

پیش‌بینی تقاضای گاز طبیعی بر مبنای مدل‌سازی با استفاده از روش شبکه‌های عصبی در منطقه گرم و خشک بر مبنای داده‌های هواشناسی

شعیب خان‌محمدی^{*}، ـ صابر خان‌محمدی^۱

چکیده

تاریخ دریافت:
۱۳۹۶/۷/۴

تاریخ پذیرش:
۱۳۹۶/۱۱/۲

کلمات کلیدی:
داده‌های هواشناسی،
پیش‌بینی،
گروه بندی داده‌های عددی،
صرف گاز طبیعی

نیاز به پیش‌بینی و الگویابی مصرف گاز به خصوص در فصول سرد سال جهت مدیریت مصرف و سیاست گذاری و برنامه ریزی امری ضروری می‌باشد. در بخش مصارف مسکونی و تجاری که بخش عمده‌ای از مصرف گاز در کشور را به خود اختصاص می‌دهد، تأثیرات متغیرهای هواشناسی بیشترین اثر را بر مصرف دارند. در این تحقیق چهار متغیر متوسط دمای روزانه (T_m)، متوسط رطوبت نسبی روزانه (φ)، ساعات آفتابی در روز (sn) و متوسط سرعت باد (W) برای پیش‌بینی مصرف در بازه زمانی کوتاه مدت استفاده شده است. نتایج برای سه شهر ایلام، ایوان و مهران به شکل معادلات چند جمله‌ای درجه دوم و بر حسب متغیرهای فوق به دست آمده است. نتایج نشان می‌دهد که سه مدل به دست آمده بر مبنای میانگین ریشه مربعات خطای نرمال شده به ترتیب دارای مقدار ۰/۲۱ و ۰/۱۲۳ و ۰/۱۱۲ می‌باشند که مقدار مطلوبی می‌باشد.

۱. مقدمه

گاز به عنوان یکی از مهمترین بخش‌های انرژی چه در کشور و چه در سطح جهانی، مطرح است. اهمیت این موضوع را می‌توان از استقبال روز افزون کشورها و دولتها به تأمین انرژی خود از این سوخت در مقابل سوخت‌های سنتی همچون نفت دید. گاز طبیعی یکی از اصلی‌ترین منابع انرژی در کشور بوده و مزایای آن، مصرف این سوخت را در سال‌های اخیر به میزان زیادی افزایش داده است. از آن جایی که این سوخت اصلی‌ترین منبع انرژی در سبد تأمین انرژی به خصوص در مصارف خانگی و صنعتی می‌باشد، پیش‌بینی تقاضای گاز طبیعی در امر سیاست‌گذاری، برنامه‌ریزی و تدارک امکانات و زیرساخت‌های لازم جهت تهییه و توزیع پایدار گاز طبیعی مورد نیاز مشترکین جایگاه ویژه‌ای دارد. گاز طبیعی بیش از ۵۰ درصد مصرف بخش خانگی و تجاری و ۴۵ درصد بخش صنعتی و ۷۰ درصد نیروگاه‌ها و پالایشگاه‌های کشور را تأمین می‌کند.

پیش‌بینی مصرف گاز طبیعی و برآورد نزدیک به مقدار دقیق گاز مصرفی بهخصوص در فصول سرد سال به شکل قابل ملاحظه‌ای می‌تواند در مدیریت مصرف گاز، جلوگیری از قطعی گاز مشترکان و تأمین مطلوب انرژی تاثیر داشته باشد. از مزایای دیگر استفاده از مدل‌های ریاضیاتی جهت تخمین مصرف گاز طبیعی، مدیریت بهتر تاسیسات انتقال و توزیع گاز و بهره وری بیشتر از تاسیسات موجود می‌باشد. آگاهی از مصرف انرژی و توانایی پیش‌گویی مصارف آتی همچنین می‌تواند در مدیریت بحران و مقابله با عدم تأمین گاز پایدار در این شرایط تاثیر بسزایی داشته باشد. اغلب مطالعات صورت گرفته جهت پیش‌بینی مصرف گاز طبیعی بر پایه متغیرهایی مانند درآمد و قیمت بوده و توجه کمتری به متغیرهایی همچون تعییرات آب و هوایی و پارامترهایی مانند دمای متوسط، رطوبت هوا، سرعت باد و دیگر متغیرها شده است [۱]. پیش‌بینی مصرف گاز می‌تواند در بازه‌های کوتاه مدت، میان مدت و بلند مدت صورت بگیرد. در بازه‌های کوتاه مدت پیش‌بینی می‌تواند از یک روز تا یک ماه انجام بگیرد هم چنین در بازه‌های بلند مدت پیش‌بینی ها می‌تواند از چند سال تا چند دهه تعییر پیدا کند [۲]. با توجه به این موضوع که توسعه مصرف کنندگان همواره بیشتر از توسعه شبکه و زیرساخت‌های مربوط به انتقال و توزیع شبکه گاز می‌باشد این امر منجر به مشکلاتی در فصول سرد زمستان جهت تأمین گاز گردد. پیشگیری از مشکلات ذکر شده نیازمند برنامه‌ریزی تولید همسو با تعییرات مصرف می‌باشد.

موارد متعددی در مورد استفاده از شبکه‌های عصبی وجود دارد که به مطالعه عددی داده‌های موجود برای پیش‌بینی خواص نانو مواد تولید شده، پیش‌بینی رفتار مواد پلیمری و پیش‌بینی مصرف گاز توسط محققان مختلف [۵-۳] ارایه شده است. میبدی و مهرجردی [۶] به مطالعه الگوسازی و پیش‌بینی مصرف انرژی بخش حمل و نقل با استفاده از الگوهای هوش مصنوعی پرداختند. آن‌ها با استفاده از داده‌های سالیانه مصرف انرژی بخش حمل و نقل کشور به عنوان متغیر خروجی الگوهای پیش‌بینی و از داده‌های سالیانه جمعیت کل کشور تولید ناخالص داخلی، و تعداد خودروها به عنوان متغیر ورودی الگوی پیش‌بینی استفاده نمودند. در این تحقیق دقت نتایج پیش‌بینی الگوهای مختلف، با استفاده از شاخص‌های ارزیابی مقایسه گردید. نتایج ارزیابی آن‌ها نشان داد که الگوی شبکه عصبی فازی، نسبت به سایر الگوها از بیشترین دقت در پیش‌بینی مصرف انرژی در بخش حمل و نقل کشور برخوردار است. همچنین براساس نتایج تحلیل حساسیت ورودی‌ها به وسیله شبکه عصبی، ورودی جمعیت کشور به عنوان ورودی شناخته شد که بیشترین تأثیر را در مصرف انرژی دارد.

در یک تحقیق عصاری و همکاران [۷] از دو مدل نمایی و خطی برای برآورد تقاضای گاز طبیعی در ایران استفاده کردند. مدل‌های ارایه شده بر اساس شاخص‌های جمعیت، تولید ناخالص داخلی و ارقام وارداتی و صادراتی ارایه شده بودند. در این تحقیق داده‌های سال‌های ۱۹۸۱ تا ۱۹۹۹ برای مدل‌سازی استفاده شده بود. صادقی و موسویان [۸] با استفاده از الگوریتم ژنتیک و ازدحام ذرات برای داده‌های ما بین سال‌های ۱۳۸۱ تا سال ۱۳۸۸ مدلی برای پیش‌بینی مصرف ماهانه گاز طبیعی بخش خانگی طی سال‌های ۱۳۸۹ تا ۱۳۹۰ با فاصله اطمینان ۹۵ درصد به دست آوردن. ابریشمی و همکاران [۹] مطالعه تقاضای گاز طبیعی در بخش خانگی - تجاری، صنعت و نیروگاه که جزء مصرف کنندگان عمده گاز طبیعی هستند، را انجام دادند. آن‌ها از دو روش ARIMA و دسته بندی داده‌های عددی GMDH برای پیش‌بینی تقاضای مصرف گاز استفاده کردند. در تحقیق مذکور از معیار میانگین مربعات خطای MSE و ریشه میانگین مربعات خطای RMSE برای مقایسه دو روش و سنجش دقت دو مدل استفاده شده بود. نتایج آن‌ها نشان داد که روش دسته بندی داده‌های عددی دارای دقت بیشتری در پیش‌بینی مصرف گاز طبیعی می‌باشد.

بررسی‌های مطالعات انجام شده نشان می‌دهد، در سال‌های اخیر مطالعات گسترده‌ای با استفاده از روش‌های مبتنی بر شبکه‌های عصبی (ANN) جهت استحصال توابع مفید با متغیرهای گوناگون

برای پیش‌بینی پدیده‌ها در علوم مختلف به کار گرفته شده است. در این مطالعه با استفاده از روش دسته‌بندی داده‌های عددی که توانایی مناسبی در مدلسازی داده‌های گستته دارد، برای تعیین توابع پیش‌بینی کننده مصرف گاز طبیعی بر اساس پارامترهای جوی نظری، میانگین دمای روزانه، رطوبت هوای ساعات آفتابی در روز و سرعت باد که بیشترین تاثیر را بر روی مصرف گاز دارند، به کار گرفته شده است. در ادامه به ارایه مبانی مدل دسته‌بندی گروهی داده‌های عددی پرداخته می‌شود.

۲. روش دسته‌بندی گروهی داده‌های عددی

الگوریتم دسته‌بندی داده‌های عددی، یک روش ساده خود سازمانده است که به تدریج مدل‌های پیچیده‌تر بر اساس ارزیابی عملکرد آن‌ها و مجموعه‌ای از داده‌های با چند ورودی و یک خروجی از آن طی سال‌های اخیر پیشنهاد شده است. روش دسته‌بندی گروهی داده‌ها یک الگوریتم چند لایه‌ای ترکیبی است که لایه‌ها و گره‌ها با استفاده از جریانی از داده‌ها ارزیابی می‌شوند. هدف استفاده از این روش به دست آوردن یک مدل ریاضیاتی برای داده‌ها تحت بررسی است. این روش به صورت انطباقی مدل‌هایی از داده‌ها را به شکل شبکه‌های بهینه شده‌ای از توابع انتقالی به صورت تولید لایه‌های مختلف ایجاد می‌کند. با استفاده از این الگوریتم، یک مدل می‌تواند توسط مجموعه‌ای از نرون‌ها مجموعه‌های جفتی که در هر لایه هستند توسط چند جمله‌ای‌های درجه دوم به هم متصل شده و بنابراین نرون‌های جدید در لایه‌های جدید تولید می‌شوند. این نوع نمایش می‌تواند به عنوان یک نگاشت ورودی به خروجی به کار گرفته شود. یک تعریف کلاسیک برای مساله یافتن تابع f است که به طور تقریبی بتواند مقدار \hat{y} را تقریب بزند. به طوری که برای ورودی $(x_1, x_2, x_3, \dots, x_n)$ به عنوان نزدیکترین تقریب به مقدار واقعی y تعریف می‌شود. بنابراین با توجه به M مشاهده چند ورودی و یک خروجی برای جفت داده‌ها داریم:

$$(1) \quad y_i = f(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) \quad i = 1, 2, \dots, M$$

اکنون این امکان وجود دارد که یک شبکه عصبی از نوع GMDH برای تخمین خروجی‌های \hat{y} برای هر بردار ورودی $(x_1, x_2, x_3, \dots, x_n)$ که به صورت زیر است استفاده شود:

$$(2) \quad \hat{y}_i = \hat{f}(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) \quad i = 1, 2, \dots, M$$

اکنون مساله تعیین یک شبکه عصبی از نوع GMDH است به طوری که مربعات اختلاف بین خروجی‌های واقعی و مقادیر تخمین زده مینیمم شود به نحوی که داشته باشیم [۱۰]:

$$\sum_{i=1}^M [\hat{f}(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) - y_i]^2 \rightarrow 0 \quad (3)$$

کامل ترین فرم ریاضیاتی می‌تواند توسط یک سیستم چند جمله‌ای درجه دوم جزیی مشکل از دو متغیر (نرون) توسط سری‌های تابعی ولترا^۱ معروف به چند جمله‌ای کولموگروف-گابور به شکل زیر نشان داده شود.

$$y = a_0 + \sum_{i=1}^n a_i x_i + \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n a_{ijk} x_i x_j x_k + \dots \quad (4)$$

که در آن a_0, a_i, a_j و a_{ijk} ثابت‌ها و x_i, x_j و ورودی‌ها و y خروجی می‌باشد. کامل ترین شکل می‌تواند توسط سیستم چند جمله‌ای که از دو متغیر (نرون) تشکیل شده است به شکل زیر نمایش داده شود.

$$\hat{y} = G(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i^2 + a_4 x_j^2 + a_5 x_i x_j \quad (5)$$

در این جاییک روش پیشخوان از شبکه‌های عصبی از نوع GMDH استفاده شده است. ضریب a_i در معادله فوق با استفاده از روش رگرسیون محاسبه می‌شود به طوری که اختلاف بین مقادیر واقعی y و مقدار تخمین زده شده \hat{y} برای هر جفت ورودی (x_i, x_j) کمترین مقدار شود [۱۱]. به طور قطع درخت چند جمله‌ای‌ها با استفاده از رابطه درجه دوم (معادله ۵) ساخته می‌شود مطابق با کمترین مقدار مربعات خطأ می‌باشد. در این حالت ضرایب هر کدام از توابع چند جمله‌ای G_i ‌ها طوری به دست می‌آیند که برای همه مجموعه‌های ورودی خروجی به طور بهینه مناسب می‌باشد به طوری که:

$$E = \frac{\sum_{i=1}^M [y_i - G_i()]^2}{\sum_{i=1}^M y_i^2} \rightarrow \min \quad (6)$$

در حالت کلی در الگوریتم GMDH همه احتمالات ترکیب دو متغیر مستقل از تعداد n پارامتر ورودی برای ساخت چند جمله‌ای درجه دوم رگرسیون به شکل معادله (۵) به کار گرفته می‌شود تا بهترین برازش بسته به مشاهدات با معیار کمترین مربعات خطأ شکل بگیرد در نتیجه:

$$\binom{n}{2} = \frac{n(n-1)}{2} \quad (7)$$

نرون ها که در لایه دوم ساخته شده به صورت مجموعه زیر است.

$$\{(y_i, x_{ip}x_{iq}) | (i = 1, 2, \dots, M) \text{ and } p, q \in (1, 2, \dots, M)\} \quad (8)$$

شکل چند جمله‌ای تابع بیان شده در معادله (5) برای مجموعه M تایی را می‌توان به صورت زیر نشان داد.

$$Aa = Y \quad (9)$$

که در آن A بردار ضرایب مجھول چند جمله‌ای معادله (5) به صورت زیر می‌باشد.

$$a = \{a_0, a_1, a_2a_3, a_4, a_5\} \quad (10)$$

$$Y = \{y_1, y_2, y_3, \dots, y_M\}^T \quad (11)$$

برای M سری داده آزمایشی ماتریس ضرایب به صورت زیر تعیین می‌شود [۱۲].

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}^2 & x_{1q}^2 & x_{1p}x_{1q} \\ 1 & x_{2p} & x_{2q} & x_{2p}^2 & x_{2q}^2 & x_{2p}x_{2q} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ 1 & x_{Mp} & x_{Mq} & x_{Mp}^2 & x_{Mq}^2 & x_{Mp}x_{Mq} \end{bmatrix} \quad (12)$$

با استفاده از تحلیل رگرسیون و روش کمترین مربعات خطای می‌توان نوشت:

$$a = (A^T A)^{-1} A^T Y \quad (13)$$


رابطه فوق بردار مجھول ها را که شامل M عضو می‌باشد نشان می‌دهد.

۳. الگوریتم ژنتیک برای حل مسائل

روش‌های تکاملی مانند الگوریتم ژنتیک در مراحل مختلف طراحی شبکه‌های عصبی با توجه به توانایی‌های منحصر به فرد آن‌ها در پیدا کردن مقادیر مطلوب و توانایی جستجو در فضاهای غیر قابل


پیش‌بینی به طور گستره‌ای مورد استفاده قرار می‌گیرند [۱۳]. با توجه به این که الگوریتم ژنتیک به عنوان یکی از بهترین روش‌های تکاملی برای بهینه سازی شناخته شده است و با توجه به این که در حل‌های دیگر روش‌ها می‌توانند برای حل معادله (۹) منجر به احتمال نقاط تکی نمی‌شود، در مطالعه حاضر برای ایجاد شبکه عصبی و تعیین ضریب آن الگوریتم ژنتیک و روش تجزیه نقاط تکین (SVD) استفاده می‌شود.

در نوع اول از دسته بندی داده‌های عددی نرون‌ها در هر لایه دارای توانایی اتصال به نرون قبلی را دارند که این نوع ساختار دسته بندی متداول دسته بندی داده‌های عددی (Common structure group) معروف است و به صورت زیر نشان داده می‌شود.



شکل ۱. یک ساختار از شبکه متداول GMDH برای یک کروموزوم

در نوع دوم از دسته بندی داده‌های عددی قید استفاده از لایه‌های مجاور برای اتصال نرون‌ها حذف شده است که در این حالت به روش عمومیت یافته دسته بندی داده‌های عددی (Generalized Group of Method Data Handling) معروف است این ساختار را می‌توان به شکل زیر نمایش داد.



شکل ۲. یک ساختار از شبکه عمومیت یافته GMDH برای یک کرموزوم در این تحقیق از ساختار عمومیت یافته روش دسته بندی گروهی داده های عددی برای چند جمله ای ها استفاده شده است.

۴. ورودی ها و خروجی های مساله

با توجه به اینکه عمدۀ مصرف انرژی در بیشتر مناطق ایران در فصول سرد سال به مصارف خانگی و گرمایش منازل مسکونی اختصاص دارد و صنایع پر مصرف نظیر صنایع سیمان و واحد های نیروگاهی در فصل سرد سال از سوخت های جایگزین استفاده می کنند، مصرف گاز در این فصل وابسته به پارامترهایی مانند دمای متوسط محیط (T_m)، رطوبت هوا (φ)، سرعت وزش باد (w) و ساعت آفتابی (d) طی یک روز می باشد. عمدۀ ترین پارامترهایی که در تخمین کوتاه مدت تقاضای گاز می تواند مورد استفاده قرار گیرد متغیرهای مذکور می باشند که به عنوان ورودی های مساله به خوبی از داده های هواشناسی و جغرافیایی هر منطقه قابل دستیابی و پیش بینی با دقت معقولی می باشد. از سوی دیگر، هدف به دست آوردن یک تابع با خروجی تقاضای مصرف است که بتواند با ورودی های دقیق با دقت مناسب تقاضای مصرف گاز را پیش بینی نماید. در این مطالعه از داده های هواشناسی ایلام در بازه زمانی مربوط به داده های موجود برای مصرف گاز استفاده شده است. سه شهر ایلام، ایوان و مهران در این مطالعه به عنوان مطالعه موردي به کار گرفته شده اند و توابع چند جمله ای برای مصارف هر کدام از آن ها با روش دسته بندی گروهی داده های عددی حاصل شده است. در این مطالعه ۳۶۵ سری از داده ها به عنوان داده های آموزش و آزمون استفاده شده اند. همچنین بازه تغییرات متغیرهای موثر بر مصرف گاز برای شهرهای مورد مطالعه در جدول ۱ آورده شده است.

جدول ۱. بازه تغییرات مشخصات آب و هواي شهرهای مورد مطالعه

و مصارف یک ساله مربوط به آن‌ها در بازه سال ۱۳۹۵


	ساعت آفتابی	سرعت وزش باد	مصارف گاز در یک روز (m^3)	دماي ميانگين رطوبت هوا (φ)	(T_m)
ایلام (مطالعه موردي ۱)	۱۰/۵ تا ۱۳/۳	۲۳ تا ۰	۱۲۶۲۷ تا ۱۳۹۹۱۳۵	-۹۲ تا ۳۳/۱۵	۱/۸۵ تا ۱/۱۵
ایوان (مطالعه موردي ۲)	۱۳ تا ۰	۴ تا ۳۰	۱۲۶۴۶ تا ۲۹۲۲۳۳	-۹۰ تا ۳۲/۶	۳/۹ تا ۴/۶
مهران (مطالعه موردي ۳)	۳ تا ۷۹	۲ تا ۲۳	۴۵۴۷ تا ۵۸۸۲۷	۱۲/۹ تا ۴/۷	۴۳/۸ تا ۴۲/۸

لازم به ذکر است که داده‌های جدول مذکور مربوط به اطلاعات روزانه این متغیرها می‌باشد. از داده‌های مورد بررسی ۲۲۰ داده به عنوان داده‌های آموزش و ۱۴۵ داده به عنوان آزمایش استفاده شده است. مرجع داده‌های مورد استفاده برای سازمان هواشناسی و مرجع داده‌های مصرف گاز شرکت ملی گاز می‌باشد.

۵. بحث و بررسی

جهت استخراج مدل مصرف گاز در شهرهای مورد مطالعه داده‌های موجود که ۳۶۵ سری داده آب و هوايی و همچنین مصارف مربوطه می‌باشند، به دو دسته داده آموزش و آزمایش تقسیم بندی شده اند. از این تعداد ۲۲۰ داده به عنوان آموزش و ۱۴۵ داده باقیمانده به عنوان داده آزمایش جهت برآورد شبکه به کار گرفته شده است. ساختار مدل شبکه عصبی در این مطالعه با دو لایه پنهان و ساختار عمومیت یافته GMDH می‌باشد.

شکل ۳ ساختار شبکه عصبی عمومیت یافته از نوع GMDH برای شهر ایلام نشان می‌دهد.



شکل ۳. ساختار شبکه GMDH در پیش‌بینی مصرف گاز برای شهر ایلام

با استفاده از ساختار بهینه به دست آمده برای الگوی مصرف گاز در شهر ایلام رابطه بازگشتی مربوط به پیش بینی مصرف گاز برای شهر ایلام با رابطه زیر نشان داده می شود.

$$\begin{aligned}
 g_{14} &= a_{01} + a_{11}(T) + a_{21}(W) + a_{31}(T)^2 + a_{41}(W)^2 \\
 &\quad + a_{51}(T)(W) \\
 g_{12} &= a_{02} + a_{12}(T) + a_{22}(\varphi) + a_{32}(T)^2 + a_{42}(\varphi)^2 + a_{52}(T)(\varphi) \\
 g_{24} &= a_{03} + a_{13}(\varphi) + a_{23}(W) + a_{33}(\varphi)^2 + a_{43}(W)^2 \\
 &\quad + a_{53}(\varphi)(W) \\
 g_{1412} &= a_{04} + a_{14}(g_{14}) + a_{24}(g_{12}) + a_{34}(g_{14})^2 + a_{44}(g_{12})^2 \\
 &\quad + a_{54}(g_{14})(g_{12}) \\
 g_{2433} &= a_{05} + a_{15}(g_{24}) + a_{25}(s) + a_{35}(g_{24})^2 + a_{45}(s)^2 \\
 &\quad + a_{55}(g_{24})(s) \\
 Demand_{Case1} &= a_{06} + a_{16}(g_{1412}) + a_{26}(g_{2433}) + a_{36}(g_{1412})^2 \\
 &\quad + a_{46}(g_{2433})^2 + a_{56}(g_{1412})(g_{2433})
 \end{aligned} \tag{۱۴}$$


همچنین ضرایب a_{ij} در رابطه بالا ضرایب ثابتی هستند که از جدول ۴ برای معادله فوق می توانند استفاده گردد.

جدول ۴. ضرایب ثابت معادله (۱۴)

پارامتر	مقادیر	پارامتر	مقادیر
a_{01}	1170735.256906212	a_{02}	711185.4264309588
a_{11}	80182.5938242690	a_{12}	-0.393208281384486
a_{21}	15298.9926507960	a_{22}	11450.7225021550
a_{31}	1596.288517697	a_{32}	799.3379311509
a_{41}	63.508969401	a_{42}	43.5228806240
a_{51}	-638.318311776	a_{52}	-502.3350874745
a_{03}	622525.1403441339	a_{04}	0.000002793214340
a_{13}	-9134.2904155100	a_{14}	0.484420694061971
a_{23}	-89191.7477941498	a_{24}	0.495866048833850
a_{33}	235.4194451153	a_{34}	-0.000000748166313
a_{43}	6705.3689287391	a_{44}	0.000000378668599
a_{53}	-694.4748135826	a_{54}	0.000001151985093

پارامتر	مقادیر	پارامتر	مقادیر
a_{05}	0.000001869326129	a_{06}	0.000006601483525
a_{15}	0.320354529890260	a_{16}	1.156730830928475
a_{25}	0.000009728680233	a_{26}	-0.151111344514388
a_{35}	0.000000802736807	a_{36}	-0.000000148244217
a_{45}	0.000093074129711	a_{46}	0.000000035114694
a_{55}	0.041161237073063	a_{56}	0.000000195979646


رابطه (۱۴) یک تابع با چند متغیر را نشان می‌دهد که با استفاده از پارامترهای میانگین دمای روزانه، رطوبت نسبی هوای ساعتی آفتابی در روز و سرعت باد، مقدار تقاضای مصرف را برآورد می‌کند. برای نشان دادن دقیقی مدل مقادیر واقعی تقاضای گاز طبیعی با مقادیر حاصل شده از تابع مدل شده نشان داده شده است.



شکل ۴. داده‌های خروجی بدست آمده از مدل و داده‌های مصارف واقعی گاز


ضریب تعیین (R^2) نشان می‌دهد که چند درصد تغییرات متغیر وابسته به وسیله متغیر مستقل تبیین می‌شود یا به عبارت دیگر ضریب تعیین نشان دهنده این است که چه مقدار از تغییرات متغیر وابسته تحت تاثیر متغیر مستقل مربوطه بوده و مابقی تغییرات متغیر وابسته مربوط به سایر عوامل می‌باشد. این ضریب در واقع نتایج تقریبی پارامتر موردنظر در آینده را براساس مدل ریاضی تعریف شده

که منطبق بر داده‌های موجود است، بیان می‌دارد. شکل ۵ پیش‌بینی مقادیر با استفاده از مدل استخراج شده و مقادیر واقعی مصرف گاز را با ضریب تعیین $R^2 = 0.8356$ نشان می‌دهد.



شکل ۵. مقایسه داده‌های استخراج شده از مدل و داده‌های واقعی مصرف گاز
با مقدار ضریب تعیین $R^2 = 0.8356$ برای شهر ایلام

شکل ۶ ساختار شبکه عصبی عمومیت یافته از نوع **GMDH** را برای شهر ایوان نشان می‌دهد.



شکل ۶. ساختمان شبکه **GMDH** در پیش‌بینی مصرف گاز برای شهر ایوان

برای شهر ایوان که نمونه‌ای از یک شهر سردسیر با مشخصه‌های متفاوت با شهر ایلام است با به کارگیری داده‌های مصرف گاز طبیعی و اطلاعات آب و هوایی طی سال ۱۳۹۴، بر پایه شبکه عصبی از نوع دسته بندی داده‌های عددی یک مدل ریاضیاتی برای مصرف گاز استخراج شده است (معادله (۱۵)). مدل حاصل شده یک معادله چند جمله‌ای درجه دوم با ضرایب ثابت است که همانند معادله رابطه پیشین در پیش‌بینی تقاضای گاز استفاده می‌شود.

$$\begin{aligned}
 Z_{34} &= a_{01} + a_{11}(s) + a_{21}(W) + a_{31}(s)^2 + a_{41}(W)^2 \\
 &\quad + a_{51}(s)(W) \\
 Z_{13} &= a_{02} + a_{12}(T) + a_{22}(s) + a_{32}(T)^2 + a_{42}(s)^2 + a_{52}(T)(s) \\
 Z_{24} &= a_{03} + a_{13}(\varphi) + a_{23}(W) + a_{33}(\varphi)^2 + a_{43}(W)^2 \\
 &\quad + a_{53}(\varphi)(W) \\
 Z_{3411} &= a_{04} + a_{14}(Z_{34}) + a_{24}(T) + a_{34}(Z_{34})^2 + a_{44}(T)^2 \\
 &\quad + a_{54}(Z_{34})(T) \\
 Z_{1324} &= a_{05} + a_{15}(Z_{13}) + a_{25}(Z_{24}) + a_{35}(Z_{13})^2 + a_{45}(Z_{24})^2 \\
 &\quad + a_{55}(Z_{13})(Z_{24}) \\
 Demand_{Case2} &= a_{06} + a_{16}(Z_{3411}) + a_{26}(Z_{1324}) + a_{36}(Z_{3411})^2 \\
 &\quad + a_{46}(Z_{1324})^2 + a_{56}(Z_{3411})(Z_{1324})
 \end{aligned} \tag{۱۵}$$


همچنین ضرایب ثابت معادلات فوق در جدول ۵ داده شده است.

جدول ۵. ضرایب ثابت معادله (۱۵)


پارامتر	مقادیر	پارامتر	مقادیر
a_{01}	207958.4748077422	a_{02}	247282.4896755619
a_{11}	8174.9712852125	a_{12}	-1926.7555427703
a_{21}	4466.2264562395	a_{22}	4191.8716929742
a_{31}	-799.0577986941	a_{32}	189.8892455864
a_{41}	-245.9987730136	a_{42}	-266.5724574572
a_{51}	-534.3734367292	a_{52}	-438.0086748898
a_{03}	110871.8231474845	a_{04}	0.000017805659992

پارامتر	مقادیر	پارامتر	مقادیر
a_{13}	2525.8077053305	a_{14}	1.773364575302190
a_{23}	2211.4791344962	a_{24}	0.000099034077511
a_{33}	-11.6348172414	a_{34}	-
			0.000002717235634
a_{43}	-95.1306112005	a_{44}	0.001579693772799
a_{53}	-25.8904978021	a_{54}	-
			0.027173287211822
a_{05}	0.000005645606992	a_{06}	0.000004552628854
a_{15}	0.578174952705620	a_{16}	0.491760834608995
a_{25}	0.568760480447241	a_{26}	0.475275224504794
a_{35}	-	a_{36}	-
	0.000001486980743		0.000000378184762
a_{45}	-	a_{46}	0.000001649521951
	0.000004492627316		
a_{55}	0.000005306574444	a_{56}	-
			0.000001122345291

شکل ۷ داده‌های آزمون و آزمایش را برای مقادیر واقعی مصرف و مقادیر بدست آمده از مدل چند جمله‌ای حاصل شده از شبکه عصبی از نوع GMDH را نشان می‌دهد. همان طور که دیده می‌شود مقادیر تخمین زده شده و مقادیر واقعی به خصوص در مصارف بالا که بیشتر حائز اهمیت است به درستی پیش‌بینی شده است.




شکل ۷. مقادیر پیش‌بینی به دست آمد از مدل و مقادیر واقعی مصرف گاز برای شهر ایوان برای ارزیابی دقیق‌تر مدل بدست آمده داده‌های واقعی و داده‌های پیش‌بینی شده در نمودار شکل ۸ رسم شده است. محاسبات انجام شده مقدار ضریب تعیین را برای این حالت $R^2 = 0.8706$ نشان می‌دهد و تجمع داده‌ها حول خط رگرسیون نشان دهنده دقت مناسب مدل در پیش‌بینی مقادیر مصرف گاز می‌باشد.



شکل ۸. مقایسه داده‌های استخراج شده از مدل و داده‌های واقعی مصرف گاز با مقدار ضریب تعیین $R^2 = 0.8706$ برای شهر ایوان

برای شهر مهران با شرایط آب و هوایی گرم و خشک که مشخصات آن در جدول ۱ ذکر شد طبق مصارف در ۳۶۵ روز و داده‌های هواشناسی در بازه مورد بررسی مدل بهینه‌ای که مصارف را می‌تواند پیش‌بینی کند مطابق شکل ۹ می‌باشد.



شکل ۹. ساختمان شبکه GMDH در پیش‌بینی مصرف گاز برای شهر ایوان

مطابق مدل به کار رفته با الگوی بهینه فوق معادله (۱۶) استخراج شده است.

$$\begin{aligned}
 d_{12} &= a_{01} + a_{11}(T) + a_{21}(\varphi) + a_{31}(T)^2 + a_{41}(\varphi)^2 + a_{51}(T)(\varphi) \\
 d_{24} &= a_{02} + a_{12}(\varphi) + a_{22}(W) + a_{32}(\varphi)^2 + a_{42}(W)^2 \\
 &\quad + a_{52}(\varphi)(W) \\
 d_{3312} &= a_{03} + a_{13}(s) + a_{23}(d_{12}) + a_{33}(s)^2 + a_{43}(d_{12})^2 \\
 &\quad + a_{53}(s)(d_{12}) \\
 d_{2412} &= a_{04} + a_{14}(d_{24}) + a_{24}(d_{12}) + a_{34}(d_{24})^2 + a_{44}(d_{12})^2 \\
 &\quad + a_{54}(d_{24})(d_{12})
 \end{aligned} \tag{۱۶}$$


$$\begin{aligned}
 Demand_{Case3} &= a_{05} + a_{15}(d_{3312}) + a_{25}(d_{2412}) + a_{35}(d_{3312})^2 \\
 &\quad + a_{45}(d_{2412})^2 + a_{55}(d_{3312})(d_{2412})
 \end{aligned}$$

برای معادله فوق الذکر ثابت‌های مربوطه در جدول ۶ ارایه شده است.


جدول ۶. ضرایب ثابت معادله (۱۶)

پارامتر	مقادیر	پارامتر	مقادیر
a_{01}	94427.90119122337	a_{02}	1361.788348483098
a_{11}	-4260.27964504978	a_{12}	1165.12230546119
a_{21}	-623.16229605854	a_{22}	-1770.03742983244
a_{31}	52.26874207251	a_{32}	-10.82354779746
a_{41}	6.19386741219	a_{42}	50.27166965894
a_{51}	9.76790774126	a_{52}	21.76348171580
a_{03}	- 0.004134126080776	a_{04}	0.000027665359493
a_{13}	- 0.061650407102359	a_{14}	- 0.154422706150614
a_{23}	1.198101375736016	a_{24}	1.329207887558343
a_{33}	- 0.807011319215627	a_{34}	- 0.000004856778525
a_{43}	0.000002007548271	a_{44}	- 0.000009847330726
a_{53}	- 0.016721493029606	a_{54}	0.000011048127398
a_{05}	0.000058273291245	a_{35}	- 0.000254993390800
a_{15}	1.148476751024793	a_{45}	- 0.000256234040167
a_{25}	- 0.056627103299780	a_{55}	0.000510003601809

شکل ۱۰ مقادیر تخمین زده شده و مقادیر واقعی مصرف گاز و همچنین نمودار شکل ۱۱ مقایسه داده‌های استخراج شده از مدل مصرف گاز و داده‌های واقعی مصرف گاز با ضریب تعیین را برای شهر مهران نشان می‌دهد.



شکل ۱۰. مقادیر پیش بینی بدست آمد از مدل و مقادیر واقعی مصرف گاز برای شهر مهران



شکل ۱۱. مقایسه داده های استخراج شده از مدل و داده های واقعی مصرف گاز

با مقدار ضریب تعیین $R^2 = 0.7936$ برای شهر مهران

چهار معیار برای سنجش دقت مدل های به دست آمده، استفاده شده است. جدول ۷ معیارها را برای سه مدل حاصل شده نشان می دهد. شاخص MAE متوسط خطای مقادیر پیش بینی و داده های واقعی را نشان می دهد. بنا به مقادیر حاصل شده برای مطالعه موردی سوم با ۵۳۴۰ کمترین و بهترین

مقدار نسبت به بقیه موارد می‌باشد. همچنین ریشه مربعات خطای معياری است که به میانگین مربع اختلاف محاسبه شده برای هر داده پیش‌بینی با داده واقعی مربوط می‌شود که در جدول ۷ نمایش داده شده است. برای چند سری داده متفاوت برای مقایسه بهتر، باید از مقدار نرمال شده که با تقسیم این مقادیر بر مقدار متوسط یا دامنه تغییرات مصرف گاز حاصل می‌شود استفاده نمود. مقدار نرمال میانگین مربعات خطای برای مقایسه چند دسته داده می‌تواند استفاده شود. طبق نتایج حاصل شده دیده می‌شود که مقدار نرمال شده میانگین ریشه مربعات خطای برای هر سه مدل در بازه مطلوب قرار دارند و همچنین برای مطالعه موردی ۲ با ۱۱۲٪ بهترین نتیجه حاصل شده است.

جدول ۷. خطاهای محاسبه شده برای سه مدل بدست آمده از روش شبکه‌های عصبی از نوع GMDH

R^2	NRMSE	RMSE	MAE	پارامتر
۰/۸۳۵۶	۰/۲۱	۱۴۵۰۲۴	۹۴۳۶۴	مدل شهر ایلام
۰/۸۷۰۶	۰/۱۱۲	۳۰۵۵۸	۲۲۰۹۹	مدل شهر ایوان
۰/۷۹۳۶	۰/۱۲۳	۷۲۶۹	۵۳۴۰	مدل شهر مهران

۶. نتیجه گیری

در این مطالعه بر اساس داده‌های بدست آمده از هواشناسی و همچنین مصارف گاز برای شهرهای مختلف در منطقه آب و هوایی گرم و خشک که قسمت عمده مصرف مربوط به مصارف خانگی می‌باشد، با استفاده از روش شبکه‌های عصبی از نوع دسته بندی داده‌های عددی مدلی بر اساس دمای متوسط روزانه، متوسط رطوبت نسبی روزانه، ساعات آفتابی روزانه و سرعت متوسط باد در روز استخراج شده است. برای سه شهر ایلام، ایوان و مهران با سه شرایط متفاوت آب و هوایی، مدل‌هایی برای پیش‌بینی الگوی مصرف استخراج شده است. در این مطالعه از روش شبکه‌های عصبی از نوع گروه بندی داده‌های عددی با ۳۶۵ داده مصرف و هواشناسی مربوطه سه مدل چند جمله‌ای با دقت قابل قبول می‌باشد. طبق داده‌های حاصل شده مدل‌های استخراج شده برای شهرهای ایلام، ایوان و مهران به طرتیب با دارای میانگین ریشه مربعات خطای نرمال شده به ترتیب ۰/۲۱، ۰/۱۱۲ و ۰/۱۲۳ و همچنین ضریب تعیین به ترتیب ۰/۸۳۵۶، ۰/۸۷۰۶ و ۰/۷۹۳۶ می‌باشند که مقدار مطلوبی می‌باشد.

همچنین تایید نشان داد در مصارف بالا علی الخصوص زمستان که نیاز به دقت بیشتری برای پیش‌بینی مصارف گاز وجود دارد، مدل‌های حاصل شده دقت بهتری دارند.

سپاسگزاری

نویسنده بر خود لازم می‌داند از شرکت ملی گاز ایران و گاز استان ایلام به جهت حمایت و پشتیبانی لازم، تشکر و قدردانی نماید.

منابع

- [۱] ابریشمی حمید، جبل عاملی فرخنده، ابوالحسنی معصومه و جوان افшиان (۱۳۹۳)، "عملکرد دو روش ARIMA و شبکه عصبی GMDH در پیش‌بینی تقاضای گاز طبیعی در بخش‌های مختلف ایران-۱۳۸۹-۱۳۸۰"، *فصلنامه مطالعات اقتصادی کاربردی ایران*. از صفحه ۳۲۲ تا ۵۸، ۳(۱۲).
- [۲] احمدآذری، مجتبی شریعتی نیاسر، محمود البرزی و افшиان بختیاری (۱۳۸۷)، "برآورد میزان بار گاز مصرفی شهر تهران با استفاده از فناوری شبکه‌های عصبی"، *نشریه دانشکده فنی*، دوره ۴۲، شماره ۸، از صفحه ۹۶۱ تا ۹.
- [۳] صادقی سید کمال، موسویان سید مهدی (۱۳۹۴)، "تحلیل آماری و برآورد فاصله اطمینان پیش‌بینی شبکه عصبی ترکیبی به منظور مقایسه با مدل خطی ARIMA: مطالعه موردی مصرف ماهانه گاز طبیعی در بخش خانگی ایران". *فصلنامه تحقیقات مدل سازی اقتصادی*. ۱۰۶-۷۳: (۲۰)۵.
- [۴] طحاری مهرجردی محمدحسین، بابایی میبدی حمید، تقی زاده مهرجردی روح الله (۱۳۹۱)، "الگوسازی و پیش‌بینی مصرف انرژی بخش حمل و نقل ایران: کاربردی از الگوهای هوش مصنوعی". *فصلنامه برنامه ریزی و بودجه*. ۱۷: ۲۹-۴۷.
- [۵] عصاری محمدرضا، احسان الله عصاری، محمد علی بهرنگ و افшиان قنبرزاده (۱۳۸۹)، "کاربردی از ترکیب الگوریتم ژنتیک و شبکه‌های عصبی مصنوعی برای برآورد مصرف گاز طبیعی در ایران". *نشریه تبدیل انرژی*، جلد اول، از صفحه ۲۵ تا ۲۵.
- [6] Abdolrahimi S., Nasernejad B. and G. Pazuki (2014), Prediction of partition coefficients of alkaloids in ionic liquids based aqueous biphasic systems using hybrid group method of data handling (GMDH) neural network, *Journal of Molecular Liquids*, Vol. 191, No. 0, pp. 79-84.
- [7] Borji, Mehdi, et al. (2015), "Parametric analysis and Pareto optimization of an integrated autothermal biomass gasification, solid oxide fuel cell and micro

- gas turbine CHP system." *International Journal of Hydrogen Energy* 40.41: 14202-14223.
- [8] Karimi, Hajir, and Jamaledin Dastranj (2015), "Artificial neural network-based genetic algorithm to predict natural gas consumption." *Energy Systems* 5.3: 571-581.
- [9] Khanmohammadi, Shoaib, Kazem Atashkari, and Ramin Kouhikamali (2016), "Modeling and assessment of a biomass gasification integrated system for multigeneration purpose." *International Journal of Chemical Engineering* 2016.
- [10] Kondo T., Ueno J. and S. Takao (2013), Hybrid Multi-layered GMDH-type Neural Network Using Principal Component Regression Analysis and its Application to Medical Image Diagnosis of Liver Cancer, *Procedia Computer Science*, Vol. 22, No. 0, pp. 172-181.
- [11] Papari, Mohammad M., et al. (2011), "Modeling thermal conductivity augmentation of nanofluids using diffusion neural networks." *International Journal of Thermal Sciences* 50.1: 44-52.
- [12] Yousefi, F. et al. (2015), "Prediction of thermodynamic behavior of copolymers using equation of state and artificial neural network." *Colloid and Polymer Science* 293.1: 75-87.