

## استفاده از رهیافت شبکه عصبی GMDH در پیش‌بینی مصرف انرژی خط یک متروی تهران

۱ احمدرضا قاسمی\*، ۲ یاسر تقی نژاد

### چکیده

امروزه انرژی و میزان مصرف آن، محور استراتژیک برنامه‌ریزی‌های سازمانی است و از طرفی گسترش سیستم حمل‌ونقل درون‌شهری با در نظر گرفتن شرایط گوناگون اقتصادی، علمی، صنعتی، آب و هوایی و رشد روزافزون شهرنشینی ضروری است. تحلیل روندهای پیشین اطلاعات مصرف انرژی جهت پیش‌بینی روندهای آینده با در نظر گرفتن نرخ توسعه خطوط مترو، راه‌حلی کلیدی در راستای برنامه‌ریزی‌ها و سیاست‌گذاری‌های کلان آینده محور خواهد بود. در این پژوهش برای پیش‌بینی مصرف انرژی خط یک متروی تهران از مدل شبکه عصبی GMDH استفاده شده است که از قابلیت شناسایی و غربال کردن متغیرهای ورودی کم اثر در دوره آموزش شبکه و حذف آن‌ها در دوره آزمون، برخوردار است و همچنین برای درک میزان دقت پیش‌بینی با مدل ARIMA مورد مقایسه قرار گرفته است. در این پژوهش، دوازده متغیر اثرگذار بر میزان مصرف انرژی متروی تهران شناسایی شده و به‌عنوان متغیرهای ورودی مدل در نظر گرفته شده است. نتایج حاکی از آن است که مدل شبکه عصبی GMDH، به‌مراتب خطای کمتری را نسبت به مدل ARIMA دارد و از دقت پیش‌بینی بالاتری برخوردار است.

تاریخ دریافت:

۱۳۹۶/۶/۴

تاریخ پذیرش:

۱۳۹۷/۴/۳۰

کلمات کلیدی:

پیش‌بینی،

انرژی،

متروی تهران،

شبکه عصبی GMDH

ghasemiamhad@ut.ac.ir

taghinezhad89@ut.ac.ir

۱. دکترای تخصصی مدیریت صنعتی دانشگاه تهران (نویسنده مسئول)

۲. کارشناس ارشد مدیریت صنعتی، دانشکده مدیریت و حسابداری، پردیس فارابی، دانشگاه تهران

## ۱. مقدمه

یکی از مواردی که به رفع بحران ترافیک در شهرهای بزرگ کمک می‌کند، استفاده از وسایل حمل‌ونقل عمومی است. مترو در کم شدن مشکل ترافیک و آلودگی هوا در شهرها بسیار مؤثر و ضروری است. انرژی الکتریکی از انواع انرژی است که دارای کاربردهای منحصربه‌فردی بوده و می‌تواند در برخی زمینه‌ها جایگزین منابع انرژی مختلفی باشد. با شناسایی برق به‌عنوان منبع انرژی و برتری آن بر سایر انرژی‌ها از لحاظ آثار زیست‌محیطی و با توجه به افزایش قیمت سوخت‌های فسیلی گرایش به سرمایه‌گذاری در تولید برق افزایش یافته است. انرژی نقش اساسی در ادامه حیات و توسعه جوامع بشری ایفا می‌کند. نرخ رشد مصرف انرژی از شاخص‌های توسعه تلقی شده و انرژی به‌عنوان یکی از عوامل تولیدی مهم و مؤثر بر رشد، از جایگاه ویژه‌ای برخوردار است [۱۹]. پیش‌بینی تقاضای انرژی برای برنامه‌ریزی انرژی، تنظیم استراتژی و تعریف سیاست‌های انرژی نه‌تنها برای کشورهای در حال توسعه که با چالش داده‌های ضروری و نهادهای لازم و مدل‌های مقتضی روبرو هستند، بلکه برای کشورهای توسعه‌یافته که این محدودیت‌ها در آن‌ها کمتر است نیز یک مؤلفه اساسی به شمار می‌رود [۱۶]. امروزه پیش‌بینی وقایع آینده مورد توجه محققین در زمینه‌های مختلف قرار گرفته و روش‌های متنوعی در این رابطه ابداع شده است. بسیاری از سیستم‌های اقتصادی که نیازمند مدل‌سازی هستند، پیچیده، غیرخطی، دارای داده‌های غالباً نا ایستا و پارامترهای ناشناخته‌ای هستند که یا غیرقابل اندازه‌گیری بوده و یا اندازه‌گیری آن‌ها در قالب مدل‌های معمول ریاضی با دشواری و نا اطمینانی همراه است [۷]. برای مدل‌سازی این‌گونه سیستم‌ها از روش‌های غیر کلاسیک که از ویژگی‌هایی همچون هوشمندی و خبرگی برخوردار هستند، استفاده می‌شود. شبکه‌های عصبی یکی از روش‌های بدیع و در حال تحول است که در موضوع‌های متنوعی از قبیل الگوسازی، شناخت الگو، خوشه‌بندی و پیش‌بینی به‌کاررفته و نتایج مفیدی داشته است [۳]. پیش‌بینی مصرف انرژی متروی تهران به برنامه‌ریزان و سیاست‌گذاران برای تصمیم‌گیری‌های مناسب کمک خواهد کرد. با توجه به ارتباط تنگاتنگ مقوله انرژی به مباحث امنیت ملی و ثبات اقتصادی کشور و نقش تعیین‌کننده و حیاتی انرژی لزوم توجه و داشتن مدلی برای پیش‌بینی شرایط آینده مصرف انرژی برای مدیران عالی کشور امری حیاتی است. در سال‌های اخیر مطالعات فراوانی در زمینه پیش‌بینی تقاضای انرژی با استفاده از تکنیک‌های نوین محاسباتی انجام شده

که از بین این مدل‌ها، مدل‌های غیرخطی و بخصوص شبکه‌های عصبی بیشترین کاربرد را در این مطالعات داشته‌اند. بنابراین در این پژوهش تلاش شده است تا مدلی مناسب برای پیش‌بینی مصرف انرژی برق در بخش متروی تهران ارائه گردد. به دلیل اهمیت گسترده انرژی در بخش حمل‌ونقل پیش‌بینی مصرف انرژی در اولویت قرار می‌گیرد. از نتایج این پژوهش می‌توان در ارائه پیشنهادی سیاستی لازم در بخش عرضه انرژی برای پاسخ‌گویی به تقاضای انرژی در بخش حمل‌ونقل ایران استفاده بهینه کرد.

## ۲. ادبیات نظری

یکی از بخش‌های صنعتی کشور که نیازمند اصلاح الگو در ارائه خدمات توسط دولت و همچنین بهره‌برداری و استفاده از آن توسط مردم است، بخش حمل‌ونقل است. حمل‌ونقل درون‌شهری یکی از زیر بخش‌های صنعت حمل‌ونقل است. سیستم‌های حمل‌ونقل درون‌شهری به‌مرور زمان و برحسب نیازمندی‌های جوامع همواره ارتقاء یافته و از ابتدایی‌ترین وسیله حمل‌ونقل که دوچرخه بوده است به قطارهای هوایی و مترو تکامل یافتند. با توجه به طرح جامع حمل‌ونقل در ایران ۱۴۰۴، در راستای بهبود و اصلاح وضعیت ترافیک شهر، در افق ۱۴۰۴ روزانه ۱۸ میلیون سفر سواره به همراه ۲۵/۵ میلیون جابجایی در شبکه معابر تهران برآورد شده است. که بر اساس آن ۲۵ درصد سفرها توسط وسایل نقلیه شخصی و ۷۵ درصد توسط حمل‌ونقل عمومی و نیمه عمومی باید انجام گیرد. با توجه به اینکه سهم تعیین‌شده برای قطار شهری در افق مذکور ۳۰ درصد است، برنامه‌ریزی برای میزان مصرف انرژی در این حوزه ضروری است.

امروزه کاربرد انرژی الکتریکی در بخش حمل‌ونقل در سراسر جهان رو به افزایش است. مطابق با آمار و ارقام ترازنامه انرژی کشور، مصرف الکتریسیته در بخش حمل‌ونقل در دنیا در سال ۲۰۱۱ به رقم ۱۲۳۶۵۱۱ گیگاوات ساعت رسیده است [۶]. بخش عمده‌ای از مصرف انرژی الکتریکی در بخش حمل‌ونقل در سراسر دنیا، به سیستم‌های قطار شهری اختصاص می‌یابد. نداشتن آلاینده‌گی، صرفه‌جویی در فضا، کاهش چشمگیر سوخت و قابلیت استفاده از فناوری‌های روز دنیا موجب شده که سیستم‌های قطار شهری به سرعت گسترش یابد [۸].

به نقل از روزنامه دنیای اقتصاد، در سال ۱۳۹۳ منطقه خاورمیانه و کشور ایران مجموعاً با ۷ شهر دارای سیستم مترو با مسافت ۳۰۰ کیلومتر، روزانه ۷ میلیون مسافر را جابه‌جا می‌کنند که سهم ایران از

این میزان، ۳ شهر و روزانه بیش از ۳ میلیون مسافر با ۱۹۰ کیلومتر خط است [۱]. در ایران هرچند پروژه احداث قطار شهری در تهران به سال ۱۳۵۴ برمی‌گردد، اما اولین خط مترو در سال ۱۳۷۷ و با ظرفیت انجام ۳۰۰ هزار مسافر در سال کار خود را آغاز کرد و طی ۱۰ سال گذشته به گونه‌ای توسعه یافته که در حال حاضر سالیانه یک میلیارد سفر در تهران با مترو انجام می‌شود. مطابق با آمار و ارقام ترازنامه انرژی کشور، مصرف برق مترو تهران نیز در سال ۱۳۹۱ برابر  $۳۷۰/۹$  گیگاوات ساعت بوده است [۱۱]. با توجه به اهداف بلندمدت در بخش انرژی و سیاست‌های تدوین شده در سند چشم‌انداز توسعه بیست‌ساله کشور، مقرر شده است مصرف بخش حمل‌ونقل از کل مصرف برق در سال ۱۴۰۴ به یک میلیون بشکه معادل نفت خام برسد [۸]. وابستگی روزافزون زندگی بشر به انرژی موجب شده است تا این عامل به‌طور بالقوه و بالفعل در کارکرد بخش‌های مختلف اقتصادی نیز نقش بسیار مهمی ایفا کند. از این رو مسئولان هر کشور باید تلاش کنند تا با پیش‌بینی هر چه دقیق‌تر مصرف انرژی، پارامترهای عرضه و تقاضا را به نحو مطلوب کنترل کنند [۱۲]. با توجه به گسترش روزافزون خطوط مترو پیش‌بینی تقاضای انرژی برق در متروی تهران در برنامه‌ریزی‌های کلان اقتصادی نقش مهمی را ایفا خواهد کرد [۱۳]. بنابراین بهتر است به منظور اجتناب از اشتباهات هزینه‌بر، از مدل‌هایی استفاده شود که مصرف انرژی را با دقت بالاتری تخمین بزند. همچنین بهتر است مدل‌هایی بکار گرفته شود که بتواند از داده‌های مصرف انرژی که ماهیت غیرخطی دارند، در پیش‌بینی استفاده کرد [6, 26]. در حال حاضر مدل‌سازی و پیش‌بینی مصرف انرژی موضوع گسترده‌ای است که مورد توجه بسیاری از دانشمندان و مهندسان قرار دارد که منجر به توجه آن‌ها به مسئله تولید انرژی و مصرف آن است [۲۹]. با توجه به غیرقابل ذخیره بودن انرژی الکتریکی در مقیاس وسیع و هزینه‌بر بودن ساخت نیروگاه‌های جدید شناخت عوامل مؤثر بر مصرف انرژی الکتریکی ضروری به نظر می‌رسد. از طرفی ارائه پیش‌بینی مطلوبی از مصرف آن جهت برقراری تعادل بین عرضه و تقاضا همواره مورد توجه برنامه‌ریزان و محققان بوده است [۹]. با توجه به روند رو به رشد توسعه خطوط مترو و اختصاص بخش قابل توجهی از انرژی بخش حمل‌ونقل به آن، پیش‌بینی میزان این انرژی با به‌کارگیری مدل مناسب اهمیت می‌یابد. با توجه به اهمیت موضوع انرژی، پژوهش‌های متعددی در خصوص پیش‌بینی مصرف انرژی انجام شده است. پژوهش‌های مذکور به دو گروه تقسیم می‌شود: پژوهش‌هایی که با روش اقتصادسنجی و پژوهش‌هایی که با روش هوش مصنوعی و شبکه‌های عصبی انجام شده است [۱۰، ۴].

برای پیش‌بینی مصرف انرژی برق با به‌کارگیری اکثر روش‌های آماری باید از ابتدا فرم رابطه تابعی بین متغیر وابسته با متغیر مستقل مشخص باشد. در اکثر مواقع و برای سادگی، روابط خطی، درجه دوم و یا لگاریتمی فرض می‌شوند، هرچند این ساده‌سازی ممکن است منجر به نتایج نادرستی شود. تعیین رابطه تابعی بین مصرف برق و عوامل مؤثر بر آن مسئله بسیار پیچیده‌ای است و به‌سادگی امکان‌پذیر نیست. بنابراین استفاده از سیستم‌های هوشمند نظیر شبکه‌های عصبی که در سال‌های اخیر موردتوجه بسیاری از متخصصین امر قرار گرفته‌اند معقول به نظر می‌رسد [۱۴]. پیش‌بینی مصرف انرژی در مترو به تعدادی از عوامل که آن را متأثر می‌کند بستگی دارد. این عوامل شامل پارامترهای هواشناسی (میانگین دمای هوا، میانگین رطوبت نسبی)، تعداد مسافر، تعداد سفر، مساحت سکوها، هر یک از خطوط مترو، ماشین‌های فروش بلیت، مراکز خدمت‌رسانی به مشتریان، تعداد آسانسورها، تعداد پله‌های برقی، مکان‌های نگهداری تجهیزات موردنیاز برای عملکرد خطوط مترو و... است [۱۸]. با توجه به مطالب پیشین برنامه‌ریزی انرژی بدون داشتن دانش قابل قبولی از مصرف انرژی گذشته و حال و تقاضای احتمالی آینده امکان‌پذیر نیست [۳۰].

### ۳. پیشینه پژوهش

گارانچی و همکاران (۲۰۱۵) با به‌کارگیری روش شبکه‌های عصبی و روش تحلیل سری‌های زمانی، مصرف انرژی در بخش حمل‌ونقل عمومی را پیش‌بینی کرده‌اند. هدف این مطالعه مقایسه‌ی معایب و مزایای این دو روش به‌وسیله‌ی معیارهای مشخص است. مسافت پیموده شده، دمای هوا، طول روز، تعطیلات یا روزهای عادی هفته و زمان بندی (تابستان/زمستان) ورودی‌های مدل شبکه عصبی هستند. باگناسکو، فرسی، ساویوزی و وینسی (۲۰۱۵) برای پیش‌بینی مصرف انرژی در تسهیلات بیمارستان از روش شبکه عصبی بهره برده‌اند. متغیرهای بار الکتریکی، دیتای مربوط به انواع روز (روزهای عادی هفته یا روزهای تعطیل)، طول روز و اطلاعات مربوط به آب‌وهوا به‌عنوان متغیرهای ورودی مدل انتخاب شده‌اند. اطاعات هر ۱۵ دقیقه یک‌بار از سیستم توزیع مرکزی گردآوری شد. متغیر خروجی میزان مصرف انرژی الکتریکی در پایان روز برای تسهیلات یک بیمارستان بزرگ است. نتایج پژوهش‌ها نشان می‌دهد که استفاده از رویکرد

شبکه عصبی به منظور مدیریت رفتار حرارتی یک ساختمان مناسب است. سو و هونگ (۲۰۱۳) به منظور به دست آوردن الگوی مصرف انرژی الکتریکی در فصل تابستان برای ساختمان‌های مسکونی از روش Arima<sup>۱</sup> استفاده کرده‌اند. به منظور صرفه‌جویی در مصرف انرژی الکتریکی در ساختمان‌های مسکونی، تحلیل دقیق و پیش‌بینی الگوی مصرف انرژی الکتریکی باید انجام شود. به این منظور اطاعات مربوط به مصرف ساعتی آپارتمان‌های مسکونی از طریق برگه‌های گردآوری داده‌ها گردآوری شده‌اند. نتایج نشان می‌دهد الگوی مصرف در طول روزهای هفته و روزهای آخر هفته و برای لوازم برقی متفاوت است. وانگ و منگ<sup>۲</sup> (۲۰۱۲)، به مصرف انرژی شهر هبی<sup>۳</sup> در کشور چین، از سال ۲۰۰۹ تا سال ۲۰۱۳ را با به‌کارگیری روش شبکه‌های عصبی هیبریدی و روش ARIMA پیش‌بینی نموده‌اند. نرخ رشد اقتصادی، سطح دست مزد افراد و داده‌های مربوط به آب‌وهوا به‌عنوان متغیرهای اثرگذار در مصرف انرژی در نظر گرفته شده‌اند. سری‌های زمانی مصرف انرژی شامل مدل‌های خطی پیچیده و الگوهای غیرخطی هستند که پیش‌بینی آن‌ها دشوار است. روش شبکه عصبی هیبریدی با ترکیب روش‌های ARIMA و شبکه عصبی مصنوعی، از مزایای هر دو روش بهره می‌برد. نتایج نشان می‌دهد که استفاده از روش شبکه عصبی هیبریدی دقت پیش‌بینی بالاتری نسبت به هر یک از روش‌های ARIMA و شبکه عصبی مصنوعی به‌طور جداگانه دارد. مصرف انرژی در هبی در طی ۵ سال آینده و در سال ۲۰۱۳، ۲۸/۲۸۸۵۶ میلیون تن زغال سنگ استاندارد است و نرخ رشد سالیانه در طول سال‌های ۲۰۰۹-۲۰۱۳، ۲/۸ درصد است. جیحونیان، قادری و پیلتن (۲۰۱۰) با به‌کارگیری روش شبکه‌های عصبی و روش ARIMA، مصرف سالیانه انرژی الکتریکی در صنایع فلزات پایه را پیش‌بینی کرده‌اند. ارزش افزوده تولید، قیمت گاز، قیمت انرژی الکتریکی، تعداد افراد شاغل و سرمایه‌گذاری کل به‌عنوان ورودی‌های مدل شبکه عصبی در نظر گرفته شده‌اند. داده‌های مربوط به مصرف سالیانه انرژی الکتریکی از سال ۱۹۸۷ تا سال ۲۰۰۶ داده‌های ورودی مدل می‌باشند. نتایج پژوهش نشان می‌دهد که روش شبکه عصبی MLP بر پایه داده‌های لگاریتمی نتایج بهتری را نشان می‌دهد.

1. Autoregressive Integrated Moving Average
2. Wang & Meng
3. Hebei

قاسمی و اصغری زاده (۱۳۹۴) با استفاده از شبکه‌های عصبی خودسامان ده و خوشه‌بندی کا میانگین، به تعیین سطح سرآمدی شرکت‌های پتروشیمی کشور مبادرت نمودند. نتایج این پژوهش گویای آن بود که سه خوشه، تعداد بهینه خوشه در این زمینه محسوب می‌شود.

آذر فتحی هلی آبادی (۱۳۹۴) به پیش‌بینی مصرف انرژی در متروی تهران با استفاده از مدل‌های شبکه عصبی و Arima پرداخت. متغیرهای اثرگذار بر میزان مصرف انرژی متروی تهران؛ دمای هوا، میانگین رطوبت نسبی، تعداد مسافر، تعداد سفر، تعداد حرکت قطارها و تعداد روزهای تعطیل در همراه در خطوط 1 و 2 متروی تهران در نظر گرفته شد. مدل شبکه عصبی به‌مراتب خطای کمتری را نسبت به مدل Arima نشان می‌داد. یاسمن گرمابدری (۱۳۹۳) با به‌کارگیری روش شبکه‌های عصبی مصنوعی، مصرف انرژی متروی تهران را برای ۱۰ ماه پیش‌بینی کرد. تعداد مسافر، تعداد سفر، دمای هوا و میانگین رطوبت نسبی ورودی‌های مدل شبکه عصبی مصنوعی هستند. با توجه به بررسی‌های به‌عمل‌آمده در این تحقیق، امکان مانور شبکه‌های عصبی بر روی تغییر شبکه و تغییر نتایج بسیار زیاد است و با تغییر تعداد متغیرها می‌توان نتایج پیش‌بینی را بهبود بخشید. مهرجردی و همکارانش (۱۳۹۱) به الگوسازی و پیش‌بینی مصرف انرژی بخش حمل‌ونقل ایران با به‌کارگیری الگوهای شبکه عصبی فازی، شبکه عصبی ژنتیک و شبکه عصبی پرداختند. متغیرهای ورودی الگوی پیش‌بینی عبارت‌اند از: داده‌های سالانه جمعیت کل کشور، تولید ناخالص داخلی و تعداد خودرو و داده‌های سالانه مصرف انرژی بخش حمل‌ونقل کشور به‌عنوان متغیر خروجی در نظر گرفته شده‌اند. نتایج ارزیابی نشان داد که الگوی شبکه عصبی فازی، نسبت به سایر الگوها از بیشترین دقت در پیش‌بینی مصرف انرژی در بخش حمل‌ونقل کشور برخوردار است. ابراهیمی و آل مراد (۱۳۹۰) به پیش‌بینی تقاضای انرژی برای بخش حمل‌ونقل ایران در افق زمانی ۱۴۰۴ با به‌کارگیری مدل Arima پرداختند. از داده‌های مربوط به تقاضای انرژی برای بخش حمل‌ونقل طی سال‌های ۱۳۴۶ تا سال ۱۳۸۸ استفاده شده است. نتایج پژوهش نشان می‌دهد که تقاضای انرژی در بخش حمل‌ونقل ایران به‌سرعت افزایش خواهد یافت. مهرزاد ابراهیمی (۱۳۹۱)، به پیش‌بینی میزان مصرف انرژی الکتریکی در بخش کشاورزی پرداخته است. وی برای این منظور از روش‌های سری زمانی Arima و شبکه عصبی پرسپترون چندلایه استفاده کرده است. در این مقاله از داده‌های سالانه ۱۳۴۶ تا ۱۳۸۷ استفاده شد. نتایج مطالعه نشان داد که شبکه عصبی پرسپترون چندلایه دقت بیشتری در پیش‌بینی میزان مصرف برق دارد.

## ۴. مواد و روش

### شبکه عصبی GMDH

در میان روش‌های شناسایی مختلف، الگوریتم دسته‌بندی گروهی داده‌های عددی که به‌اختصار GMDH خوانده می‌شود، سیستمی خود سازمانده بوده که توسط پرفسور ایواخنکو به‌عنوان روش آنالیز چندگانه برای مدل‌سازی و شناسایی سیستم‌های پیچیده توسعه یافت. به‌عبارت‌دیگر می‌توان بدون داشتن اطلاعات تخصصی در مورد سیستم از GMDH در مدل‌سازی استفاده نمود [۲۵].

شبکه عصبی GMDH، شبکه‌ای یک‌سویه است 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. متغیرهای ورودی هر نرون، خروجی و یا مقادیر تخمین زده‌شده توسط هر دو نرون انتخاب‌شده در لایه پیشین است که به ازای  $N$  خروجی سیستم اصلی مجدداً مدل می‌شوند [۲۸]. [۱۹]، به‌طور کلی مسائل شناسایی سیستم این‌گونه مطرح می‌شوند: فرض شود رابطه نامشخص تابع  $(f)$  میان متغیرهای  $X=(X_1, X_2, X_3, \dots, X_m)$  و مقادیر متناظر  $y$  همانند رابطه (۱) باشد:

$$Y_i=f(X_{i1}, X_{i2}, X_{i3}, \dots, X_{im}) \quad i=1,2, \dots, N \quad (1)$$

که در آن  $X_i$  متغیرهای مدل،  $m$  تعداد متغیرها،  $y_i$  خروجی مدل و  $N$  تعداد مشاهدات یا سری داده‌های تجربی است. رابطه  $(f)$  را می‌توان توسط تابع  $(\hat{f})$  به‌گونه‌ای تقریب زد که مجموع مربعات خطابه ازای نمونه داده‌های ورودی و خروجی کمینه شود.

$$\text{Min} \rightarrow \sum_{k=1}^N \left[ (\hat{F}(X_{ki}, X_{kj}) - Y_i)^2 \right] \quad (2)$$

در این رابطه،  $(\hat{f})$  می‌تواند به‌صورت تابعی خطی و یا غیرخطی از متغیرهای ورودی سیستم باشد. نگاهی که بین متغیرهای ورودی و خروجی توسط GMDH برقرار می‌شود، یک تابع غیرخطی به‌صورت زیر است [۲۱، ۲۵].

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



که به نام سری ولترا<sup>۱</sup> شناخته می‌شود و ضرایب  $a$ ، ضرایب سری ولترا در مدل GMDH هستند. الگوریتم GMDH بر اساس تجزیه سری توابع ولترا به چندجمله‌ای‌های درجه دوم دومتغیره پایه‌ریزی شده است. درواقع هدف این الگوریتم یافتن ضرایب مجهول ( $\hat{a}$ ) در سری توابع ولترا است. به این منظور با تجزیه آن به چندجمله‌ای‌های درجه دوم دومتغیره به گونه‌ای این ضرایب مجهول در عوامل تجزیه شده پخش می‌شوند، لذا ضرایب مجهول در این چندجمله‌ای‌های درجه دوم تنظیم می‌شوند.

$$y(x_i, x_j) = a_0 + a_1x_i + a_2x_j + a_3x_i^2 + a_4x_j^2 + a_5x_ix_j \quad (4)$$

تابع  $y$  دارای شش ضریب مجهول است، لذا باید طوری تنظیم شود که به ازای تمام نمونه‌های دومتغیره وابسته به سیستم  $\{(x_{ip}, x_{iq}), i=1,2,3,\dots,N\}$  درحالی که  $p, q \in \{1,2,\dots,m\}$  باشند، خروجی مطلوب  $\{(y_i), i=1,2,\dots,N\}$  برقرار می‌شود. به همین دلیل تابع  $G$  بر اساس قاعده کمترین مربعات خطا<sup>۲</sup> پایه‌ریزی می‌شود.

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

با شرایط حاکم بر مسئله، دستگاه معادله فوق را می‌توان به فرم ماتریسی نیز نمایش داد.

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

که در آن  $A$  ماتریس متغیرها،  $Y$  ماتریس خروجی‌ها و ماتریس  $a$  ترانزاده ماتریس ضرایب است.

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

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

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

1. Volterra series

2. Least Squares Error

برای حل معادله لازم است که معکوس ماتریس غیر مربعی  $A$  محاسبه شود. به همین دلیل برای محاسبه معکوس ماتریس غیر مربعی  $A$ ، از روش حل معادلات نرمال<sup>۱</sup> استفاده می‌شود. بنابراین بردار ضرایب مجهول  $a$  توسط رابطه زیر به دست می‌آید [۲۰].

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

### فرآیند خود رگرسیون میانگین متحرک انباشته (ARIMA)

یکی از روش‌های معروف مدل‌سازی و پیش‌بینی سری زمانی، روش خود رگرسیون میانگین متحرک انباشته (ARIMA) است. فرآیند عمومی مدل ریاضی  $ARIMA(p,d,q)$  را می‌توان به صورت زیر نوشت.  $\varepsilon_t$  در این رابطه جزء اخلاص است [۲۳].

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (11)$$

در فرآیند  $ARIMA(p,d,q)$ ؛  $p$ ،  $d$  و  $q$  به ترتیب بیان‌گر تعداد جملات فرآیند خود رگرسیون، مرتبه انباشتگی و تعداد جملات فرآیند میانگین متحرک هستند. یکی از مسائل مهم در این فرآیند ساکن بودن سری زمانی است. یک سری زمانی در صورتی ساکن است که قدر مطلق ریشه‌های آن بزرگ‌تر از واحد باشند. در صورتی که سری زمانی مورد مطالعه مانا باشد  $d$  برابر صفر خواهد بود که در نتیجه فرآیند  $ARIMA(p,d,q)$  تبدیل به فرآیند  $ARMA(p,q)$  می‌شود. در صورت غیر ساکن بودن سری زمانی، برای مانا کردن آن نیاز به تفاضل‌گیری از سری زمانی است. از آنجاکه اغلب متغیرهای اقتصادی نا مانا هستند، برای این متغیرها  $d$  برابر تعداد تفاضل‌گیری‌ها است. برای تخمین الگوی  $ARIMA$  یا  $ARMA$  از روش باکس جنکینز استفاده می‌شود که دارای چهار مرحله است [۲]. مرحله اول شناسایی است که در این مرحله مقادیر واقعی  $p$ ،  $d$  و  $q$  باید تعیین می‌شوند. در این مرحله از آزمون‌های متعددی بهره گرفته می‌شود. از جمله این آزمون‌های می‌توان به نمودار خودهمبستگی<sup>۲</sup> یا نمودار خودهمبستگی جزئی<sup>۳</sup> و آزمون دیکی فولر<sup>۱</sup> تعمیم‌یافته اشاره کرد. همچنین در این مرحله از

1. Solving Normal Equation(SNE)
2. Auto correlation
3. Partial auto correlation

معیارهای آکائیک و شوارتز نیز زیاد استفاده می‌شود. در مرحله دوم بعد از شناسایی شاخص‌های اصلی و تعداد جملات وقفه AR و MA پارامترهای مدل با استفاده از روش حداقل مربعات برآورد می‌شوند. در این مرحله در بعضی موارد به جای روش حداقل مربعات از روش حداکثر درست‌نمایی استفاده می‌شود. در مرحله سوم پس از انتخاب مدل ARIMA و تخمین پارامترهای آن، دقت و اعتبار الگو مورد بررسی و آزمون قرار می‌گیرد. در این مرحله از آزمون‌های تکی و کلی رگرسیون استفاده می‌شود. مرحله چهارم، پیش‌بینی است. در این مرحله با استفاده از الگوی برآورد شده به پیش‌بینی سری زمانی در داخل نمونه و یا خارج نمونه اقدام می‌شود [۱].

### معیارهای ارزیابی مدل‌ها

به منظور ارزیابی و مقایسه نتایج روش‌ها و مدل‌های به کار برده شده در این پژوهش، از شاخص‌های آماری مانند میانگین مربعات مجذور خطا<sup>۲</sup>، ضریب تعیین<sup>۳</sup> و میانگین قدر مطلق خطا<sup>۴</sup> استفاده شده است که به ترتیب:

$$RMSE = \sqrt{\sum_{i=1}^n \left( \frac{(obs-pre)}{n} \right)} \quad (12)$$

$$R^2 = \frac{\sum_{i=1}^n (obs - \overline{obs})(pre - \overline{pre})}{\sqrt{\sum_{i=1}^n (obs - \overline{obs})^2 \sum_{i=1}^n (pre - \overline{pre})^2}} \quad (13)$$

$$MAPE = \frac{1}{n} \sum \left| \frac{X_k - X_{ok}}{X_k} \right|, \text{ for } k = 1, 2, \dots, n \quad (14)$$

که در روابط ۱۲ و ۱۳: obs: مقادیر مشاهده‌ای، pre: مقادیر پیش‌بینی شده توسط شبکه مدل و N: تعداد کل داده‌ها و در رابطه ۱۴: n: تعداد دوره‌ها،  $X_k$ : مقدار پیش‌بینی دوره K ام،  $X_{ok}$ : مقدار واقعی دوره K ام و  $X_0$ : میانگین مقدار واقعی تمام دوره‌ها در هر مرحله از آزمون‌های آموزش و آزمایش است. هرچه مقدار RMSE به صفر و مقدار R به یک نزدیک‌تر باشد، نشان‌دهنده نزدیک

1. Augmented Dicky Fuller
2. Root mean square error
3. Coefficient of Determination
4. Mean absolute Percentage error

بودن مقادیر مشاهده و پیش‌بینی‌شده به یکدیگر و دقیق‌تر بودن جواب‌ها در هر مرحله است [۲۴]. ضریب همبستگی، میانگین مربعات خطا و میانگین قدر مطلق خطا در نرم‌افزار MATLAB R2016a در شاخه Neural Network محاسبه شده است.

### مدل‌سازی با استفاده از شبکه عصبی GMDH

خط یک متروی تهران به طول ۳۹ کیلومتر با ۲۹ ایستگاه است. این خط از ایستگاه تجریش واقع در ابتدای خیابان شریعتی تا ایستگاه کهریزک واقع در ضلع جنوب شرقی بهشت‌زهرا است. این خط در ایستگاه شهید بهشتی با خط سه، در ایستگاه هفت تیر با خط در حال احداث شش، در ایستگاه دروازه دولت با خط چهار، در ایستگاه امام خمینی با خط دو و در ایستگاه مولوی با خط در حال احداث هفت تقاطع دارد. در این بخش میزان مصرف انرژی خط یک متروی تهران، با استفاده از روش شبکه عصبی GMDH مدل‌سازی و پیش‌بینی شده است. برای مدل‌سازی و پیش‌بینی با استفاده از روش شبکه عصبی GMDH از نرم‌افزار Matlab R2016a و داده‌های ماهانه سال ۱۳۹۰ تا سال ۱۳۹۵ استفاده شده است. ۸۰ درصد داده‌ها (فروردین ۱۳۹۰ تا آذر ۱۳۹۴) جهت آموزش شبکه و مدل‌سازی و ۲۰ درصد داده‌ها (دی ۱۳۹۴ تا اسفند ۱۳۹۵) به منظور پیش‌بینی در نظر گرفته شده است. در جدول ۱ متغیرهایی که در مدل‌سازی شبکه عصبی GMDH استفاده شده، ارائه شده است. انتخاب متغیرهایی که بیشترین تأثیر را بر روی خروجی شبکه دارد توسط شبکه صورت می‌گیرد. در این بخش چهار مدل مورد بررسی قرار گرفته که در هر مدل با توجه به تعداد متغیرهای پذیرفته شده و زائد توسط الگوریتم GMDH، شبکه مورد استفاده از لایه‌های ورودی و لایه‌های پنهان متفاوتی تشکیل شده است. لازم به ذکر است که تعداد متغیرهای ورودی در تعیین تعداد لایه‌ها تأثیر دارد و افزایش تعداد لایه‌های پنهان سبب پیچیده‌تر شدن محاسبات و کاهش خطای مدل‌سازی می‌شود اما با مشکلاتی چون افزایش حجم و زمان محاسبات و پیچیدگی فرآیند پیش‌بینی همراه خواهد بود. با توجه به توانایی الگوریتم GMDH در شناسایی متغیرهای زائد و انتخاب متغیرهای مهم در فرآیند مدل‌سازی، نگرانی بابت استفاده از متغیرهای مختلف در مدل وجود ندارد. لازم به ذکر است که برای گردآوری داده‌ها در خصوص مصرف انرژی در متروی تهران به شرکت بهره‌برداری راه‌آهن شهری تهران مراجعه شد و اطلاعات مورد نیاز گردآوری گردید. داده‌های مربوط به دمای هوا و میانگین رطوبت نسبی ماهیانه برگرفته از سایت اداره کل هواشناسی استان تهران است.

جدول ۱. متغیرهای ورودی مدل (منبع: یافته‌های تحقیق)

متغیرها	شرح
<b>As</b>	مساحت سکوه‌های هر ایستگاه
<b>At</b>	میانگین دمای ماهیانه هوای شهر تهران
<b>Ncs</b>	تعداد مراکز خدمت‌رسانی به مشتریان
<b>Arh</b>	میانگین رطوبت نسبی ماهیانه شهر تهران
<b>Acu</b>	مساحت واحدهای تجاری در هر ایستگاه
<b>Np</b>	تعداد مسافر در همراه در خط یک
<b>Nt</b>	تعداد سفر در همراه در خط یک
<b>Ntm</b>	تعداد حرکت قطارها در همراه در خط یک
<b>Nse</b>	تعداد پله‌های برقی در هر ایستگاه
<b>Ndc</b>	تعداد روزهای تعطیل در همراه
<b>Ne</b>	تعداد آسانسورها در هر ایستگاه
<b>Nm</b>	تعداد ماشین‌های فروش بلیت

مأخذ: نتایج تحقیق

با توجه به مطالب فوق برای مدل‌سازی تقاضای مصرف انرژی خط یک متروی تهران در این بخش چهار مدل مورد بررسی قرار گرفته و در جدول ۲ مدل‌های برآورده ارائه شده است. در این جدول، ستونی با عنوان مؤثرترین متغیر آورده شده است، این بدین معنی است که این متغیرها در مدل‌سازی بیشترین اثر را بر خروجی شبکه دارد. در واقع الگوریتم GMDH خود متغیرهای مؤثر و زائد در هر مدل را شناسایی می‌کند و متغیر زائد را حذف می‌کند.


جدول ۲. نتایج حاصل از پیش‌بینی میزان مصرف انرژی خط یک متروی تهران

مدل	متغیرهای مدل	مؤثرترین متغیر	داده‌های آموزشی		داده‌های آزمایشی	
			MAPE	RMSE	MAPE	RMSE
۱	As,At Arh,Np Nse,Nt	At, Np, Nt	۱۴.۲۱۳	۰.۸۴۵	۱۴.۵۴۶	۰.۸۶۷
۲	Nm,Ne,At,Nt m Np,Acu Ncs	Nc,Np,Nmt,At	۱۳.۹۵۶	۰.۷۸۷	۱۴.۰۱۲	۰.۷۹۵
۳	As, Ncs At,Ntm Np,Arh Ne,Nse Nm	Nc,Np,Nmt,At	۱۳.۲۶۵	۰.۵۱۳	۱۳.۶۴۷	۰.۵۵۲
۴	Np,Acu Arh,Nt Ncs,At As, Ndc Nc, Nse Na,Nmt	Nc,At,Np,Nt, Nmt, Ndc	۹.۲۸۴	۰.۳۴۲	۱۰.۷۱۸	۰.۳۹۳

مأخذ: نتایج تحقیق

با توجه به نتایج به دست آمده، مدل چهارم که دارای مجذور میانگین مربعات خطا، میانگین قدر مطلق خطای کمتر و دقت و ضریب همبستگی بیشتری است، مدل مطلوب است. دقت پیش‌بینی این مدل ۰.۹۵ درصد است و در این مدل متغیرهایی نظیر تعداد ماشین‌های فروش بلیت، میانگین دمای هوای ماهیانه شهر تهران، تعداد مسافر در هر ماه در خط یک، تعداد سفر در هر ماه در خط یک، تعداد حرکت قطارها در هر ماه در خط یک و تعداد روزهای تعطیل در هر ماه؛ دارای بیشترین اثر بر مصرف انرژی در خط یک متروی تهران است. بنابراین در این مدل، لایه ورودی شامل شش نرون است که تعداد عوامل مؤثر را نشان می‌دهد و در هر شبکه با افزایش تعداد لایه‌ها، خروجی به مقادیر واقعی نزدیک‌تر شده، در نهایت در بهترین حالت با هشت نرون در لایه پنهان، بهترین خروجی دریافت می‌شود و شبکه از لایه هشتم به بعد با کاهش دقت در خروجی همراه می‌شود و در هر شبکه، خروجی با میانگین مجذور خطا و برآزش

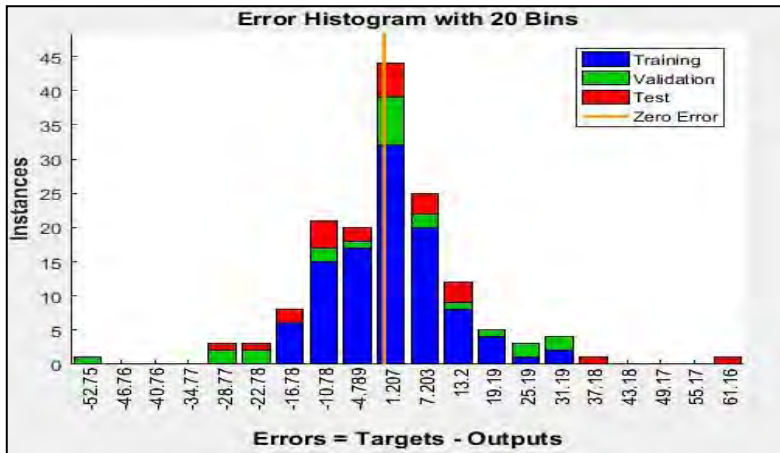
رگرسیون کنترل می‌شود. سرانجام لایه خروجی شامل یک نرون است. شبکه با هشت نرون در لایه میانی و در تکرار ششم با کمترین مقدار MSE بهترین عملکرد را دارد.



شکل ۱. برازش تعداد دفعات تکرار در شبکه عصبی GMDH (منبع: یافته‌های تحقیق)

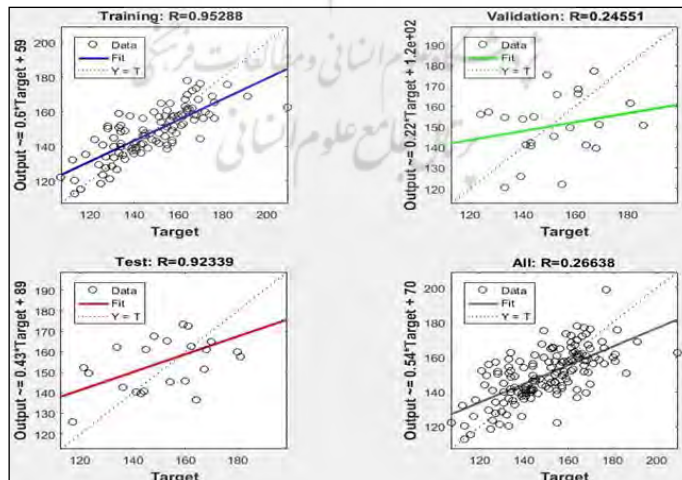
بنابراین، با انتخاب شبکه‌ای با هشت نرون در لایه میانی، همه خطای شبکه برای داده‌های آموزشی در اطراف صفر توزیع پیدا می‌کنند و توزیع خطاها با یاس چندانی به طرف خاصی ندارد و این نشان‌دهنده عمل کرد بسیار خوب شبکه در تعلیم داده‌های تمرینی<sup>۱</sup> است (شکل ۲).

پژوهشگاه علوم انسانی و مطالعات فرهنگی  
پرتال جامع علوم انسانی



شکل ۲. عمل کرد شبکه (منبع: یافته‌های تحقیق)

پس از عرضه نمونه‌های آموزشی به شبکه، وزن شبکه (پارامترهای آزاد) به گونه‌ای اصلاح می‌شوند که تفاوت پاسخ مطلوب و خروجی واقعی شبکه کمینه شود. این فرآیند با نمونه‌های ورودی تکرار می‌شود تا اینکه شبکه به حالت پایدار برسد و تغییر زیادی در وزن‌ها رخ ندهد [۱۵]. در شکل (۳) مقادیر خطا برای هر یک از داده‌های آموزشی، آزمایشی و اعتبار سنجی و مجموع کل داده‌ها نشان داده شده است.



شکل ۳. دقت شبکه عصبی جهت پیش‌بینی در مرحله آموزشی



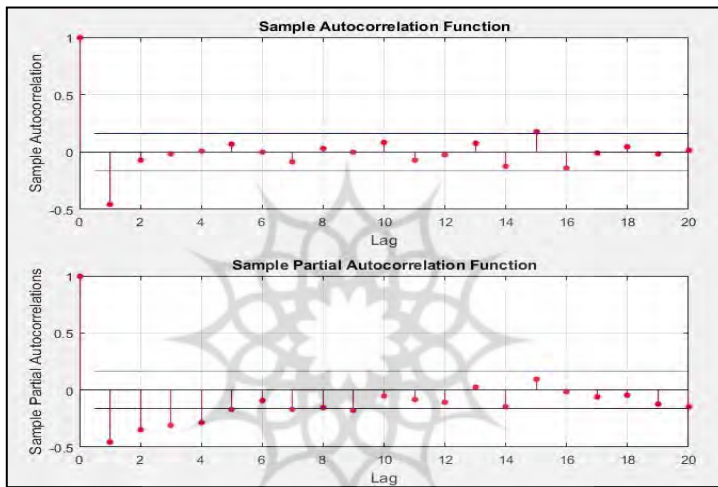
## مدل سازی با استفاده از الگوی سری زمانی ARIMA

در این بخش به مدل سازی و پیش بینی میزان مصرف انرژی خط یک متروی تهران با استفاده از مدل آریمای پرداخته شده است. در مدل ARIMA جهت برآورد الگو از نرم افزار MATLAB R2016a و از داده های فروردین سال ۱۳۹۰ تا اسفند سال ۱۳۹۵ استفاده شده است؛ بدین صورت که داده های فروردین ۱۳۹۰ تا آذر ۱۳۹۴ جهت مدل سازی و از داده های دی ۱۳۹۴ تا اسفند ۱۳۹۵ جهت ارزیابی عملکرد مدل در پیش بینی به کار گرفته شده است. متغیرهای پژوهش نیز به عنوان ورود مدل در نظر گرفته شده است. برای اینکه بهترین مدل ARIMA را برای پیش بینی میزان مصرف انرژی شناسایی کنیم نیازمند آن هستیم که داده ها را در وهله اول به حد ایستایی برسانیم. با انجام دو مرحله دیفرانسیل گیری، داده ها به حد ایستایی رسیده اند؛ در واقع تعداد جملات فرایند میانگین متحرک  $q=2$  است. در این روش پس از اطمینان از ایستایی سری، باید مراتب MA و AR تعیین شود. معمولاً در این مرحله، برآوردهایی با درجات بالاتر انجام شده و بهترین الگو از بین آنها با توجه به معیارهای آکایک و شوارتز و همچنین نوفه سفید بودن جملات پسماند انتخاب می شود. برای انتخاب الگوی مناسب از معیار آکایک و شوارتز استفاده شده که بر این اساس الگوی  $ARIMA(1,1,1)$  انتخاب شده است. اما از آنجاکه هدف اصلی برآورد این الگوها، پیش بینی است، میزان خطای پیش بینی از اهمیت بیشتری در انتخاب الگو برخوردار است که همان الگویی که با معیار آکایک انتخاب شد یعنی  $ARIMA(1,1,1)$  کمترین خطای پیش بینی را دارا است. نتایج تفصیلی حاصل از برآورد  $ARIMA(1,1,1)$  در جدول ۳ آورده شده است

جدول ۳. نتایج حاصل از برآورد مدل ARIMA (مأخذ: محاسبات پژوهشگر)

نام متغیر	ضریب	آزمون t
عرض از مبدأ	۵۲.۱	۱.۲
AR(1)	۰.۷۵	۴.۰۹
AR(2)	-۰.۱	-۰.۹
AR(3)	-۰.۰۷	-۰.۸۷
MA (1)	-۰.۷۱	-۳.۱

در جدول ۳، جمله خودرگرسیونی مرتبه اول  $AR(1)$  به لحاظ آماری بی معنا است. بقیه متغیرها در سطح خطای ۰.۱ از نظر آماری معنی دار هستند و همین طور با توجه به نمودار خودهمبستگی و خودهمبستگی جزئی مدل های فراوانی برآورد شده و با اعمال قواعد مدل سازی با روش  $ARIMA$  و با توجه به معیار آکاییک و شوارتز، بهترین مدل مطلوب  $AR(1)$  انتخاب شده است. در مدل مطلوب ارائه شده خودهمبستگی و ناهمسانی واریانس وجود ندارد.



شکل ۴. نمودار ACF و PACF (منبع: یافته های تحقیق)

پس از انتخاب بهترین مدل، از آن جهت پیش بینی در دوره دی ۱۳۹۴ تا اسفند ۱۳۹۵ استفاده شده است. نتایج حاصل از پیش بینی در مدل  $ARIMA$  با توجه به معیارهای مورد نظر در جدول ۴ ارائه شده است.

جدول ۴. خطای پیش بینی میزان مصرف انرژی در مدل  $ARIMA$

داده های آزمایشی	داده های آموزشی	داده های آزمایشی		داده های آموزشی		مدل
		RMSE	MAPE	RMSE	MAPE	
$r^2$	$r^2$					
۰.۶۳۸	۰.۶۸۲	۰.۹۴۸	۱۷.۶۵۹	۰.۹۲۹	۱۶.۹۸۵	<b>AR(1)</b>

## ۵. نتیجه گیری

همان طور که در جدول ۳ و ۴ مشاهده شد، اختلاف زیادی بین نتایج دو روش ARIMA و شبکه عصبی GMDH وجود دارد. با توجه به دقت پیش‌بینی ۰.۹۵ درصد در مدل چهارم حاصل از روش GMDH می‌توان گفت که این مدل برای پیش‌بینی میزان مصرف انرژی خط یک متروی تهران بسیار مناسب است. هر چه میزان خطای RMSE کمتر باشد، دقت پیش‌بینی بالاتر است. میزان خطای RMSE در مدل‌های GMDH به ترتیب ۰.۸۶۷، ۰.۷۹۵، ۰.۵۵۲، ۰.۳۹۳ و در مدل ARIMA ۰.۹۴۸ است. نتایج به دست آمده حاکی از آن است که میزان درصد خطای پیش‌بینی هر یک از چهار مدلی که با شبکه عصبی GMDH ارائه گردید، کمتر از مدل ارائه شده ARIMA است و این نشان دهنده قدرت خوب پیش‌بینی این مدل است. در نتیجه می‌توان گفت که مدل به دست آمده از الگوریتم GMDH توانایی پیش‌بینی و توضیح تغییرات میزان مصرف انرژی را با دقت بالا دارد. پژوهش‌های متعددی در خصوص پیش‌بینی میزان مصرف انرژی در بخش‌های مختلف و با به‌کارگیری روش‌های شبکه‌های عصبی و سری‌های زمانی از جمله ARIMA انجام شده است و نتایج این مطالعات نشان می‌دهد که شبکه‌های عصبی برای پیش‌بینی‌های بلندمدت و کوتاه‌مدت میزان مصرف انرژی از دقت بالاتری نسبت به سایر روش‌ها برخوردار است. چانگ و همکارانش در سال ۲۰۱۱ پیش‌بینی میزان مصرف انرژی در تایوان را با به‌کارگیری روش‌های شبکه‌های عصبی و ARIMA انجام داده‌اند و به این نتیجه رسیده‌اند که شبکه عصبی با متغیرهای مربوط به مصرف انرژی و آلودگی هوا برای پیش‌بینی بلندمدت بهترین نتیجه را دارد. لیونگ و لی در سال ۲۰۱۲ به منظور پیش‌بینی مصرف انرژی در هر یک از ایستگاه‌های متروی شهر هونگ کونگ از رویکرد شبکه‌های عصبی بهره جستند. با به‌کارگیری شبکه عصبی پرسپترون چندلایه، وابستگی غیرخطی میان مصرف انرژی با پارامترهای مربوط به ویژگی‌های طراحی ایستگاه‌های مترو و پارامترهای هواشناسی مدل‌سازی دست یافتند و این نتیجه رسیدند که توجه به میزان مصرف انرژی برق در ایستگاه‌های مترو عامل مهمی در طراحی ایستگاه‌های جدید است و میزان مصرف آسانسورها و پله‌های برقی می‌توانند عوامل مهمی در پیش‌بینی مصرف انرژی در ایستگاه‌های مترو است. گارناچی و همکاران در سال ۲۰۱۵ با به‌کارگیری روش شبکه‌های عصبی و روش تحلیل سری‌های زمانی مصرف انرژی در بخش حمل‌ونقل عمومی را پیش‌بینی کرده‌اند. در پژوهش‌های پیشین در رابطه با پیش‌بینی میزان مصرف انرژی مترو، فقط متغیرهایی نظیر دمای هوا،

میانگین رطوبت نسبی، تعداد مسافر، تعداد سفر، تعداد حرکت قطارها و تعداد روزهای تعطیل در هرماه مورد استفاده قرار گرفته و از این رو نقطه قوت این پژوهش استفاده از متغیرهای دیگر علاوه بر این متغیرهاست؛ متغیرهایی نظیر تعداد ماشین‌های فروش بلیت، تعداد آسانسورها در هر ایستگاه، تعداد پله‌های برقی در هر ایستگاه، مساحت واحدهای تجاری در هر ایستگاه، تعداد مراکز خدمت‌رسانی به مشتریان و مساحت سکوها هر ایستگاه است که در هر ایستگاه به‌طور جداگانه مورد بررسی قرار گرفته و در مدل به کار گرفته است لذا میزان دقت پیش‌بینی در این تحقیق بالاتر از پژوهش‌های پیشین است. نتایج این پژوهش نشان‌دهنده این بوده که مدل شبکه عصبی با دقت بسیار بالاتری نسبت به روش سری زمانی مصرف انرژی را پیش‌بینی می‌کند. با توجه به نتایج این پژوهش و مطالعات قبلی پیشنهاد می‌شود سیاست‌گذاران از این روش برای پیش‌بینی میزان مصرف انرژی خط یک متری تهران در سال‌های آینده استفاده کنند و با توجه به خطای بسیار کم مدل می‌توانند در راستای برآورد میزان انرژی مورد نیاز؛ با گسترش خطوط مترو، مدنظر قرار گیرد.

## منابع

- [۱] ابریشمی، ح؛ معینی، ع؛ مهرآرا، م؛ احراری، م. و ف. سلیمانی کیا (۱۳۸۷)، مدل‌سازی و پیش‌بینی قیمت بنزین با استفاده از شبکه عصبی GMDH، فصل‌نامه پژوهش‌های اقتصادی ایران، سال دوازدهم، شماره ۳۶، ص ۳۷-۵۸.
- [۲] ابریشمی، حمید؛ غنیمی فرد، حجت‌الله؛ احراری. مهدی و منیژه رضایی (۱۳۸۹)، پیش‌بینی قیمت گازوئیل خلیج فارس، مبتنی بر تحلیل تکنیکی و شبکه‌های عصبی، فصلنامه مطالعات اقتصاد انرژی، سال هفتم، شماره ۲۴، ص ۱۷۱-۱۹۲.
- [۳] اصغری اسکویی، محمدرضا (۱۳۸۱)، کاربرد شبکه‌های عصبی در پیش‌بینی سری‌های زمانی، فصلنامه پژوهش‌های اقتصادی ایران، ۱۲، ص ۶۹-۹۶.
- [۴] جعفری، محمد؛ مرتضی پور. حمید؛ جعفری نعیمی، کاظم و محمد مهارلویی (۱۳۹۶)، پیش‌بینی ذخیره حرارت در سامانه گرمایشی خورشیدی و انرژی مصرفی گلخانه با شبکه عصبی مصنوعی، نشریه انرژی ایران، دوره ۲۰، شماره ۲، صفحه ۵-۲۲.
- [۵] داغبندان، الهیار و نسا ستایش (۱۳۹۵). مدل‌سازی و پیش‌بینی میزان مصرف گاز طبیعی به کمک شبکه‌های عصبی نوع GMDH چندهدفی. مطالعه موردی: شرکت گاز شهر رشت، نشریه انرژی ایران، دوره ۱۹، شماره ۴، صفحه ۱۳۳-۱۴۸.

- [۶] دفتر برنامه‌ریزی کلان برق و انرژی، ترازنامه انرژی سال (۱۳۹۱)، وزارت نیرو، معاونت امور برق و انرژی زمستان ۱۳۹۱.
- [۷] رضایی، رضا (۱۳۸۳)، مقایسه عملکرد پیش‌بینی در مدل‌های شبکه عصبی مصنوعی و ARIMA (مورد مطالعه: تقاضای ماهیانه برق در ایران)، پایان‌نامه کارشناسی ارشد علوم اقتصادی، دانشگاه تهران.
- [۸] شاه حسینی، امید؛ سلیمیان، زهره؛ گودرزی، رضا و محمد علیمردانی (۱۳۸۹)، پیش‌بینی تقاضای انرژی الکتریکی در بخش حمل‌ونقل ایران توسط مدل MAED تا سال ۱۳۹۵، نشریه انرژی ایران، دوره ۱، ص ۱۱-۲۴.
- [۹] صادقی، حسین؛ افضلیان، علی اکبر؛ حقانی، محمود و حسین سهرابی وفا (۱۳۹۱)، پیش‌بینی تقاضای بلندمدت انرژی الکتریکی با استفاده از الگوریتم ترکیبی عصبی فازی و انبوه ذرات، فصلنامه تحقیقات مدل‌سازی اقتصادی، دوره ۱۰، ص ۲۱-۵۶.
- [۱۰] طحاری، محمدحسین؛ بابایی، حمید و روح اله تقی‌زاده (۱۳۹۱)، الگوسازی و پیش‌بینی مصرف انرژی بخش حمل‌ونقل ایران: کاربردی از الگوهای هوش مصنوعی، فصل‌نامه علمی پژوهشی، دوره ۱۰، ص ۲۹-۴۷.
- [۱۱] قدری، فرید (۱۳۹۳)، رتبه جهانی متروی تهران، دنیای اقتصاد، شماره ۳۴۴۷.
- [۱۲] گرمابدری، یاسمن (۱۳۹۳)، پیش‌بینی مصرف انرژی در متروی تهران با استفاده از شبکه‌های عصبی، پایان‌نامه کارشناسی ارشد، دانشگاه آزاد اسلامی واحد علوم و تحقیقات.
- [۱۳] محمدقلی‌ها، علی و فرشید کریمی (۱۳۹۲)، بهینه‌سازی مصرف انرژی در حمل‌ونقل شهری در افق ایران ۱۴۰۴ با تأکید بر توسعه مترو، مجله حمل‌ونقل و توسعه، دوره ۷۴، ص ۴۱-۴۷.
- [۱۴] منهای، محمدباقر؛ کاظمی، عالیبه؛ شکوری، حامد؛ مهرگان، محمدرضا و محمد رضا تقی‌زاده (۱۳۸۸)، پیش‌بینی تقاضای انرژی بخش حمل‌ونقل با استفاده از شبکه‌های عصبی: مطالعه موردی در ایران، پژوهش‌های مدیریت در ایران، ۲۰۳، ص ۲۰-۲۲۰.
- [۱۵] مهدی زاده، محمدباقر (۱۳۸۳)، شبکه‌های عصبی مصنوعی و کاربردهای آن در مهندسی عمران، انتشارات عبادی. چاپ اول.
- [16] Bhattacharyya S.C., And G.R. Timilsina (2009), *Energy Demand Models for Policy Formulation*, Policy Research Working, Paper: 48-66.
- [17] Ceylan H. and H.K. Ozturk (2004). "Estimating energy demand of Turkey based on economic indicators using genetic algorithm approach" *Energy Convers Manage*, Vol. 45, No.15, pp. 2525-2537.
- [18] Leung C.M., Lee W.M. and E. Philip (2013), "Estimation of electrical power consumption in subway design by intelligent approach" *Applie Wnergy*, Vol.101, No.21, pp. 636-643.
- [19] Dunkerley J.W., Ramsay L., Gordon and E. Cecelski (1981) *Energy Strategies for Developing Countries*, Washington, DC: Resources for the Future.

- [20] Darvizeh A., Nariman-Zadeh N. and H. Gharababaei (2003), "GMDH-type neural network modeling of explosive cutting process of plates using singular value decomposition" *Systems Analysis Modelling Simulation*, Vol. 43, pp.1383-1397.
- [21] Dolenko S., Orlov Y.V. and I.G. Persiantsev (1996) *Practical implementation and use of Group Method of data Handling (GMDH): Prospects and problems*. Proceedings of ACEDC, 96, PEDC, University of Plymouth, England.
- [22] Glasure YU. And A.R. Lee (1997), "Co-integration, error-correction, and the relationship between GDP and electricity: The case of South Korea and Singapore" *Resour Energy Econ*, Vol, 20. pp. 232-246.
- [23] Green W.H. (2012) *Econometric analysis*. 3th edition. Prentice Hall, Englewood Cliffs, New Jersey.
- [24] Ho, S.L., Min, X. and Thong Ngee, G. (2002) *A Comparative Study of Neural Network and Box-Jenkins ARIMA Modeling in Time Series Prediction*. Computers and Industrial Engineering, pp: 371- 375.
- [25] Ivakhnenko A.G. (1971) *Polynomial theory of complex systems*. Systems, Man and Cybernetics, IEEE Transactions on, SMC-1, 4., pp. 364-378.
- [26] Kavaklioglu K., Ceylan H., Ozturk HK. and O.E. Canyurt (2009) *Modeling and prediction of Turkey's electricity consumption using artificial neural networks*. Energy Convers Manage, Vol. 50.
- [27] Murat YS. and H. Ceylan (2006) *Use of artificial neural networks for transport energy demand modeling*. Energy Policy, Vol. 34, No.17, pp. 3165-3172.
- [28] Nariman-Zadeh N. and A. Jamali (2007) *Pareto design of GMDH-type neural networks for nonlinear systems*. Proceedings of the International Workshop on Inductive Modelling, Czech Technical University, Prague, Czech Republic, vol. 22, 96-103.
- [29] Ozturk HK., Ceylan H., Canyurt OE. And A. Hepbasli (2005) *Electricity estimation using genetic algorithm approach: A case study of Turkey*. Energy, Vol. 30, No.7, pp. 1003-1012.
- [30] Sozen A., Gulseven Z. and E. Arcaklioglu (2007) Forecasting based on sectoral energy consumption of GHGs in Turkey and mitigation policies. Energy Policy, Vol 35.
- [31] Ghasemi A.R. and E. Asgharizadeh (2014). Presenting a Hybrid ANN-MADM Method to Define Excellence Level of Iranian Petrochemical Companies. *Journal of information technology management*, Vol.6, No.2, 267-284.

## فهرست علائم و نمادها

		علائم اختصاری
TD	Training Data	داده‌های آموزشی
PD	Prediction Data	داده‌های آزمایشی
GMDH	Group Method of Data Handling	روش دسته‌بندی داده‌های گروهی
ARIMA	Autoregressive Integrated Moving Average	خود رگرسیون میانگین متحرک انباشته
SNE	Solving Normal Equation	حل معادلات نرمال
PAC	Partial auto correlation	خودهمبستگی جزئی
AC	Auto correlation	خودهمبستگی
RMSE	Root mean square error	میانگین مربعات مجذور خطا
$R^2$	Coefficient of Determination	ضریب تعیین
MAPE	Mean absolute Percentage error	متوسط درصد خطای مطلق
ADF	Augmented Dicky Fuller	آزمون دیکی فولر
LSE	Least Squares Error	کمترین مربعات خطا
		نمادها
$X_i$	Input to Model	متغیر ورودی
$A_i$	Volterra series Coefficients	ضرایب سری ولترا در مدل <b>GMDH</b>
$Y_i$	Output of Model	متغیر خروجی
Arh	Average relative humidity	میانگین رطوبت نسبی ماهیانه شهر تهران
Acu	Area of commercial units	مساحت واحدهای تجاری در هر ایستگاه
$N_p$	Number of passengers	تعداد مسافر در هر ماه در خط یک
$N_t$	Number of travel	تعداد سفر در هر ماه در خط یک
$N_{tm}$	Number of train movements	تعداد حرکت قطارها در هر ماه در خط یک
$N_{se}$	Number of stairs electric	تعداد پله‌های برقی در هر ایستگاه
$N_h$	Number of holidays	تعداد روزهای تعطیل در هر ماه
$N_e$	Number of elevators	تعداد آسانسورها در هر ایستگاه
$N_m$	Number of machines	تعداد ماشین‌های فروش بلیط