحلیل گردیده است.

یکی از مهم‌ترین مزایای این پژوهش این است که تاکنون هیچ مطالعه‌ای درباره پیش‌بینی فشار گاز در ایستگاه‌های تقلیل فشار برون‌شهری (CGS) انجام نشده است، درحالی‌که این فشار می‌تواند شاخصی برای میزان مصرف گاز باشد. پژوهش‌هایی که میزان مصرف گاز مشترکین را پیش‌بینی می‌کنند، اصولاً با مشکل اعتبار و کیفیت داده‌های اندازه‌گیری شده و عدم اطمینان به صحت آن با توجه به دخیل بودن عامل انسانی در جمع‌آوری مواجه هستند. درحالی‌که داده‌های فشار و دمای ایستگاه‌های CGS به‌صورت اتوماتیک، بدون دخالت عامل انسانی و دقیقه‌ای در اختیار قرار گرفته است. ثانیاً در این مقاله، سناریوهای مختلف برای پیش‌بینی بررسی شده و بهترین سناریو معرفی گردیده است. همچنین از یادگیری عمیق^۲ به‌عنوان یکی از جدیدترین رویکردها در زمینه پیش‌بینی بهره گرفته شده است.

۲. مفاهیم پایه

۲.۱. هوش مصنوعی، یادگیری ماشین و شبکه‌های

عصبی

طی سالیان اخیر هوش مصنوعی و یادگیری ماشین جایگاه بسیار ویژه‌ای در علوم مختلف کسب کرده است. سرمایه‌گذاری‌های هنگفت روی این فناوری جدید حکایت از این نقش بسیار مهم دارد. صنعت هوش مصنوعی در حال آماده‌سازی برای رشدی خیره‌کننده است. پیش‌بینی می‌شود ارزش آن طی هشت سال آینده ۱۳ برابر افزایش خواهد یافت. این گسترش سریع به‌دلیل پیشرفت‌های فناورانه

مبحث انرژی همواره یکی از ارکان اساسی قدرت دولت‌ها و یکی از عوامل کلیدی در سیاست‌گذاری‌های اقتصادی و اجتماعی ایران بوده است. با وجود تلاش‌ها برای کاهش وابستگی به منابع فسیلی، به‌دلیل ذخایر عظیم نفت و گاز، این حوزه همچنان نقشی حیاتی در توسعه پایدار کشور ایفا می‌کند [۱]. سیستم‌های انرژی به‌واسطه رفتارهای پیچیده همواره مورد توجه پژوهشگران بوده‌اند [۲]. تأمین انرژی در ایران، با توجه به وسعت جغرافیایی و تنوع اقلیمی، نیازمند برنامه‌ریزی علمی و دقیق است. با این حال، سیاست جایگزینی مصرف گاز طبیعی به‌جای فرآورده‌های نفتی، بدون در نظر گرفتن مدیریت بهینه انرژی، نتایج مطلوبی نداشته و در برخی موارد با منافع ملی نیز در تعارض قرار گرفته است [۱]. گاز طبیعی به‌دلیل ویژگی‌هایی همچون آلودگی کمتر، قیمت مناسب و دسترسی آسان، به‌عنوان منبع اصلی تأمین انرژی در کشور شناخته می‌شود. این منبع بیش از ۵۰٪ از انرژی مصرفی در بخش خانگی-تجاری، ۴۵٪ در بخش صنعتی و ۷۰٪ در نیروگاه‌ها و پالایشگاه‌های ایران را تأمین می‌کند [۳]. علاوه بر این، ایران با دارا بودن ۱۷٪ از ذخایر گاز جهان، در رتبه دوم جهانی قرار دارد، اما در زمینه مصرف، با میزان مصرفی سه برابر متوسط جهانی و ۱۳ برابر کشوری مانند ژاپن، جایگاه چهارم را به خود اختصاص داده است [۳]. وابستگی بیش از ۷۰ درصدی سبد انرژی ایران به گاز طبیعی و رشد سریع مصرف جهانی این منبع، اهمیت آن را به‌عنوان محور توسعه اقتصادی کشور برجسته می‌سازد [۴ و ۵]. طبق پژوهش اعظمی و همکاران [۶]، مصرف گاز طبیعی تأثیر مستقیمی بر رشد اقتصادی کشورهای صادرکننده دارد. همچنین، مطالعات نشان می‌دهند که در میان منابع انرژی اولیه، مصرف گاز طبیعی در سال‌های آینده، به‌ویژه در کشورهای در حال توسعه، رشد بیشتری خواهد داشت. با توجه به این روند و محدودیت منابع، مدیریت صحیح تولید و مصرف گاز طبیعی برای جلوگیری از بحران‌های آتی ضروری است [۵].

برنامه‌ریزی صحیح در حوزه عرضه گاز طبیعی مستلزم آگاهی از میزان تقاضا و پیش‌بینی آن در آینده است، زیرا این امر نقشی اساسی در سیاست‌گذاری انرژی، هدایت مصرف، و کنترل عرضه و تقاضا دارد. به‌دلیل نوسانات زیاد در مصرف انرژی، استفاده از مدل‌های دقیق و کارآمد برای پیش‌بینی تقاضای گاز ضروری است. رشد اقتصادی، توسعه شهرنشینی، تغییرات فصلی، و گسترش صنایع از عوامل کلیدی تأثیرگذار بر میزان مصرف گاز طبیعی محسوب می‌شوند که برنامه‌ریزی برای تأمین و توزیع این منبع را ضروری می‌سازد. یکی از

1. City Gate Station (CGS)
2. Deep learning

چشمگیر و پذیرش فزاینده در بخش های مختلف صورت می گیرد. تنها در سال ۲۰۲۳، بازار هوش مصنوعی ۳۸٪ رشد داشته که بیانگر افزایش سرعت ادغام فناوری های هوش مصنوعی در کسب و کار و زندگی روزمره است. انتظار می رود. تا سال ۲۰۲۵، صد میلیون نفر در مشاغل مرتبط با هوش مصنوعی مشغول به کار باشند که نشان دهنده تأثیر قابل توجه این صنعت بر اشتغال و اقتصاد جهانی است.

یادگیری ماشین^۱ یکی از مهم ترین شاخه های هوش مصنوعی است. طبق تعریف، یادگیری ماشین، مطالعه الگوریتم ها و مدل های آماری مورد استفاده سیستم های کامپیوتری است که به جای استفاده از دستورالعمل های واضح از الگوها و استنباط برای انجام وظایف سود می برند. یادگیری ماشین زیرمجموعه ای از هوش مصنوعی است که براساس داده های نمونه یا داده های آموزش به منظور پیش بینی یا تصمیم گیری بدون برنامه ریزی آشکار، ایجاد می کنند. هدف یادگیری ماشین این است که کامپیوترها بتوانند به تدریج و با افزایش حجم داده ها، کارایی بهتری در انجام وظیفه مورد نظر پیدا نمایند.

استفاده از هوش مصنوعی و یادگیری ماشین در پیش بینی به سازمان ها و افراد کمک می کند تا با دقت و سرعت بیشتری تصمیم گیری کنند و به نتایج بهتری دست یابند. یکی از مسائلی که همواره کاربرد پرهیجانی از یادگیری ماشین بوده، پیش بینی است. موضوع پیش بینی همواره یکی از جذاب ترین موضوعات نه تنها در زمینه های علمی بلکه در همه امورات انسان بوده است. درعین حال به دلیل عدم قطعیت موجود در آینده پیش بینی همواره با چالش مواجه بوده است [۹]. مهم ترین دلیل نیاز به پیش بینی، کمک به برنامه ریزی و تصمیم گیری و انجام اقدامات لازم برای کنترل و مدیریت بحران است [۱۰]؛ لذا پیش بینی را می توان در ابعاد کلان به طور مستقیم با سیاست، اقتصاد و مدیریت استراتژیک کشورها در ارتباط دانست. از طرف دیگر، صاحب نظران مبحث انرژی را همواره با ثبات، جایگاه و اقتدار یک کشور معادل دانسته اند [۱۱]؛ لذا هرگونه تلاشی در جهت مدیریت مصرف انرژی با استقبال گسترده مواجه می گردد.

یادگیری عمیق، هسته اصلی پژوهش فعلی ماست. اگرچه یادگیری عمیق از منظر تئوری در هر مدلی قابل اعمال است، تقریباً تمامی ساختارهایی که تاکنون در عمل برای پیاده سازی یادگیری عمیق مورد استفاده قرار گرفته اند، مبتنی بر شبکه های عصبی مصنوعی^۲ بوده اند. شبکه های عصبی تنوع زیادی از مدل هایی است که از نورون ها به عنوان واحدهای محاسباتی پایه ای خود استفاده می کنند. این مدل ها در ابتدای کار بر مبنای مشاهدات بیولوژیک توسعه

می یافتند اما درحال حاضر، توسعه آنها از مشاهدات بیولوژیک مستقل شده و شبکه های جدید براساس ایده های صرفاً ریاضیاتی ایجاد می شوند. شبکه های عصبی می توانند در دو حالت یادگیری با نظارت^۳ به منظور انجام عملیاتی مانند طبقه بندی^۴ (یادگیری متمایزگر) و برازش و یادگیری بدون نظارت^۵ برای انجام عملیاتی مانند کاهش بعد و یا یادگیری نمایش استفاده شوند.

شبکه های عصبی به صورت یک شبکه با سه لایه ورودی، مخفی و خروجی از عناصر پردازشی به نام نورون^۶ تعریف می شود. هر لایه شامل تعدادی نورون است که یک ارتباط کامل با نورون های لایه دیگر دارند. یک نورون کوچک ترین واحد پردازش است که معمولاً شامل یک تابع ریاضی غیرخطی است. رفتار کلی نورون ها عملکرد شبکه عصبی را نتیجه می دهد. یک نورون به تنهایی قادر به انجام اعمال محاسباتی بسیار ساده است، اما می توان همین نورون ها را در شبکه های عصبی به گونه ای قرار داد که بتوانند عملیات پیچیده محاسباتی را انجام دهند. ساختار و نحوه عملکرد شبکه های عصبی هدف این مقاله نیست و فرض شده خوانندگان با ساختار کلی شبکه های عصبی و همچنین یادگیری عمیق آشنایی دارند. در ادامه، مروری بر مفاهیم مرتبط با انتقال گاز خواهیم داشت و در فصل آینده مهم ترین پژوهش های انجام شده در این حوزه را مرور خواهیم نمود.

۲.۲. مفاهیم مربوط به انتقال گاز

همان طور که بیان شد، گاز طبیعی امروزه به عنوان یک انرژی پاک و از طرفی تجدیدناپذیر به عنوان یکی از مؤلفه های قدرت و ثروت برای کشور ایران در نظر گرفته می شود. از طرفی، دارا بودن رتبه دوم دنیا به لحاظ میزان ذخایر و از طرف دیگر، رتبه چهارم در مصرف آن نشان می دهد که استفاده از این منبع انرژی بایستی تدبیر و مدیریت گردد. بهینه سازی مصرف، نوسازی زیرساخت ها، افزایش تولید و تأمین انرژی با مناسب ترین شیوه، افزایش راندمان از طریق استفاده از فناوری های جدید، تلاش در جهت افزایش بهره وری و کاهش میزان اتلاف و هدررفت انرژی از جمله اقداماتی است که می توان در جهت استفاده بهینه از این منبع انرژی صورت داد. یکی دیگر از رویکردها پیش بینی مصرف گاز است که نه تنها سبب امکان انجام اقدامات پیش دستانه و جلوگیری از غافل گیری می گردد، بلکه زمینه را برای تحلیل رفتار مشترکین نیز فراهم می آورد. در این مقاله قصد داریم تا ضمن پیش بینی میزان مصرف گاز که در فشار ورودی به ایستگاه های

3. Supervised learning
4. Classification
5. Unsupervised learning
6. Neuron

1. Machine Learning
2. Artificial Neural Networks

می‌دهند قسمت‌هایی از ایستگاه نظیر فیلترها و یا کنتورها را به‌صورت مجموعه‌ای مجزا طراحی نمایند. در این صورت بهره‌بردار قدرت انتخاب بیشتری از خطوط را داشته و لرزش قسمت‌های تقلیل فشار به قسمت اندازه‌گیری منتقل نمی‌شود.

همان‌گونه که مطرح شد، پیش‌بینی مصرف گاز با استفاده از فاکتورهای مختلف در شهرهای مختلف کشور و حتی دنیا همواره به‌عنوان یکی از موضوعات داغ مورد توجه محققان بوده است. به‌طور کلی، اطلاعاتی از پروژه‌های صنعتی انجام‌شده در اختیار نیست، اما می‌توان پژوهش‌هایی را ذکر نمود که هدف آن‌ها پیش‌بینی مصرف گاز بوده است.

۳. مرور پژوهش‌های پیشین

با مروری بر پژوهش‌های انجام‌شده می‌توان ذکر کرد که به‌طور کلی، دو رویکرد کلی برای پیش‌بینی مصرف گاز از طریق حل مسئله رگرسیون متصور است. در دسته اول از روش‌های مبتنی بر علم آمار برای این منظور استفاده می‌شود، درحالی‌که در دسته دوم از روش‌های مبتنی بر هوش مصنوعی و یادگیری ماشین به‌منظور پیش‌بینی استفاده می‌شود. توانایی بالای دسته دوم در تخمین غیرخطی برای داده‌ها، سبب محبوبیت آن‌ها شده است.

در میان پژوهش‌های انجام‌شده در خارج از کشور، موارد متعددی را می‌توان ذکر کرد که از دیدگاه‌های مختلف و با استفاده از الگوریتم‌های گوناگون به بیان و حل مسئله می‌پردازند. سو و همکاران در سال ۲۰۱۹ [۱۲] یک روش ترکیبی از تبدیل موجک،^۱ یادگیری عمیق و الگوریتم ژنتیک ارائه نمودند و برای پیش‌بینی مصرف گاز به‌صورت ساعتی از آن بهره‌برداری نمودند. تبدیل موجک به‌منظور کاهش پیچیدگی پیش‌بینی از تجزیه سری اصلی بارهای گاز به چندین جزء فرعی استفاده می‌شود. روش یادگیری عمیق با ساختار RNN از طریق ترکیب یک مدل چندلایه Bi-LSTM و یک مدل LSTM^۲ ساخته شده است. مدل چندلایه Bi-LSTM می‌تواند به‌طور جامع ویژگی‌های موجود در اجزای فرعی را به تصویر بکشد و مدل LSTM برای پیش‌بینی مصرف گاز آینده براساس این ویژگی‌های انتزاعی استفاده می‌شود. برای افزایش عملکرد مدل یادگیری عمیق ساختاریافته RNN، از الگوریتم ژنتیک برای بهینه‌سازی ساختار هر لایه در مدل استفاده شده است.


CGS سرجمع می‌شود، اثر تغییرات آب‌وهوایی را بر میزان مصرف بررسی نمایم. پیش از ادامه بحث و مرور مهم‌ترین پژوهش‌های انجام‌شده درخصوص پیش‌بینی مصرف گاز، به‌اختصار ایستگاه‌های تقلیل فشار گاز (CGS) معرفی می‌گردد.

خطوط انتقال گاز به ایستگاه تقلیل فشار واقع در ورودی شهر به نام CGS می‌رسد. در ایستگاه‌های CGS فشار ورودی از 1000psi به 250psi کاهش پیدا می‌کند. شایان به ذکر است فشار ورودی به ایستگاه‌های تقلیل فشار در شرایط عادی عموماً بین 700 psi تا 1000psi متغیر است. این کاهش فشار توسط رگولاتورها انجام می‌شود. گاز خروجی از ایستگاه‌های CGS با فشار 250psi وارد خطوط تغذیه می‌شود. فشار گاز موجود در خطوط تغذیه برای ورود به شبکه شهر می‌بایست در یک مرحله دیگر کاهش داده شود. برای این منظور گاز به سمت ایستگاه‌هایی به نام TBS هدایت می‌شود. فشار گاز ورودی به TBS برابر 250psi و فشار گاز خروجی از آن برابر 60psi است. گاز داخل شبکه شهری با فشار 60psi شهری در کل سطح شهر (کوچه‌ها و خیابان‌ها در گردش) بین مشترکین توزیع می‌شود. برای انشعاب‌گیری به منازل از وسیله‌ای به نام TService استفاده می‌شود. قبل از ورود به محل مصرف، فشار گاز شبکه شهری مجدداً توسط رگولاتور تا 25psi (نسبی) شکسته می‌شود و گاز با این فشار توسط وسایل گازسوز مورد مصرف قرار می‌گیرد.

یک ایستگاه تقلیل فشار گاز متناسب با ظرفیت فشار ورودی و خروجی، نوع مصرف‌کننده، تعداد و مراحل شکست فشار و خطوط آن به شکل‌های مختلفی طراحی و ساخته می‌شود. اگر با توجه به نوع مصرف‌کننده بخواهند یک تقسیم‌بندی ارائه دهند می‌توان نوشت:


- ایستگاه‌هایی که شبکه‌های توزیع گاز را تغذیه می‌کنند (ایستگاه شهری)؛
- ایستگاه‌هایی که شبکه داخلی صنایع و واحدهای تجاری و مسکونی بزرگ را تغذیه می‌کنند (ایستگاه‌های صنعتی و تجاری). این ایستگاه‌ها توسط امور مهندسی طراحی و سفارش می‌گردند. در ایستگاه‌هایی که ظرفیت آن‌ها بیش از پنج هزار متر مکعب در ساعت بوده و تداوم گازرسانی حیاتی است، تعداد خطوط ایستگاه بیش از یک خط خواهد بود که معمولاً در این‌گونه موارد ظرفیت هر خط درصدی از ظرفیت کل ایستگاه است. در ایستگاه‌های دارای یک خط جهت بعضی از تجهیزات خط کنار گذر طراحی می‌گردد تا هنگام تعمیرات در امر گازرسانی وقفه‌ای ایجاد نگردد. برخی از طراحان ترجیح

فصلی خاکستری با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات^{۱۰} پیشنهاد شده است. شایان ذکر است مدل پیش‌بینی خاکستری یک روش پیش‌بینی عددی است که در شرایطی که داده‌های کمی در دسترس است یا اطلاعات دارای عدم قطعیت هستند، استفاده می‌شود. این مدل که بخشی از نظریه سیستم‌های خاکستری^{۱۱} است، معمولاً در مواردی به کار می‌رود که اطلاعات کامل یا دقیقی از پدیده مورد مطالعه در دسترس نباشد. در این کشور نیز به‌مانند کشورمان ایران یک عدم تناسب بین تولید و مصرف مشاهده می‌شود که در شکل (۱) نمایش داده شده است.



شکل (۱): رشد تولید و مصرف در کشور چین [۱۶]

شکل‌های (۲) و (۳) به ترتیب عملکرد مدل را برای دو نوع پیش‌بینی نشان می‌دهند. در شکل (۲)، پیش‌بینی برای دوره‌هایی نمایش داده شده است که مدل در فرایند آموزش آن‌ها را دیده است (داده‌های آموزشی). در شکل (۳)، پیش‌بینی مدل برای بازه‌های زمانی آینده ارائه شده است که در مرحله آموزش دیده نشده‌اند و مدل باید براساس الگوهای یادگرفته‌شده، مقدار آن‌ها را پیش‌بینی کند.



شکل (۲): پیش‌بینی روش برای داده‌های تعلیم داده‌شده [۱۷]

در پژوهشی دیگر [۱۳] محققان به پیش‌بینی مصرف گاز برای ۶۰ ساعت آینده با استفاده از یادگیری عمیق پرداختند. در مدل یادگیری ارائه‌شده توسط این محققان، از متغیرهای دما و اطلاعات روزانه که شامل نشانگرهایی برای تعطیلات و سایر مناسبت‌های روزانه بود، بهره گرفته شده است.

دو و همکاران [۱۴] با افزودن اطلاعات زمینه‌ای^۱ شامل دانش دامنه‌ای^۲ و همبستگی‌های زمانی-مکانی^۳ به مدل یادگیری عمیق، دقت پیش‌بینی را بهبود بخشیدند. این اطلاعات به مدل کمک کرد تا الگوهای مصرف گاز را بهتر درک کند و پیش‌بینی‌های دقیق‌تری ارائه دهد. نتایج نشان می‌دهد که مدل پیشنهادی قادر به دستیابی به نتایج پیش‌بینی‌شده دقیق‌تر و کارآمدتر در مقایسه با مدل‌های پیشرفته، مانند درخت‌های تصمیم‌گیری^۴ و واحدهای بازگشتی دروازه‌دار^۵ است. میانگین خطاهای نسبی مطلق^۶ و ریشه میانگین مربعات خطا^۷ به‌دست‌آمده توسط مدل پیشنهادی کمتر از ۰/۱۱ و ۰/۱۴ در همه موارد است که نشان‌دهنده بهبود نسبت به کارهای قبلی است. نتایج به‌دست‌آمده حاکی از نقش مهم داده‌های ذکرشده در بهبود عملکرد مدل دارد. پیش از این و در سال ۲۰۲۲ همین نویسنده از ترکیب روش‌های CNN و LSTM به‌منظور پیش‌بینی روزانه گاز استفاده کرده بود [۱۵].

پیش‌بینی سالانه مصرف گاز در ایالات متحده آمریکا توسط سینگ و همکاران در سال ۲۰۲۳ مورد بررسی قرار گرفت [۱۶]. پیش‌بینی مصرف گاز طبیعی در ایالات متحده آمریکا فرایندی پیچیده است زیرا این مصرف تحت تأثیر عوامل متعددی قرار دارد. برخی از این عوامل، تأثیر مستقیمی بر میزان مصرف گاز دارند، درحالی‌که برخی دیگر به‌صورت غیرمستقیم بر آن اثر می‌گذارند. در این پژوهش از رویکردهای ماشین بردار پشتیبان^۸ و شبکه‌های عصبی به‌منظور پیش‌بینی بهره گرفته شد.

لی و همکاران در سال ۲۰۲۱ به پیش‌بینی ماهانه مصرف گاز کشور چین پرداختند [۱۷]. در چین، تولید ماهانه گاز طبیعی دارای تغییرات فصلی و چرخه‌ای آشکار است. بنابراین استفاده از یک مدل پیش‌بینی خاکستری^۹ سستی چندان مؤثر نیست؛ در نتیجه، یک مدل

1. Contextual Information
2. Domain Knowledge
3. Temporal-Spatial Correlations
4. Decision trees
5. Gated Recurrent Unit (GRU)
6. Mean Absolute Error (MAE)
7. Root Mean Square Error (RMSE)
8. Support Vector Machines (SVMs)
9. Grey Prediction Model

10. Particle Swarm Optimization (PSO)
11. Grey System Theory

رگرسیون برای مدل سازی استفاده شده و مدل سازی به دو روش انجام شده که در اولی، پیش‌بینی مصرف با استفاده از خصوصیات مشترک و در دومی، پیش‌بینی مصرف با استفاده از سری زمانی مصرف صورت گرفته است. سپس نتایج مدل‌های مختلف با یکدیگر مقایسه شده و مشخص گردیده در هر دو روش، میزان دقت درخت تصمیم بیشتر از دو مدل دیگر است.


به‌منظور پیش‌بینی مصرف گاز مشترکین در شهرستان رشت، داغبندان و ستایش در سال ۱۳۹۵ پژوهشی انجام دادند [۴]. در ابتدا برخی از متغیرهای تأثیرگذار بر مصرف گاز با استفاده از روش‌شناسی سطح پاسخ شناسایی شده است. در ادامه شبکه عصبی نوع GMDH برای مدل سازی و پیش‌بینی میزان گاز طبیعی مصرفی در بخش خانگی، با استفاده از مجموعه داده‌های ورودی-خروجی مورد مطالعه قرار گرفته است.

از مجموع پژوهش‌های انجام شده می‌توان به این نتیجه رسید که اگرچه پیش‌بینی مصرف گاز با استفاده از فاکتورهای مختلف در شهرهای مختلف کشور همواره یکی از موضوعات مورد توجه بوده، بایستی توجه داشت رفتار مشترکین از شهری به شهر دیگر و از مقطع زمانی به مقطع زمانی دیگر دستخوش تغییر می‌شود. از طرفی، مدل‌های یادگیری روزبه‌روز دچار تغییر شده و روش‌های قدیمی جای خود را به روش‌های با دقت بالاتر می‌دهند.

در فصل آینده به طراحی سناریوهای مختلف پیش‌بینی و ساخت مدل برای این منظور پرداخته خواهد شد.

۴. روش پیشنهادی

ساختارهای عمیق برخلاف ساختارهای کم‌عمق در شبکه‌های عصبی تعداد لایه‌های مخفی بیشتری در معماری خود دارند. مطابق قضیه جهانی تقریب‌زننده [۲۰]، یک شبکه عصبی چندلایه با تابع فعال سازی^۲ غیرخطی قادر است هر تابع پیوسته غیرخطی را روی یک یک مجموعه فشرده تقریب بزند. باین حال، تقریب توابع غیرپیوسته غیرخطی نیازمند شبکه‌های عصبی عمیق تر یا روش‌های خاصی مانند انتگرال‌گیری از توابع پایه است [۲۱]. مدل‌های یادگیری عمیق معمولاً دارای تعداد پارامترهای بیشتری هستند و نیاز به محاسبات سنگین‌تری نسبت به مدل‌های کم‌عمق دارند. باین حال، در برخی موارد، اگر مدل کم‌عمق نیاز به استخراج ویژگی‌های دستی گسترده‌ای داشته باشد، استفاده از یادگیری عمیق می‌تواند هزینه کلی پردازش را کاهش دهد، زیرا ویژگی‌های مهم به‌طور خودکار آموخته می‌شوند [۲۲]. یادگیری



شکل (۳): پیش‌بینی روش برای افق‌های آینده [۱۷]

در داخل کشور نیز پیش‌بینی مصرف گاز موضوعی مورد توجه بوده است. خانم هنری و همکارانشان در سال ۱۳۹۵ پیش‌بینی مصارف گاز خانگی و تجاری برای یک دوره پنج‌ساله شهر اصفهان را با استفاده از شبکه‌های عصبی ارائه نمودند [۱۸]. برای یافتن یک ساختار مناسب شبکه عصبی، سه ساختار متفاوت با نام‌های دینامیک، هرس کامل و شبکه‌های پایه شعاعی^۱ بررسی شده است. داده‌های واقعی مصارف گاز ۱۰ سال (۱۳۸۱ تا ۱۳۹۰) برای پیش‌بینی مصارف (۱۳۹۱ تا ۱۳۹۵) استفاده شده است. به‌منظور پیش‌بینی مصارف خانگی و تجاری گاز طبیعی، متغیرهای مستقل جمعیت، دما، تعداد مشترکین و قیمت گاز انتخاب شده‌اند.

در پژوهشی دیگر [۱۹] پیش‌بینی مصرف گاز طبیعی مشترکین خانگی با استفاده از روال‌های داده‌کاوی در استان کرمان صورت پذیرفت. در این مقاله که به‌منظور پیش‌بینی مصرف ماهیانه گاز طبیعی مشترکین خانگی انجام شده، سوابق مصرف مشترکین استان کرمان طی سال‌های ۸۵-۸۸ مورد استفاده قرار گرفته است. استان کرمان با ۳۰ شهر و ۱۷۹ روستای برخوردار از گاز طبیعی، دارای ۳۰۳۵۲۷ مشترک است که بخش عمده آن‌ها، یعنی ۲۶۸۱۲۴ مشترک، خانگی می‌باشد و با توجه به توسعه گازرسانی در این استان، تعداد این مشترکین، در حال افزایش است. یکی از فعالیت‌هایی که در جریان گازرسانی به مشترکین انجام می‌شود، فرایند قرائت کنتور مشترکین برای صدور صورت حساب گاز می‌باشد که هر ۴۵ یا ۶۰ روز یک بار انجام می‌شود و انجام این فرایند، به‌خصوص در بخش خانگی، نیازمند صرف هزینه و زمان زیادی است و با افزایش تعداد مشترکین، این هزینه و زمان افزایش می‌یابد. در صورت پیش‌بینی مصرف گاز مشترکین، به‌طور قابل ملاحظه‌ای در این هزینه و زمان صرفه‌جویی خواهد شد. در این تحقیق، از شبکه عصبی، درخت تصمیم و

عمیق امروزه و به سرعت تبدیل به یکی از محبوب‌ترین زمینه‌های پژوهشی شده است.

ساختارهای عمیق با اضافه کردن لایه‌های مخفی بیشتر سعی در رفع مشکلات شبکه‌های عصبی به‌خصوص تعمیم‌پذیری، مقیاس‌پذیری و گرفتار شدن در بهینه محلی دارد. به عنوان یک مثال عملی، تابع توازن با ابعاد d را در نظر بگیرید. در این صورت تعداد متغیرهای مورد نیاز برای نمایش این تابع در یک ماشین بردار پشتیبان گاوسی^۱، در یک شبکه عصبی با یک لایه مخفی و در یک شبکه عصبی با $O(\log_2 d)$ لایه مخفی به ترتیب برابر با $O(d^2)$ ، $O(2^d)$ و $O(d)$ خواهد بود [۲۳]. بنابراین، ساختارهای عمیق چون تعداد پارامتر کمتری نیاز دارند، توانایی بالقوه بیشتری به نسبت ساختارهای کم عمق به منظور بهبود عمومی سازی و کاهش محاسبات دارند [۲۴]. مدل‌های یادگیری عمیق در عمل منجر به نمایش‌هایی با ویژگی‌های قابل توجهی می‌شوند که می‌توانند نسبت به تغییرات جزئی در داده‌های ورودی (مانند نویز و نوسانات مقطعی) مقاوم باشند. این ویژگی به‌ویژه در مدل‌هایی مانند LSTM و DNN، باعث یادگیری الگوهای پایدارتر در سری‌های زمانی می‌شود و مدل را در برابر تغییرات کوتاه مدت تقویت می‌کند [۲۲]. یکی از ویژگی‌های مهم شبکه‌های یادگیری عمیق، توانایی آن‌ها در ایجاد نمایش‌های توزیع شده^۲ و تنک^۳ است. در یک نمایش توزیع شده، هر ویژگی ورودی در چندین نورون مختلف نمایش داده می‌شود و هر نورون نیز اطلاعاتی از چندین ورودی را در خود نگه می‌دارد. این ویژگی باعث افزایش کارایی مدل و بهبود تعمیم‌پذیری آن می‌شود [۲۵]. از سوی دیگر، نمایش‌های تنک به این معنا هستند که تنها تعداد محدودی از نورون‌ها برای نمایش یک ویژگی خاص فعال می‌شوند، که این امر منجر به کاهش ابعاد مؤثر و بهینه‌تر شدن فرایند یادگیری می‌شود [۲۶]. به علاوه، ساختارهای عمیق می‌توانند نمایش‌های سلسله‌مراتبی را یاد بگیرند که مشابهت بسیاری با ساختار بینایی در انسان دارد. می‌توان گفت یادگیری عمیق در واقع نوعی شبکه عصبی مصنوعی است که دارای چندین لایه مخفی است و می‌تواند ویژگی‌های پیچیده‌تری را نسبت به شبکه‌های کم عمق یاد بگیرد. این مدل‌ها برای پردازش مجموعه داده‌های بزرگ و شناسایی روابط پیچیده استفاده می‌شوند. اگرچه در برخی موارد، اجرای مدل‌های عمیق نیاز به GPU برای پردازش سریع‌تر دارد، برخی از مدل‌های ساده یادگیری عمیق می‌توانند روی CPU نیز اجرا شوند.

البته باید توجه داشت اگرچه روش‌های یادگیری عمیق در پیش‌بینی الگوهای پیچیده عملکرد بهتری دارند، این روش‌ها چالش‌هایی نیز به همراه دارند؛ از جمله این چالش‌ها می‌توان به نیاز به حجم بالای داده برای آموزش، هزینه محاسباتی بالا، مشکل تفسیرپذیری، زمان طولانی برای آموزش مدل و نیاز به تنظیم دقیق ابرپارامترها اشاره کرد. با این حال، با پیشرفت سخت‌افزارهای پردازشی و توسعه روش‌های بهینه‌سازی مانند استفاده از یادگیری انتقالی^۴ و تنظیم وزن‌ها، این چالش‌ها تا حد زیادی کاهش یافته است.

مدل‌های یادگیری عمیقی که در این مقاله برای پیش‌بینی مصرف گاز مورد استفاده قرار گرفته، عبارت‌اند از: LSTM، CNN و DNN. مدل LSTM به دلیل توانایی آن در یادگیری وابستگی‌های زمانی طولانی مدت و حل مشکل ناپدید شدن گرادیان انتخاب شده است. از سوی دیگر، CNN به دلیل قابلیت آن در استخراج ویژگی‌های محلی از داده‌های سری زمانی به کار گرفته شده است. همچنین، مدل DNN به عنوان یک مدل پایه برای مقایسه عملکرد با سایر روش‌های یادگیری عمیق در نظر گرفته شده است.

شکل (۴) ساختار روش پیشنهادی را که الگوی تمامی روش‌های پیش‌بینی با استفاده از یادگیری ماشین است، نمایش می‌دهد.

1. Gaussian support vector machine
2. Distributed Representations
3. Sparse Representations

۴. فشار گاز تابع فشار و دما در روز قبل و ماقبل آن و دما در

$$P_{t+1}=f(P_t, P_{t-1}, T_t) \text{ است: روز ماقبل آن است}$$

۵. فشار گاز تابع فشار و دما در سه روز منتهی به آن و دما در

$$P_{t+1}=f(P_t, P_{t-1}, P_{t-2}, T_t) \text{ است: روز ماقبل آن است}$$

از بین سناریوهای ذکر شده بهترین سناریو که کمترین خطای پیش‌بینی را برای داده‌های آموزش گزارش نماید، به‌عنوان سناریوی این مقاله انتخاب خواهد شد. یکی از تفاوت‌های روش پیشنهادی با پژوهش‌های گذشته این است که در مقالات مشابه که رفتار آینده مدل تابع رفتار آن در دوره‌های گذشته است، تأثیر دوره‌های قبل بر دوره مورد پیش‌بینی در آینده، یکسان در نظر گرفته شده است [۲۷ و ۲۸]. در عمل واضح است که فشار روز یک روز قبل در یک CGS در پیش‌بینی فشار روز آینده تأثیر بیشتری به نسبت فشار روزهای قبل‌تر از آن دارد.

در نهایت باید از یک مدل یادگیری ماشین به‌منظور ساخت و برآورد مدل استفاده کنیم. در این مقاله از روش شناخته‌شده رگرسیون بردار پشتیبان^۱ و سه نوع روش یادگیری عمیق یعنی شبکه‌های LSTM، شبکه‌های CNN^۲ و شبکه‌های DNN^۳ بهره گرفته‌ایم.

۵. ارزیابی

در این فصل، به ارزیابی و اعتبارسنجی پیش‌بینی مصرف گاز استان در قالب فشار گاز ایستگاه‌های CGS خواهیم پرداخت و وابستگی آن به تغییرات آب‌وهوا را مورد تحلیل قرار خواهیم داد.


۱.۵. مجموعه داده‌ها

داده‌های جمع‌آوری شده از شرکت گاز استان خراسان جنوبی، شامل اطلاعات مختلف ایستگاه‌های CGS شهرستان‌های مختلف استان است. اطلاعات از سال ۱۳۹۹ لغایت ۱۴۰۲ به‌صورت هر دو دقیقه یک بار اخذ شده است. از آنجاکه فشار گاز در یک روز تغییرات چندانی ندارد، فشار گاز تنها یک نوبت در روز اخذ شده است. بنابراین تعداد داده‌ها ۱۰۹۵ داده است. جدول (۱) اطلاعات آماری داده‌های مورد نظر را خلاصه می‌نماید.

جدول (۱): اطلاعات آماری مجموعه داده‌ای مورد استفاده

آماره	مقدار
تعداد	۱۰۹۵
میانگین	۴۹۶/۲۱
انحراف معیار	۱۰۸/۵۹
بیشینه	۷۶۸
کمینه	۱۳۰

1. Support Vector Regression (SVR)
2. Convolutional Neural Network
3. Deep feedforward neural networks



شکل (۴): روش پیش‌بینی

در گام اول داده‌ها برای ورود بایستی آماده‌سازی شوند. برای این منظور از نرمال‌سازی داده‌ها استفاده می‌کنیم. روشی که برای نرمال‌سازی در این مقاله استفاده شده، روش Z-score است. بدین منظور میانگین و واریانس داده‌ها محاسبه شده و مطابق رابطه (۱) نرمال می‌شوند.

$$x_{new} = \frac{x_{new} - \mu}{\sigma} \quad (1)$$

در این رابطه، μ و σ به ترتیب میانگین و واریانس داده‌هاست.

برای یافتن بهترین ترکیب وابستگی ورودی‌ها و خروجی‌ها پنج سناریو شامل ترکیب‌های مختلف به شکل زیر را در نظر می‌گیریم:

۱. فشار گاز فقط تابع فشار در روز قبل است: $P_{t+1}=f(P_t)$


۲. فشار گاز تابع فشار در روز قبل و روز ماقبل آن است:

$$P_{t+1}=f(P_t, P_{t-1})$$

۳. فشار گاز تابع فشار در روز قبل و دما در روز ماقبل آن است:

$$P_{t+1}=f(P_t, T_t)$$

برای اطمینان از صحت آموزش مدل‌های یادگیری ماشین، شکل (۵) نمودار خطای MSE را برای داده‌های آموزش و همچنین اعتبارسنجی در جریان یادگیری روش DNN را نشان می‌دهد.



شکل (۵): خطای MSE برای آموزش روش DNN

مطابق نتایج شکل (۵)، با افزایش تکرارهای مدل یادگیری، خطای یادگیری کاهش یافته و در ادامه ثابت مانده است؛ لذا می‌توان از صحت انجام این گام اطمینان حاصل نمود. به علاوه، خطای گام آموزش مدل‌ها نیز در جدول (۳) گزارش شده است.

جدول (۳): خطای MSE آموزش مدل در سناریوهای مختلف

سناریو	SVR	LSTM	CNN	DNN
۱	۳۷۰۲/۹۸	۱۵۷۹۹۶/۷۱	۲۶۲۹/۱۱	۲۵۹۱/۸۴
۲	۴۴۴۵/۰۱	۱۴۹۱۸۰/۶۹	۲۷۱۲/۱۸	۱۹۷۹/۵۸
۳	۴۴۰۵/۹۲	۱۴۴۰۵۰/۰۷	۲۶۳۳/۳۶	۲۶۰۹/۲۲
۴	۵۲۳۹/۷۸	۱۵۰۵۱۷/۹۴	۲۶۴۸/۰۸	۱۹۷۱/۴۱
۵	۴۰۹۸/۰۲	۹۴۹۱۲/۳۸	۲۲۳۱/۰۵	۱۸۰۸/۴۱

همان‌طور که مشاهده می‌شود، در سناریوی پنجم کمترین خطای آموزش را دریافت کرده‌ایم؛ لذا به‌منظور پیش‌بینی فشار در یک روز خاص بهترین نتیجه وقتی حاصل می‌شود که فشار گاز طی در سه روز گذشته (سناریوی ۵) و دما به‌عنوان فاکتورهای تأثیرگذار لحاظ شوند. به‌علاوه، روش DNN به‌عنوان مدل یادگیری عملکرد بهتری نسبت به سایر روش‌ها گزارش نموده است. جدول (۴) خطای MSE را برای داده‌های تست را نمایش می‌دهد.

جدول (۴): خطای MSE تست مدل در سناریوهای مختلف پیش‌بینی

سناریو	SVR	LSTM	CNN	DNN
۱	۸۴۹/۴۸	۱۰۲۹/۲۱	۸۲۴/۴۹	۸۱۶/۲۶
۲	۸۱۰/۲۶	۸۲۷/۶۵	۸۱۸/۴۱	۸۰۰/۸۴
۳	۸۵۷/۵۷	۹۰۰/۳۶	۸۴۴/۱۳	۸۳۰/۴۹
۴	۷۴۴/۴۰	۷۵۳/۰۶	۷۷۰/۷۹	۷۴۰/۲۰
۵	۷۰۰/۱۸	۷۳۰/۶۹	۶۸۷/۱۲	۶۷۶/۷۳

هدف این پژوهش پیش‌بینی فشار ورودی ایستگاه‌های CGS است که بیانگر میزان مصرف گاز نیز می‌باشد.

۲.۵. نتایج

در گام اول بایستی از بین سناریوهای ذکرشده در بخش پیشین برای پیش‌بینی فشار، بهترین سناریو را انتخاب کنیم. انتخاب بهترین سناریو به ما کمک می‌کند تا نتیجه‌گیری کنیم کدام متغیرها تأثیر بیشتری بر پیش‌بینی فشار دارد. بدین منظور داده‌های موجود را به هریک از پنج سناریوی گفته‌شده تبدیل می‌کنیم. سپس آن‌ها را به دو دسته آموزش (۸۰٪ داده‌ها) و تست (۲۰٪ باقی‌مانده) جدا نموده و دقت را برای روش‌های مختلف محاسبه می‌کنیم. البته باید توجه داشت که مدل‌های یادگیری در زبان برنامه‌نویسی MATLAB از بخشی از داده‌های آموزش (برای نمونه در روش DNN، ۲۰٪) به‌منظور اعتبارسنجی استفاده می‌کند. شایان ذکر است هر آزمایش را برای چهار مدل یادگیری ماشین ذکرشده یعنی SVR، LSTM، CNN و DNN انجام می‌دهیم. جدول (۲) معماری روش‌های مورد استفاده را خلاصه می‌نماید.

جدول (۲): معماری مدل‌های استفاده‌شده

مدل	معماری
SVR	کرنتل RBF. $\epsilon=0.01$ و $C=100$
LSTM	یک لایه LSTM با ۶۴ نرون و تابع فعال‌سازی tanh، یک لایه Dropout با نرخ ۰/۲ برای جلوگیری از بیش‌برازش، و یک لایه Dense با ۳۲ نرون و تابع فعال‌سازی ReLU
CNN	یک لایه پیش‌بینی ^۱ (Conv1D) با ۳۲ فیلتر و کرنتل 1×3 ، یک لایه MaxPooling با اندازه 1×2 ، یک لایه Flatten، و یک لایه Dense با ۶۴ نرون و تابع فعال‌سازی ReLU
DNN	یک لایه Dense با ۱۲۸ نرون و تابع فعال‌سازی ReLU، یک لایه Dropout با نرخ ۰/۳، و یک لایه Dense دیگر با ۶۴ نرون


همچنین برای آموزش مدل‌های یادگیری عمیق، از الگوریتم بهینه‌سازی Adam با نرخ یادگیری ۰/۰۰۱ استفاده شده است. تعداد اپیزودهای آموزشی برابر ۱۰۰ و اندازه دسته برابر ۳۲ در نظر گرفته شده است. تابع هزینه مورد استفاده برای مدل‌های رگرسیونی، میانگین مربعات خطا بوده است. برای جلوگیری از بیش‌برازش، لایه‌های Dropout با نرخ ۰/۲ تا ۰/۳ به کار گرفته شده‌اند. همچنین، از Early Stopping با آستانه ۱۰ اپیزود بدون بهبود استفاده شده است تا از اجرای غیرضروری آموزش جلوگیری شود.

۶. نتیجه‌گیری و کارهای آینده

استفاده از یادگیری ماشین و هوش مصنوعی برای پیش‌بینی مصرف گاز طبیعی دارای اهمیت بسیاری است و می‌تواند در بهبود برنامه‌ریزی و مدیریت بهینه مصرف این منبع انرژی تأثیرگذار باشد. این فناوری‌ها می‌توانند در جوانب مختلف تأمین و مصرف گاز طبیعی کمک نمایند. پیش‌بینی الگوی مصرف گاز نقش بسیار مهمی در موازنه عرضه و تقاضا، ارائه الگوهای موفق برای مدیریت این انرژی، جلوگیری از قطع گاز مشترکین خانگی و صنایع و حتی مسائل امنیتی و سیاسی دارد. در این مقاله، مسئله پیش‌بینی مصرف گاز در قالب پیش‌بینی فشار گاز ورودی CGS و رابطه آن با تغییرات آب‌وهوا مد نظر قرار گرفت. دلیل در نظر گرفتن فشار گاز ورودی آن است که پژوهش‌های بسیاری مصرف گاز مشترکین را مورد بررسی قرار داده، اما به این نتیجه نرسیده‌اند که فشار گاز تابعی از دما نیست، به این علت که در تابستان که مصرف مشترکین خانگی کمتر می‌شود، سهم بیشتری نصیب صنایع می‌شود. برعکس در زمستان، با افزایش مصارف خانگی سهم صنایع کاهش می‌یابد. در این مقاله سؤال ابتدایی آن بود که آیا فشار گاز تابعی از تغییرات آب‌وهوایی است یا خیر. با توجه به یافته‌های تحقیق مشاهده شد در نظر گرفتن دما در پیش‌بینی فشار مؤثر است. سناریوهای مختلف پیش‌بینی و روش‌های گوناگون یادگیری ماشین بررسی گردید و بهترین سناریو برای آموزش و تست مدل معرفی گردید. در نهایت، پیش‌بینی در افق‌های یک هفته، یک ماه و یک سال صورت پذیرفت. ذکر این نکته ضروری است که هرچه بازه پیش‌بینی بیشتر شود، دقت مدل کمتر خواهد شد. برای مثال پیش‌بینی هواشناسی برای روز آینده دقت بالاتری به نسبت هفته آینده دارد.


به‌عنوان کار آینده می‌توان عوامل بیشتری به غیر از تغییرات آب‌وهوایی را به‌عنوان ورودی سیستم یادگیری در نظر گرفت. به‌خوبی می‌دانیم که مصرف گاز تابع عوامل متعددی از فنی گرفته تا غیرفنی و حتی سیاسی است. در نظر گرفتن این عوامل علاوه بر اینکه نیازمند تحلیل‌های مخصوص به خود است، یادگیری ماشین را نیز با چالش‌هایی روبه‌رو می‌کند که می‌تواند بسیار جذاب باشد. به‌علاوه در این پژوهش با سعی و خطا تعداد روزهایی که برای پیش‌بینی آینده مورد استفاده قرار گرفت، سه روز بود. می‌توان از تحلیل حساسیت برای بررسی تأثیر تعداد روزهای گذشته بر دقت مدل استفاده کرد و بازه بهینه را به دست آورد.

مطابق اطلاعات جدول (۴)، روش DNN در گام تست بهترین نتایج را در سناریوی ۵ ارائه نموده است. شکل (۶) نمودار مقادیر واقعی و پیش‌بینی شده فشار را برای داده‌های تست نمایش می‌دهد. همان‌گونه که مشخص است، عملکرد روش DNN در پیش‌بینی مطابق این شکل بسیار مناسب بوده است.



شکل (۶): مقادیر پیش‌بینی‌شده در مقابل مقادیر واقعی فشار

حال در گام آخر، مدل آموزش دیده‌شده که از صحت و نحوه عملکرد مطلوب آن مطمئن شده‌ایم، برای پیش‌بینی افق آینده و داده‌های دیده‌نشده استفاده می‌شود. شکل (۷) نتایج مدل آموزش دیده‌شده برای پیش‌بینی فشار گاز ایستگاه CGS شهرستان بیرجند طی یک سال آینده را نمایش می‌دهد.



شکل (۷): پیش‌بینی فشار گاز برای یک سال آینده

آنچه مشخص است، مطابق پیش‌بینی تمام پدیده‌های طبیعی، هرچه بازه پیش‌بینی طولانی‌تر در نظر گرفته شود، خطای پیش‌بینی نیز بیشتر می‌شود. در مسائل سری زمانی از جمله مسئله حاضر از آنجاکه مبنای پیش‌بینی فشار گاز برای روزهای آینده، فشار گاز در روزهای پیشین است و فشار گاز در روزهای گذشته نیز خود حاصل پیش‌بینی مدل است، خطای حاصل از پیش‌بینی انتشار می‌یابد. به زبان دیگر، باید گفت پیش‌بینی برای روزهای آینده به واقعیت نزدیک‌تر خواهد بود تا ماه‌های آینده.

سیاسگزاری

سفارش شرکت گاز استان خراسان جنوبی در چارچوب قرارداد تحقیقاتی- پژوهشی به شماره ۱۴۰۲/۰۰۲/۵ و با حمایت معاونت پژوهش و فناوری دانشگاه صنعتی بیرجند به انجام رسیده است.

این مقاله مستخرج از طرح پژوهشی با عنوان «پیش‌بینی روند تغییرات مصرف گاز استان خراسان جنوبی با تحلیل تغییرات آب‌وهوایی» به

مراجع

- [1] HajiMirzaei, S. M. A., Behrouzifar, M., Bahadori S., Malek Hosseini, A., "Evaluating approved policies in the field of energy and presenting proposed policies to improve energy governance in Iran", Quarterly Energy Economics Review, Vol. 20, pp. 269-305, 2024 (in persian), <http://iiesj.ir/article-1-1617-en.html>
- [2] Hafezi, R., Akhavan, A., Pakseresht, S., "Development a hybrid computational model based on Artificial Neural Network to predict natural gas Global Demand", Energy Engineering and Management, Vol. 8, Issue 4, pp. 38-49, 2019 (in persian), <https://doi.org/10.22052/8.4.38>.
- [3] Sepehrifar, H., Lotfizade, F., Farahmandian, A., "Analysis of main factors of residential gas consumption in Iran", Quarterly Journal of Energy Policy and Planning Research, Vol. 7, No. 4, pp. 1-27, 2022 (in persian), <http://epprjournal.ir/article-1-1077-en.html>.
- [4] Daghbandan, A., Setayesh, N., "Modeling and prediction of natural gas consumption with help of multi objective GMDH-Type Neural Network. Case study: regional gas distribution company of Rasht city", Journal of Energy, Vol. 19, No. 4, 2017 (in persian), <http://necjournals.ir/article-1-831-en.html>.
- [5] Baradaran, V., Shafiei, S., "Development of Markov Chain Grey Regression Model to Forecast the Annual Natural Gas Consumption", Quarterly Journal of Energy Policy and Planning Research, Vol. 15, No. 63, pp. 243-267, 2020 (in persian), <http://iiesj.ir/article-1-1114-en.html>.
- [6] Azami, S., "The relationship between natural gas consumption and economic growth given structural breaks in countries exporting natural gas: an approach using Dumitrescu-Hurlin", Quarterly Journal of Energy Policy and Planning Research, Vol. 14, No. 57, pp. 39-64, 2018, (in persian), <http://iiesj.ir/article-1-968-en.html>.
- [7] Karimi, T., Sadeghi, Moghaddam, M. R., Rahnama, R., "Investigating the effect of temperature changes on natural gas consumption in Iran", Energy Economics Studies, Vol. 24, No. 6, pp. 193-218, 2010 (in persian), <https://ensani.ir/fa/article/70509>.
- [8] Esmaeili, S., "Prediction of natural gas consumption in subscribers of South Khorasan province (Birjand) using deep learning tools", M.S Thesis, Islamic Azad University, Birjand Branch, 2011 (in persian).
- [9] Sun, F., Ren, L., Jin, W., "FastNet: A feature aggregation spatiotemporal network for predictive learning", Engineering Applications of Artificial Intelligence, Vol. 130, p. 107785, 2024, <https://doi.org/10.1016/j.engappai.2023.107785>.
- [10] Wu, X., Zhan, J., Ding, W., "TWC-EL: A multivariate prediction model by the fusion of three-way clustering and ensemble learning", Information Fusion, Vol. 100, p. 101966, 2023, <https://doi.org/10.1016/j.inffus.2023.101966>.
- [11] Ramzan, M., Abbasi, K. R., Iqbal, H. A., Adebayo, T. S., "What's at Stake? The empirical importance of government revenue and debt and renewable energy for environmental neutrality in the US economy", Renewable Energy, Vol. 205, pp. 475-489, Mar. 2023, <https://doi.org/10.1016/j.renene.2023.01.071>.
- [12] Su, H., Zio, E., Zhang, J., Xu, M., Li X., Zhang, Z., "A hybrid hourly natural gas demand forecasting method based on the integration of wavelet transform and enhanced Deep-RNN model", Energy, Vol. 178, pp. 585-597, 2019, <https://doi.org/10.1016/j.energy.2019.04.167>.
- [13] Hribar, R., Potočnik, P., Šilc, J., Papa, G., "A comparison of models for forecasting the residential natural gas demand of an urban area", Energy, Vol. 167, pp. 511-522, 2019, <https://doi.org/10.1016/j.energy.2018.10.175>.
- [14] Du, J., et al., "A knowledge-enhanced graph-based temporal-spatial network for natural gas consumption prediction", Energy, Vol. 263, p. 125976, 2023, <https://doi.org/10.1016/j.energy.2022.125976>.
- [15] Du, J., et al., "A hybrid deep learning framework for predicting daily natural gas consumption", Energy, Vol. 257, p. 124689, 2022, <https://doi.org/10.1016/j.energy.2022.124689>.
- [16] Singh, S., Bansal, P., Hosen, M., Bansal, S. K., "Forecasting annual natural gas consumption in USA: Application of machine learning techniques-ANN and SVM", Resources Policy, Vol. 80, p. 103159, 2023, <https://doi.org/10.1016/j.resourpol.2022.103159>.
- [17] Li, N., Wang, J., Wu, L., Bentley, Y., "Predicting monthly natural gas production in China using a novel grey seasonal model with particle swarm optimization", Energy, Vol. 215, p. 119118, 2021, <https://doi.org/10.1016/j.energy.2020.119118>.
- [18] Honari, E., Yaghini, M., Nadimi, M. H., "Forecasting the natural gas consumption in residential and commercial sectors of Isfahan for five years using Artificial Neural Networks", Research in Production and Operations

- Management, Vol. 7, No. 1, pp. 247-262, 2016, <https://doi.org/10.22108/jpom.2016.20922>.
- [19] Doust Mohammadi, A., Sharifi Rad, R., Akbarpour, M., Akarpour, S., "Prediction of natural gas consumption of household customers using data mining procedures, case study: Kerman Gas Company", The First National Conference on Modern and Smart Business Data Mining and Image Processing, 2018 (in persian).
- [20] Hornik, K., "Approximation capabilities of multilayer feedforward networks", Neural Networks, Vol. 4, No. 2, pp. 251-257, 1991, [https://doi.org/10.1016/0893-6080\(91\)90009-T](https://doi.org/10.1016/0893-6080(91)90009-T).
- [21] Lu, Z., Pu, H., Wang, F., Hu, Z., Wang, L. "The expressive power of neural networks: A view from the width", Advances in Neural Information Processing Systems (NeurIPS), 30, 2017, <https://doi.org/10.1145/3326365.3326379>.
- [22] Goodfellow, I., Bengio, Y., Courville, A. "Deep learning", MIT press, 2016.
- [23] Bengio, Y., Delalleau, O., Le, Roux N., "The curse of highly variable functions for local kernel machines", in Proceedings of the 18th International Conference on Neural Information Processing Systems, in NIPS'05. Cambridge, MA, USA: MIT Press, pp. 107-114, 2005, <https://doi.org/10.1016/j.jmlr.2005.10.001>.
- [24] Goodfellow, I. J., Le, Q., Saxe, A. M., Lee, H., Ng, A. Y., "Measuring invariances in Deep Networks", in Proceedings of the 22Nd International Conference on Neural Information Processing Systems, in NIPS'09. USA: Curran Associates Inc., pp. 646-654, 2009, <https://doi.org/10.5555/2999792.2999851>.
- [25] Bengio, Y., Courville, A., Vincent, P., "Representation learning: a review and new perspectives", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 35, No. 8, pp. 1798-1828, 2013, <https://doi.org/10.1109/TPAMI.2013.50>.
- [26] Olshausen, B. A., Field, D. J. "Sparse coding with an overcomplete basis set: A strategy employed by V1?", Vision Research, Vol. 37, No. 23, pp. 3311-3325, 1997, [https://doi.org/10.1016/S0042-6989\(97\)00169-7](https://doi.org/10.1016/S0042-6989(97)00169-7).
- [27] Demir, V., Yaseen, Z. M., "Neurocomputing intelligence models for lakes water level forecasting: a comprehensive review", Neural Computing and Applications, Vol. 35, pp. 303-343, <https://doi.org/10.1007/s00521-022-07699-z>.
- [28] Ruma, J. F., Adnan, M. S. G., Dewan, A., Rahman, R. M., "Particle swarm optimization based LSTM networks for water level forecasting: A case study on Bangladesh river network", Results in Engineering, Vol. 17, p. 100951, 2023, <https://doi.org/10.1016/j.rineng.2023.100951>.