

# مدل سازی و پیش بینی میزان مصرف گاز طبیعی به کمک

## شبکه های عصبی نوع GMDH چندهدفی

### مطالعه موردی: شرکت گاز شهر رشت

الهیار داغبندان<sup>۱</sup>، نساستایش<sup>۲</sup>

تاریخ پذیرش مقاله:

۹۵/۰۳/۲۵

تاریخ دریافت مقاله:

۹۴/۱۲/۱۴

#### چکیده:

مصرف گاز به عنوان منبع انرژی پاک برای مصارف صنعتی و گرمایشی و حمل و نقل به طور گسترده ای پذیرفته شده است و از میان سوخت های فسیلی، مصرف گاز برای داشتن محیط زیستی پاک تر مورد توجه بسیار قرار گرفته است. به دلیل اهمیت تأثیر مشخصه های هواشناسی در مصرف گاز شهرها و نیز امکان کاهش ناگهانی دما و در نتیجه افزایش میزان مصرف گاز شهرها، ضرورت اطلاع و پیش بینی مصرف گاز امری اجتناب ناپذیر است که در این تحقیق به آن پرداخته شده است. در ابتدا، برخی از متغیرهای تأثیرگذار بر مصرف گاز با استفاده از روش شناسی سطح پاسخ شناسایی گردیده است. در ادامه، شبکه عصبی نوع GMDH برای مدل سازی و پیش بینی میزان گاز طبیعی مصرفی در بخش خانگی، با استفاده از مجموعه داده های ورودی-خروجی مورد مطالعه قرار گرفته است. برای ارزیابی مدل پیشنهادی، ۸۴ داده مربوط به ۷ سال متوالی از شرکت گاز شهر رشت به صورت موردی به دست آمده است. به منظور مدل سازی، داده ها به دو دسته (۷۰ درصد برای آموزش و ۳۰ درصد برای آزمایش) تقسیم شده اند. نتایج حاصل از مدل سازی با داده های تجربی مقایسه گردید که ضریب تعیین ۰/۸۹۴۳ بوده و تطابق بسیار خوبی با نتایج تجربی نشان داده است.

#### کلمات کلیدی:

پیش بینی، شبکه عصبی نوع GMDH، مدل سازی، مصرف گاز

## مقدمه

گاز طبیعی به علت تامین بیش از ۵۰ درصد انرژی مصرفی در بخش خانگی-تجاری، ۴۵ درصد در بخش صنعتی و ۷۰ درصد در نیروگاه‌ها و پالایشگاه‌های کشور، از اهمیت و جایگاه ویژه‌ای در میان سایر منابع انرژی برخوردار است<sup>۱</sup>. همچنین وفور و گستردگی منابع گاز طبیعی در ایران، قیمت نسبتاً پایین آن، تامین رفاه خانوارها به لحاظ سهولت و تداوم دسترسی به آن، آلاینده‌گی زیست محیطی کمتر، مصارف غیر انرژی‌یک در صنایع نفت و پتروشیمی و بسیاری امتیازات و مزایای دیگر، جایگاه و نقش مهم گاز طبیعی را در حال حاضر و بویژه در سال‌های آینده به عنوان یکی از تامین کنندگان اصلی انرژی مورد نیاز بخش‌های مختلف مصرفی کشور آشکار می‌سازد<sup>[۵]</sup>.

جهت 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 می‌باشد. در همین راستا، در این مقاله پیش‌بینی تقاضای گاز طبیعی در شهر رشت به عنوان یک مطالعه منطقه‌ای مورد بررسی قرار گرفته است.

تحقیقات بسیاری در زمینه استفاده از روش‌های هوشمند برای پیش‌بینی میزان مصرف گاز طبیعی صورت گرفته است. لیو و لین<sup>[۱۱]</sup> میزان مصرف گاز طبیعی مسکونی در تایوان را با استفاده از مدل سری زمانی بررسی کرده و از دما و قیمت به عنوان ورودی استفاده و  $RMSE^3=0.0191$  شده است. سیمک<sup>۴</sup> و همکارانش<sup>[۱۹]</sup> از تفسیر منحنی منطقی برای پیش‌بینی میزان مصرف گاز در لهستان با استفاده از ورودی دمای ماهیانه استفاده کرده‌اند. آراس<sup>۵</sup> [۱۵] از روش رگرسیون برای پیش‌بینی میزان مصرف گاز در ترکیه استفاده کرده و  $R^{2f}=0.902$  شده است. فروزان‌فر و همکارانش<sup>[۱۷]</sup> دو روش  $NLP^7$  و  $GA^8$  را برای مصرف سالانه و فصلی مسکونی و تجاری از سال ۱۹۹۵ تا ۲۰۰۸ مقایسه نموده‌اند. ختن‌زاد و همکارانش<sup>[۲]</sup> با استفاده از شبکه عصبی مصنوعی<sup>۹</sup> (ANN) به پیش‌بینی میزان مصرف گاز طبیعی پرداختند که ورودی‌ها شامل دما و قیمت ماهانه بوده و  $R^2=0.882$  به دست آمده است. گوروکو<sup>۱۰</sup> و همکارانش<sup>[۱۳]</sup> از روش

(۱) این ارقام مربوط به متوسط سهم گاز طبیعی در تامین انرژی مصرفی بخش‌های مختلف مصرف طبق ترازنامه کشور-سال ۱۳۹۰ استخراج گردیده است.

- 2) Liu and Lin
- 3) Root Mean Squared Error
- 4) Siemek
- 5) Aras
- 6) Coefficient of Determination
- 7) Neuro-Linguistic Programming
- 8) Algorithm Genetic
- 9) Artificial Neural-Network
- 10) Gorucu

ANN برای یافتن پارامترهای بهینه در مصرف کوتاه مدت گاز استفاده کردند و سپس در تحقیقی دیگر به همراه گومراه [۸] میزان مصرف کوتاه مدت گاز را با استفاده از تحلیل رگرسیون چند متغیری، برای شهر آنکارا در ترکیه به دست آوردند.

در میان تحقیقات بسیاری که برای پیش‌بینی میزان مصرف گاز صورت گرفته، متغیرهای ورودی بسیاری دیده می‌شود اما در هیچ‌کدام پارامترهای هواشناسی که جزو مهمترین عناصر اثرگذار در مصرف گاز می‌باشد با گستردگی تحقیق حاضر، مورد بررسی قرار نگرفته است. برای یافتن بهترین پارامترهای هواشناسی به چند نکته اهمیت داده شده است: اولاً پارامتر انتخاب شده باید دارای تغییرات در دامنه گسترده‌تری باشد تا بتوان میزان اثرگذاری را در میزان مصرف گاز طبیعی بررسی کرد و ثانياً میزان تغییرات آن پارامتر توسط مصرف کنندگان به وضوح احساس شود [۱].

روش‌های بسیاری برای پیش‌بینی میزان مصرف گاز وجود دارد که به چند نمونه اشاره شده است اما همیشه سریع‌ترین و پردقت‌ترین شیوه‌ها باید در نظر گرفته شود. در این تحقیق، از میان روش‌های شناسایی ساختار شبکه عصبی GMDH برای حل مساله مورد استفاده قرار می‌گیرد و دو تابع هدف، خطای مدل‌سازی و خطای پیش‌بینی به‌طور هم‌زمان بهینه می‌شوند. این سیستم توانایی بالایی در مدل‌سازی این فرایند داشته و می‌تواند تغییرات خروجی را نسبت به تغییر پارامترهای موثر بر فرایند پیش‌بینی کنند [۹].

## مواد و روش‌ها

### جمع‌آوری داده‌ها و انتخاب متغیرهای ورودی

جهت بررسی پارامترهای اقلیمی در منطقه شهر رشت، کلیه ایستگاه‌های هواشناسی تاسیس شده در منطقه و اطراف آن شناسایی و آمار و اطلاعات موجود آنها جمع‌آوری و دسته‌بندی شده است. ایستگاه‌های مورد بررسی متشکل از دو ایستگاه متعلق به سازمان هواشناسی و چهار ایستگاه متعلق به وزارت نیرو بوده است. مشخصات عمومی ایستگاه‌های هواشناسی در جدول (۱) آورده شده است. ایستگاه سینوپتیک رامسر و کلیماتولوژی لاهیجان نزدیک‌ترین ایستگاه‌های متعلق به سازمان هواشناسی به منطقه موردنظر هستند که دارای آمار مناسب می‌باشند. در ابتدا، پارامترهای هواشناسی بسیاری از جمله حداکثر دما، حداقل دما، رطوبت نسبی، ساعات آفتابی، تعداد روزهای یخبندان، عمق یخبندان، میزان باد، میزان تبخیر و بارندگی از طریق محاسبات و پایگاه‌های هواشناسی نامبرده جمع‌آوری و سپس تاثیر هر پارامتر بر میزان مصرف از طریق مدل‌سازی بررسی شده است [۱].

جدول (۱) مشخصات ایستگاههای هواشناسی محدوده مطالعاتی

ردیف	نام ایستگاه	نوع ایستگاه	طول جغرافیایی	عرض جغرافیایی	ارتفاع (متر)	متولی
۱	شلمان	باران سنجی	۵۰-۳۰	۳۷-۱۰	۲	وزارت نیرو
۲	کلچال	باران سنجی	۵۰-۱۷	۳۷-۰۳	۱۵۶	وزارت نیرو
۳	طول لات	باران سنجی	۵۰-۱۷	۳۶-۵۹	۱۱۳	وزارت نیرو
۴	هرابتر	باران سنجی	۵۰-۱۸	۳۶-۵۹	۱۲۳	وزارت نیرو
۵	رامسر	سینوپتیک	۵۰-۴۰	۳۶-۵۴	-۲۰	سازمان هواشناسی
۶	لاهیجان	کلیماتولوژی	۵۰-۰۰	۳۷-۱۱	-۲	سازمان هواشناسی

از دیگر اطلاعات و پارامترهای مورد نیاز برای پیش‌بینی و مدل‌سازی، میزان مصرف ماهانه گاز طی دوره هفت ساله ۱۳۸۵ تا ۱۳۹۱ و همچنین تعداد مشترکین و تعداد واحدهای موجود در حوزه مورد نظر بوده است که از شرکت گاز شهر رشت<sup>۱</sup> (NIGC) به دست آمده است.

به منظور مدل‌سازی، ابتدا متغیرهای تاثیرگذار بر فرایند شناسایی شده و ارتباط میان آنها مشخص گردیده است. به منظور تعیین متغیرهای موثر و چگونگی ارتباط بین آنها از روش‌شناسی سطح پاسخ<sup>۲</sup> (RSM) استفاده گردیده است. این روش توسط باکس و ویلسون<sup>۳</sup> در سال ۱۹۵۱ به منظور تقریب متغیر پاسخ از یک مدل چند جمله‌ای درجه اول معرفی شد [۱۴]. با استفاده از این روش می‌توان روابط موجود بین پاسخ و متغیرهای مستقل را مشخص کرد. نرم‌افزار بکارگرفته شده بدین منظور، نرم‌افزار مینی تب<sup>۴</sup> می‌باشد. برای این کار، ابتدا داده‌های تجربی به نرم‌افزار معرفی شده و پس از حصول نتایج، یکی از پارامترهایی که برای هر اثر متقابل مشخص می‌گردد P<sup>۵</sup> است. در صورتی که این مقدار از ۰/۰۵ بیشتر باشد، نشان می‌دهد متغیر مربوطه اثر قابل توجهی بر خروجی ندارد که با این شرایط حذف می‌گردد [۱۲، ۶].

در نهایت، مدل‌سازی فرایند با استفاده از داده‌های تجربی شامل ۸۴ داده انجام شده است. مدل شامل چهار پارامتر موثر شامل متوسط دمای روزانه در هر ماه، متوسط رطوبت روزانه در هر ماه، متوسط بارندگی روزانه در هر ماه و تعداد واحدهای

1) National Iranian Gas Company  
 2) Response Surface Methodology  
 3) Box and Wilson  
 4) Minitab16  
 5) P-value

شهر رشت به صورت ماهانه، به عنوان ورودی و یک خروجی که میزان مصرف گاز طبیعی شهر رشت در بخش خانگی به صورت ماهانه است، بوده است.

### شبکه‌های عصبی چند هدفی نوع GMDH

در میان روش‌های شناسایی مختلف، الگوریتم دسته‌بندی گروهی داده‌های عددی که به اختصار GMDH خوانده می‌شود، سیستمی خود-سازمانده بوده که توسط پروفسور ایواخنکو<sup>۱</sup> به عنوان روش تحلیل چندگانه، برای مدل‌سازی و شناسایی سیستم‌های پیچیده توسعه یافت. به عبارت دیگر، می‌توان بدون داشتن اطلاعات تخصصی در مورد مساله مورد نظر از GMDH برای مدل‌سازی استفاده نمود [۷].

شبکه عصبی GMDH، شبکه‌ای یک سویه می‌باشد که از چندین لایه و هر لایه نیز از چندین نرون تشکیل یافته است. تمامی نرون‌ها از ساختاری مشابه برخوردارند که همگی آنها دارای دو ورودی و یک خروجی می‌باشند و هر نرون با ۵ وزن و یک بایاس عمل پردازش را میان داده‌های ورودی و خروجی برقرار می‌کند. نرون‌های هر لایه به صورت غیرخطی با یکدیگر ترکیب شده و نرون‌های جدیدی را تولید می‌نمایند که این نرون‌های جدید لایه بعدی مدل را تشکیل می‌دهند. متغیرهای ورودی هر نرون، خروجی و یا مقادیر تخمین زده شده توسط هر دو نرون انتخاب شده در لایه پیشین می‌باشند که به ازای  $N$  خروجی سیستم اصلی مجدداً مدل می‌شوند [۳، ۱۸].

به طور کلی، مسائل شناسایی سیستم به این گونه مطرح می‌شوند:

فرض می‌کنیم رابطه نامشخص تابع  $(f)$  میان متغیرهای  $X = (x_1, x_2, \dots, x_m)$  و مقادیر متناظر  $y$  همانند رابطه زیر باشد:

$$y_i = f(x_{i1}, x_{i2}, \dots, x_{im}) \quad i = 1, 2, \dots, N \quad (1)$$

رابطه  $(f)$  را می‌توان توسط تابع  $(\hat{f})$  به گونه‌ای تقریب زد که مجموع مربعات خطا به ازای نمونه داده‌های ورودی و خروجی کمینه شود:

$$\sum_{k=1}^N [(\hat{f}(x_{ki}, x_{kj}) - y_i)^2] \rightarrow \text{Min} \quad (2)$$

در این رابطه،  $(\hat{f})$  می‌تواند به صورت تابعی خطی و یا غیر خطی از متغیرهای ورودی سیستم باشد. نگاشتی که بین متغیرهای ورودی و خروجی توسط شبکه عصبی GMDH برقرار می‌شود، یک تابع غیر خطی به صورت رابطه زیر

1) Ivakhnenko

می‌باشد [۷،۱۶].

$$\hat{y} = a_0 + \sum_{i=1}^m a_i x_i + \sum_{i=1}^m \sum_{j=1}^m a_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijk} x_i x_j x_k + \dots \quad (3)$$

رابطه (۳) به نام سری ولترا<sup>۱</sup> شناخته می‌شود. الگوریتم GMDH بر اساس تجزیه سری توابع ولترا به چند جمله‌ای‌های درجه دوم دو متغیره پایه‌ریزی شده است. در واقع، هدف این الگوریتم یافتن ضرایب مجهول (a) در سری توابع ولترا می‌باشد. بدین منظور با تجزیه آن به چند جمله‌ای‌های درجه دوم دو متغیره به گونه‌ای این ضرایب مجهول در عوامل تجزیه شده پخش می‌گردند. لذا ضرایب مجهول در این چند جمله‌ای‌های درجه دوم تنظیم می‌شوند:

$$y(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i^2 + a_4 x_j^2 + a_5 x_i x_j \quad (4)$$

تابع  $y$  دارای شش ضریب مجهول می‌باشد، لذا بایستی آنها را طوری تنظیم کنیم که به ازای تمام نمونه‌های دو متغیره وابسته به سیستم  $\{(x_{ip}, x_{iq}), i = 1, 2, 3, \dots, N\}$  خروجی مطلوب  $\{(y_i), i = 1, 2, \dots, N\}$  برقرار گردد. به همین دلیل، تابع  $G$  را بر اساس قاعده کمترین مربعات خطا پایه‌ریزی می‌کنیم [۱۸].

$$\sum_{k=1}^N \left[ (G(x_{ki}, x_{kj}) - y_k)^2 \right] \rightarrow \text{Min} \quad (5)$$

با شرایط حاکم بر مساله، دستگاه معادلات فوق را می‌توان به فرم ماتریسی نیز نمایش داد:

$$Aa = Y \quad (6)$$

که در آن

$$a = \{a_0, a_1, a_2, a_3, a_4, a_5\}^T \quad (7)$$

$$Y = \{y_1, y_2, y_3, \dots, y_N\} \quad (8)$$

1) Volterra series

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}^2 & x_{1q}^2 & x_{1p}^2 x_{1q}^2 \\ 1 & x_{2p} & x_{2q} & x_{2p}^2 & x_{2q}^2 & x_{2p}^2 x_{2q}^2 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ 1 & x_{Np} & x_{Nq} & x_{Np}^2 & x_{Nq}^2 & x_{Np}^2 x_{Nq}^2 \end{bmatrix} \quad (9)$$

برای حل معادله لازم است که معکوس ماتریس غیر مربعی A محاسبه گردد. به همین دلیل، برای محاسبه معکوس ماتریس غیر مربعی A از روش حل معادلات متعامد<sup>۱</sup> (SNE) استفاده می‌شود. بنابراین، بردار ضرائب مجهول a توسط رابطه زیر به دست می‌آید [۱۰].

$$a = (A^T A)^{-1} A^T Y \quad (10)$$

#### مدل‌سازی و تحلیل یافته‌ها

هدف از مدل‌سازی، پیدا کردن و شناسایی رابطه‌ای بین پارامترهای ورودی و خروجی و بکارگیری شبکه GMDH به منظور کاهش در پیچیدگی سیستم شبکه عصبی می‌باشد. همچنین افزایش دقت در مدل‌سازی و پیش‌بینی اثر تغییر متغیرهای ورودی بر خروجی فرایند در نظر گرفته می‌شود. متغیرهای ورودی شامل متوسط دمای روزانه در هر ماه، متوسط رطوبت نسبی روزانه در هر ماه، متوسط بارندگی روزانه در هر ماه و تعداد واحدهای شهر رشت به صورت ماهانه می‌باشد. محدوده مورد مطالعه این متغیرها در جدول (۲) آورده شده است.

جدول (۲) محدوده داده‌های جمع آوری شده به عنوان متغیر ورودی

متغیرهای ورودی	حداقل	حداکثر	میانگین
متوسط دما [°C]	۱/۶	۲۷/۷	۱۶/۶
متوسط رطوبت نسبی	۶۸/۶۴	۹۰	۸۰/۷۱
متوسط بارندگی (میلی متر)	۰/۶	۳۷۷/۵	۱۰۸/۵۳
تعداد واحدها	۱۷۱۹۰۴	۲۳۹۴۹۰	۲۰۰۸۰۴/۵۴

مدل‌سازی فرایند با استفاده از داده‌های تجربی شامل ۸۴ داده مربوط به ۷ سال متوالی انجام شده است. مدل شامل چهار متغیر موثر به عنوان ورودی و یک خروجی که میزان مصرف گاز طبیعی در بخش خانگی است، می‌باشد. نمونه

داده‌های جمع آوری شده به منظور مدل‌سازی در جدول (۳) آورده شده است.

جدول (۳) نمونه داده‌های ورودی و خروجی مدل‌سازی

شماره	ورودی‌های مدل				خروجی
	متوسط دما	متوسط رطوبت	متوسط بارندگی	تعداد واحد	
۱	۱۳/۹	۸۳/۵۸۵	۶۱/۸	۱۷۱۹۰۴	۱۸۹۴۰۱۰۳
۲	۱۶/۴	۸۶/۲۹	۹۰/۲	۱۷۲۸۸۱	۱۹۵۱۴۱۸۷
...	...	...	...	...	...
...	...	...	...	...	...
۸۳	۱۰/۱	۸۰	۷۴/۷	۲۳۸۰۸۲	۸۳۳۷۳۹۶۱
۸۴	۱۰/۷	۸۱	۱۲۴	۲۳۹۴۹۰	۷۲۹۳۱۱۱۴

برای نمایش توانایی و استعداد شبکه عصبی نوع GMDH در زمینه پیش‌بینی پارامتر خروجی در حالتی که پارامترهای ورودی تغییر می‌کنند، داده‌های آزمایشگاهی به دو دسته (۷۰ درصد برای آموزش و ۳۰ درصد برای آزمایش) تقسیم شده‌اند تا عملکرد مدل مورد ارزیابی قرار گیرد. به منظور ارزیابی صحت و دقت مدل برای تخمین میزان مصرف گاز خانگی، از پارامترهای آماری چون متوسط مربعات خطا<sup>۱</sup> (MSE)، مجاور میانگین مربعات خطای نرمال<sup>۲</sup> (NRMSE) و ضریب تعیین<sup>۳</sup> (R<sup>2</sup>) استفاده شده است:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_{(i,exp)} - Y_{(i,model)})^2 \quad (11)$$

$$NRMSE = \left[ \sum_{i=1}^n (Y_{(i,exp)} - Y_{(i,model)})^2 / n \right]^{0.5} / (Y_{(exp,max)} - Y_{(exp,min)}) \quad (12)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_{(i,exp)} - Y_{(i,model)})^2}{\sum_{i=1}^n (Y_{(i,exp)})^2} \quad (13)$$

که  $Y_{i,model}$  مصرف گاز محاسبه شده توسط مدل،  $Y_{i,exp}$  مصرف گاز تجربی،  $Y_{exp,min}$  حداقل میزان مصرف گاز تجربی،  $Y_{exp,max}$  حداکثر میزان مصرف گاز تجربی و  $n$  تعداد دسته‌ها می‌باشد.

- 1) Mean Squared Error
- 2) Normal Root Mean Squared Error
- 3) Coefficient of Determination



### مدل‌سازی با شبکه GMDH

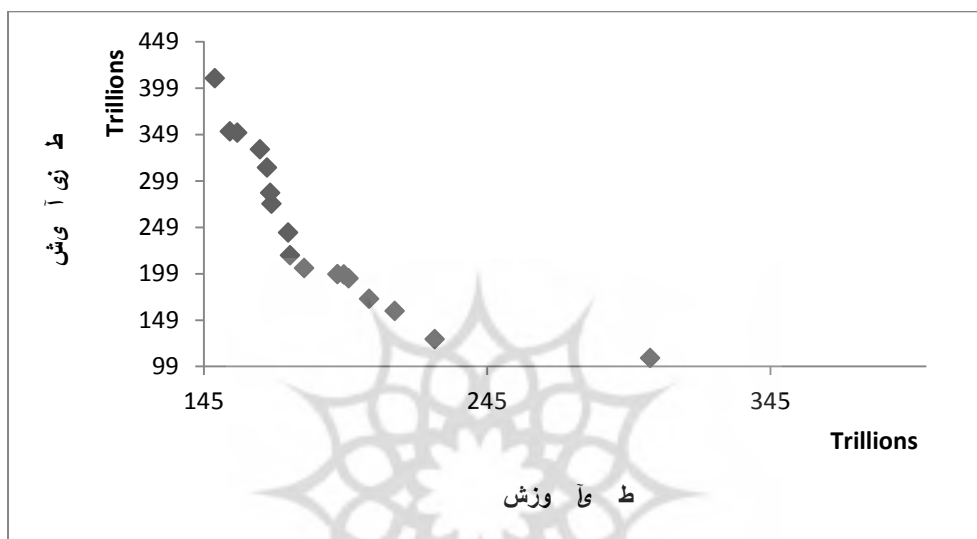
به منظور طراحی شبکه GMDH چندهدفی می‌بایست توابع هدف تعریف گردند که این توابع عبارتند از کمینه کردن خطای آموزش و آزمایش شبکه که مربوط به اختلاف بین داده‌های تجربی و نتایج حاصل از مدل می‌باشد. با طراحی بهینه توابع مورد نظر سیستم، سیستمی خواهیم داشت که میزان مصرف گاز را به میزان قابل قبولی پیش‌بینی می‌کند.

برای دستیابی به این مهم، از طراحی تکاملی ساختار شبکه عصبی توسط الگوریتم ژنتیک<sup>۱</sup> استفاده شد. در الگوریتم ژنتیک ابتدا جمعیت اولیه<sup>۲</sup> ایجاد و کروموزوم‌ها<sup>۳</sup> تولید شدند، سپس کروموزومی که کمترین میزان خطای آموزش و خطای آزمایش (بر اساس معادله (۱۱)) را داراست به عنوان کروموزوم برتر انتخاب شد که در شکل (۱) منحنی پارتو<sup>۴</sup> کروموزوم‌های تولید شده نمایش داده شده است. مقدار کمترین خطای آموزشی و آزمایشی با استفاده از این نمودار در جدول (۴) آمده است. نقطه مصالحه طراحی از بین تمامی نقاط پارتو می‌تواند نقطه M باشد، زیرا خطای مدل‌سازی نسبت به خطای آموزشی در این نقطه دارای توازن بیشتری نسبت به نقاط دیگر است. به دست آوردن نقطه M آخرین مرحله از مدل‌سازی می‌باشد، بدین ترتیب کروموزوم برتر به منظور تعیین میزان مصرف گاز به دست آمده است و چون در این مورد، مدل دارای ۳ لایه مخفی بوده، کروموزوم مورد نظر به طول ۲<sup>۴</sup> می‌باشد که توان ۴، یکی بیشتر از تعداد لایه‌های مخفی بوده است، لذا کروموزوم بدست آمده ۱۶ رقمی می‌باشد که هر رقم مربوط به یک ورودی است.

جدول (۴) میزان خطای آموزش و آزمایش در منحنی پاره تو مدل GMDH چندهدفی

خطای آموزش	خطای آزمایش	نقاط طراحی
۱/۰۹۷	۱/۴۸۹۵۷	$A \times 10^{14}$
۱/۰۷۹۴۳	۳/۰۲۵۷۲	$B \times 10^{14}$
۱/۲۸۳۳۲	۲/۲۶۵۳	$M \times 10^{14}$

- 1) Genetic Algorithm
- 2) Initial Population
- 3) Chromosome
- 4) Pareto



شکل (۱) نقاط پارتو خطای آموزش و آزمایش مدل GMDH چند هدفی.

کروموزوم بدست آمده :

۱ ۲ ۳ ۳ ۱ ۳ ۳ ۳ ۱ ۳ ۱ ۳ ۴ ۴ ۴ ۴

۱- متوسط دما ۲- متوسط رطوبت ۳- بارندگی ۴- تعداد واحدها

پارامترهای ژنتیکی مطابق جدول (۵) در نظر گرفته شده است، سپس مدل سازی انجام شده که ساختار شبکه عصبی GMDH بدست آمده برای پیش بینی میزان مصرف گاز در شکل (۲) ارائه شده است. در نهایت، جهت پیدا کردن و شناسایی رابطه ای بین پارامترهای ورودی و خروجی، معادلات مربوطه برای ساختار GMDH به منظور پیش بینی میزان مصرف گاز بدست آمده که در جدول (۶) گزارش شده است. مدل سازی شرح داده شده با انجام کدنویسی در نرم افزار متلب<sup>۱</sup> انجام شده است.

پس از بدست آمدن مدل پیشنهادی، نتایج حاصل از مدل سازی با داده های تجربی مقایسه گردیده است (شکل ۳). همانگونه که در شکل مشخص می باشد، نتایج حاصل از مدل سازی تطبیق بسیار خوبی با نتایج تجربی دارند. دقت و مقادیر

1) Matlab 7.11.0 (R2010b)

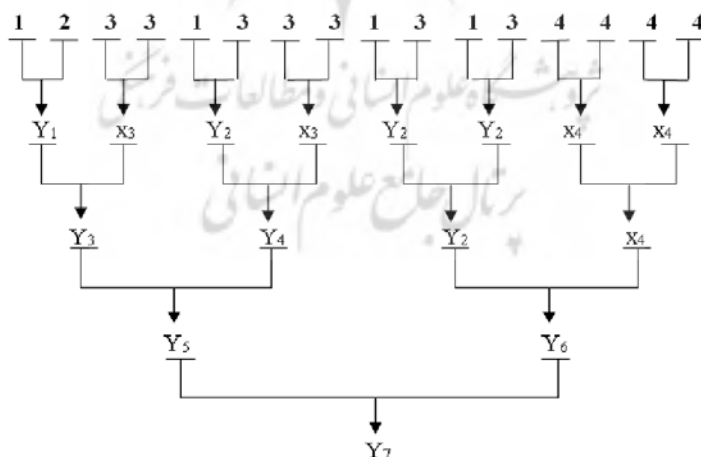
خطا در جدول (۷) گزارش شده است.

جدول ۵) مقداردهی پارامترهای الگوریتم ژنتیک در مدل GMDH چند هدفی

۰/۱	احتمال جهش <sup>۱</sup>	۲۰۰	جمعیت اولیه
۰/۹۷	احتمال پیوند(تولید مثل) <sup>۳</sup>	۱۰۰۰	تعداد نسل <sup>۲</sup>
۲	تعداد توابع هدف <sup>۵</sup>	۳	تعداد لایه‌های مخفی <sup>۴</sup>

1 3 3 1 4 4 4 4 1 3 3 3 1 2 3 3

After arrangement:

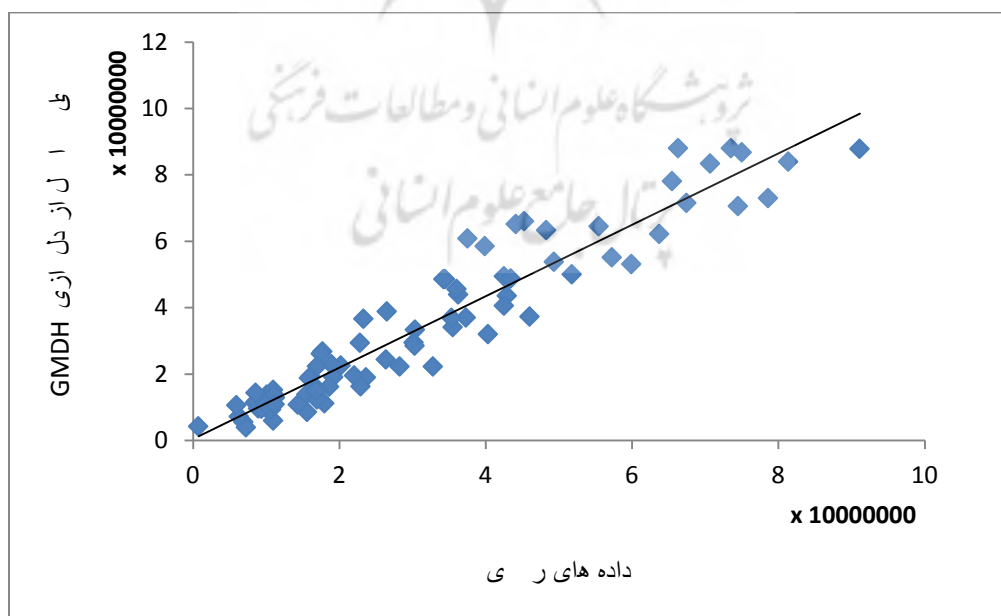


شکل ۲) ساختار پیشنهادی شبکه عصبی نوع GMDH چند هدفی برای پیش‌بینی میزان مصرف گاز طبیعی خانگی

- 1) Probability of Mutation
- 2) Number of Generations
- 3) Probability of Crossover
- 4) Hidden Layer
- 5) Number of Objective Functions

جدول ۶) روابط بازگشتی مدل GMDH چند هدفی به منظور پیش‌بینی میزان مصرف گاز طبیعی خانگی

$Y_1 = -221922939.567879 - 389470.309716034 x_1 + 6914842.88774079 x_2 + 22485.8102139962 x_1^2 - 40244.6796886133 x_2^2 - 32134.2877692169 x_1 x_2$
$Y_2 = 40843575.6055367 - 601500.817982043 x_1 + 230215.819014949 x_3 - 14150.9632112967 x_1^2 - 88.6203232412761 x_3^2 - 11267.014273067 x_1 x_3$
$Y_3 = (1.22259649258813e-013) + (2.23672249064776e-006)Y_1 + (6.6107273264988e-011)x_3 + (1.43290538585849e-008)Y_1^2 + (1.87770953206251e-008)x_3^2 + (0.00228556051839242)Y_1 x_3$
$Y_4 = (-3.405234274915e-016) + (1.00854849699547e-008)Y_2 + (-4.3757366189992e-012)x_3 + (1.99712907397108e-008)Y_2^2 + (-1.47495898576091e-009)x_3^2 + (-0.000181724519297259)Y_2 x_3$
$Y_5 = (2.34731436456949e-021) + (1.07532177101122e-014)Y_3 + (-1.18658920442121e-014)Y_4 + (9.25553089258418e-008)Y_3^2 + (5.69428474804388e-008)Y_4^2 + (-1.3515271248457e-007)Y_3 Y_4$
$Y_6 = (9.91400640045996e-016) + (1.90567301072878e-009)Y_2 + (1.91167408105269e-010)x_4 + (2.56692448455276e-010)Y_2^2 + (3.71480792169052e-005)x_4^2 + (4.930566247099e-006)Y_2 x_4$
$Y_7 = (2.49601111248567e-022) + (-1.02057951188889e-015)Y_5 + (4.58754686522647e-015)Y_6 + (2.68740526855091e-008)Y_5^2 + (4.74261813762259e-008)Y_6^2 + (-6.09106742987495e-008)Y_5 Y_6$



شکل ۳) مقایسه خروجی واقعی و خروجی مدل شده در مدل‌سازی GMDH چند هدفی

جدول ۷) خطای حاصل از مدل سازی GMDH

$R^2$	۰/۸۹۴۳
NRMSE	۰/۰۴۶۴
MSE	۰/۰۰۰۲۶۸

### نتیجه گیری

در این مقاله، سعی شده است با استفاده از شبکه‌های عصبی گامی در جهت مدل سازی میزان مصرف گاز طبیعی شهر رشت در بخش خانگی، با توجه به متغیرهای ورودی برداشته شود که هدف عمده آن ارائه مدلی است که به ازای مقادیر تجربی از دقت بالایی برخوردار بوده و پیش بینی معقولی را به همراه داشته باشد.

به منظور ارزیابی مدل بدست آمده از پارامترهای آماری چون متوسط مربعات خطا (MSE)، مجذور میانگین مربعات خطای نرمال (NRMSE) و ضریب تعیین ( $R^2$ ) استفاده گردید که نتایج بدست آمده حاکی از قابل اتکا بودن مدل GMDH بدست آمده می باشد.

در این پژوهش، مشاهده شده است که پارامترهای هواشناسی انتخاب شده به عنوان ورودی از اثرگذارترین پارامترهای هواشناسی می باشند و در صورت تغییرات در آنها، تغییرات قابل ملاحظه‌ای در میزان مصرف گاز طبیعی دیده شده است. افزایش تعداد پارامترهای جانبی در طول آموزش شبکه باعث آموزش دقیق تر شبکه و حصول نتایج نزدیک تر به واقعیت می گردد و هرچه تعداد داده‌های مورد استفاده در شبکه بیشتر باشد، آموزش شبکه بهتر صورت می گیرد، با این وجود، مدت زمان آموزش مورد نیاز افزایش یافته و احتمال بروز خطا در طول فرآیند آموزش تا رسیدن به جواب مطلوب تر بیشتر می گردد. از مزایای این مدل آن است که هر سیستم پیچیده و غیر خطی را می توان مدل کرد و به هر میزان دقت در انتخاب پارامترهای ورودی بیشتر باشد، خطای مدل ایجاد شده نیز کمتر خواهد بود.


### تقدیر و تشکر

نویسندگان مقاله بر خود لازم می دانند از زحمات مدیریت محترم و تمامی کارکنان محترم شرکت گاز شهر رشت که نهایت همکاری را در جمع آوری داده‌های لازم داشته‌اند، تشکر و قدردانی نمایند.

## منابع

- [۱] ( علیجانی، بهول؛ قویدل رحیمی، یوسف. (۱۳۸۴). «مقایسه و پیش بینی تغییرات دمای سالیانه تبریز با نا هنجاری‌های دمایی کره زمین با استفاده از روش رگرسیون خطی و شبکه‌های عصبی مصنوعی»، مجله جغرافیا و توسعه، شماره ۶، صص ۳۸-۲۱.
- [2] Aras H, Aras N (2004) Forecasting residential natural gas demand. *Ene sou* 26: 463-472.
- [3] Box, G. E. and Wilson, K. (1951). "On the experimental attainment of optimum conditions." *Journal of the Royal Statistical Society. Series B (Methodological)*. 13 (1), 1-45.
- [4] Daghandan, A., Akbarizadeh, M., and Yaghoobi, M. (2013). "Modeling and Optimization of Poly Electrolyte Dosage in Water Treatment Process by GMDH Type-NN and MOGA." *International Journal of Chemoinformatics and Chemical Engineering (IJCCE)*. 3 (2), 94-106.
- [5] Darvizeh, A., Nariman-Zadeh, N., and Gharababaei, H. (2003). "GMDH-type neural network modelling of explosive cutting process of plates using singular value decomposition." *Systems Analysis Modelling Simulation*. 43 (10), 1383-1397.
- [6] Dolenko, S. "Orlov Yu. V., & Persiantsev IG (1996), Practical implementation and use of Group Method of Data Handling (GMDH): Prospects and Problems", *Proc., Proceedings of ACEDC'96*.
- [7] Foruzanfar M, Doustmohammadi A, Menhaj MB, Hasanzadeh S (2010) Modeling and estimation of the natural gas consumption for residential and commercial sectors in Iran. *App Enr* 87: 268-274.
- [8] Ghorbani, F., Younesi, H., Ghasempouri, S. M., Zinatizadeh, A. A., Amini, M., and Daneshi, A. (2008). "Application of response surface methodology for optimization of cadmium biosorption in an aqueous solution by *Saccharomyces cerevisiae*." *Chemical Engineering Journal*. 145 (2), 267-275.
- [9] Gorucu FB, Geris PU, Gumrah F, Artificial neural network modeling for forecasting gas consumption. *Energy source* 2004; 26(3): 299-307.
- [10] Gorucu FB, Gumrah F. Evaluation and forecasting of gas consumption by statistical analysis. *Energy source* 2004; 26(3): 267-76.
- [11] Ivakhnenko, A. (1971). "Polynomial theory of complex systems." *Systems, Man and Cybernetics, IEEE Transactions on*. (4), 364-378.
- [12] J. Li, X. Dong, J. Shangguan, M. Hook, Forecasting the growth of China's natural gas consumption, *Energy* 36 (2011) 1380–1385.
- [13] Khayet, M., Zahrim, A., and Hilal, N. (2011). "Modelling and optimization of coagulation of highly concentrated industrial grade leather dye by response surface methodology." *Chemical Engineering Journal*. 167 (1), 77-83.

- [14] Khotanzad A, Elragal H, Lu T. Combination of artificial neural-network forecasters for prediction of natural gas consumption. IEEE Trans Neural Network 2000; 11(2): 464-73.
- [15] Liu LM, Lin MW (1991) Forecasting residential consumption of natural gas using monthly and quarterly time series. Int J Forecast 7:3\_16.
- [16] Nariman-zadeh, N., Darvizeh, A., Darvizeh M., Gharababaei H., "Modeling of explosive cutting process of plates using GMDH-type neural network and singular value decomposition", Journal of Materials Processing Technology, vol. 128, no. 1, 2002, pp. 80-87(8).
- [17] Nariman-Zadeh, N., Jamali, "Pareto genetic design of GMDH-type neural networks for nonlinear systems", Proc., Proceedings of the International Workshop on Inductive Modelling, Czech Technical University, Prague, Czech Republic, 96-103.
- [18] Siemek J, Nagy S, Rychliki S (2003) Estmiation of natural-gas consumption in Poland based on the logestic-curve interpretation. Appl Enrgy 75: 1-7.
- [19] Zadeh, L.A., "Fuzzy sets", Information and control, Vol. 8, No. 3, 1965, PP. 338\_353.



## فهرست علائم و نمادها

			علائم اختصاری
NIGC		National Iranian Gas Company	شرکت گاز ملی ایران
TE		Training Error	خطای آموزش
PE		Prediction Error	خطای آزمایش
RSM		Response Surface Methodology	روش شناسی سطح پاسخ
GMDH		Group Method of Data Handling	روش دسته‌بندی داده‌های گروهی
MUGA		Multi Uniform diversity of Genetic Algorithms	الگوریتم ژنتیک چندهدفی
SNE		Solving Normal Equation	حل معادلات نرمال
MSE		Mean Squared Error	متوسط مربعات خطا
NRMSE		Normalized Root-Mean Squared Error	درصد متوسط خطای مطلق
R <sup>2</sup>		Coefficient of Determination	ضریب تعیین
			نمادها
T	[°C]	Temperature	دما
X <sub>i</sub>	[-]	Input to model	ورودی‌های مدل
P-Value	[-]	Probability of obtaining a test statistic result	مقدار P
A <sub>i</sub>	[-]	Volterra series coefficients	ضرایب سری ولترا در مدل GMDH
Y <sub>i</sub>	[-]	Output of model	خروجی مدل
Y <sub>i,exp</sub>	[-]	Experimental data	نتایج تجربی
Y <sub>i,model</sub>	[-]	Model data	نتایج مدل‌سازی
Y <sub>exp,min</sub>	[-]	Minimum of experimental data	حداقل نتایج تجربی
Y <sub>exp,max</sub>	[-]	Maximum of experimental data	حداکثر نتایج تجربی
N	[-]	Number of data samples	تعداد داده‌های تجربی
n	[-]	Number of variables	تعداد متغیرها