

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

^۱ احمد رضا قاسمی*، ^۲ یاسر تقی نژاد

چکیده

امروزه انرژی و میزان مصرف آن، محور استراتژیک برنامه‌ریزی‌های سازمانی است و از طرفی گسترش سیستم حمل و نقل درون‌شهری با در نظر گرفتن شرایط گوناگون اقتصادی، علمی، صنعتی، آب و هوازی و رشد روزافزون شهرنشینی ضروری است. تحلیل روندهای پیشین اطلاعات مصرف انرژی جهت پیش‌بینی روندهای آینده با در نظر گرفتن نرخ توسعه خطوط مترو، راه حلی 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 آموخت شبكه و حذف آن‌ها در دوره آزمون، ARIMA برخوردار است و همچنین برای درک میزان دقت پیش‌بینی با مدل شبکه عصبی GMDH مورد مقایسه قرار گرفته است. در این پژوهش، دوازده متغیر اثرگذار بر میزان مصرف انرژی متروی تهران شناسایی شده و به عنوان متغیرهای ورودی مدل در نظر گرفته شده است. نتایج حاکی از آن است که مدل شبکه عصبی GMDH به مرتب خطا 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

1. ghasemiahmad@ut.ac.ir

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

2. taghinezhad89@ut.ac.ir

2. 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 حمل و نقل 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 منحصر به فردی بوده و می‌تواند در برخی زمینه‌ها جایگزین منابع انرژی مختلفی باشد. با شناسایی برق به عنوان منبع انرژی و برتری آن بر سایر انرژی‌ها از لحاظ آثار زیست محیطی و با توجه به افزایش قیمت سوخت‌های فسیلی گرایش به سرمایه‌گذاری در تولید برق افزایش یافته است. انرژی نقش اساسی در ادامه حیاط و توسعه جوامع بشری ایفا می‌کند. نرخ رشد مصرف انرژی از شاخص‌های توسعه تلقی شده و انرژی به عنوان 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 نه تنها برای کشورهای در حال توسعه که با چالش داده‌های ضروری و نهادهای لازم و مدل‌های مقتضی روبرو هستند، بلکه برای کشورهای توسعه یافته که این محدودیت‌ها در آن‌ها کمتر است نیز یک مؤلفه اساسی به شمار می‌رود [۱۶]. امروزه پیش‌بینی وقایع آینده موردنوجه 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 ناایستا و پارامترهای ناشناخته‌ای هستند که یا غیرقابل اندازه‌گیری بوده و یا اندازه‌گیری آن‌ها در قالب مدل‌های معمول ریاضی با دشواری و نااطمینانی همراه است [۷]. برای مدل‌سازی این گونه سیستم‌ها از روش‌های غیر کلاسیک که از ویژگی‌هایی همچون هوشمندی و خبرگی برخوردار هستند، استفاده می‌شود. شبکه‌های عصبی یکی از روش‌های بدین و در حال تحول است که در موضوع‌های متنوعی از قبیل الگوسازی، شناخت الگو، خوشه‌بندی و پیش‌بینی به کار رفته 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 گستردگی انرژی در بخش حمل و نقل پیش‌بینی مصرف انرژی در اولویت قرار می‌گیرد. از نتایج این پژوهش می‌توان در ارائه پیشنهادهای سیاستی لازم در بخش عرضه انرژی برای پاسخ‌گویی به تقاضای انرژی در بخش حمل و نقل ایران استفاده بهینه کرد.

۲. ادبیات نظری

یکی از بخش‌های صنعتی کشور که نیازمند اصلاح الگو در ارائه خدمات توسط دولت و همچنین بهزه‌برداری و استفاده از آن توسط مردم است، بخش حمل و نقل است. حمل و نقل درون‌شهری یکی از زیر بخش‌های صنعت حمل و نقل است. سیستم‌های حمل و نقل درون‌شهری به مرور زمان و بر حسب نیازمندی‌های جوامع همواره ارتقاء یافته و از ابتدای ترین وسیله حمل و نقل که دوچرخه بوده است به قطارهای هوایی و مترو تکامل یافته‌است. با توجه به طرح جامع حمل و نقل 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 معاابر تهران برآورد شده است. که بر اساس آن ۲۵ درصد سفرها توسط وسایل نقلیه شخصی و ۷۵ درصد توسط حمل و نقل عمومی و نیمه عمومی باید انجام گیرد. با توجه به اینکه سهم تعیین شده 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 حمل و نقل در سراسر جهان رو به افزایش است. مطابق با آمار و ارقام ترازنامه انرژی کشور، مصرف الکتریسیته در بخش حمل و نقل در دنیا در سال ۲۰۱۱ به رقم ۱۲۳۶۵۱۱ گیگاوات ساعت رسیده است^[۶]. بخش عمده‌ای از مصرف انرژی الکتریکی در بخش حمل و نقل در سراسر دنیا، به سیستم‌های قطار شهری اختصاص می‌یابد. نداشتن آلایندگی، صرفه‌جویی در فضای 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 برگرداد، 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 حمل و نقل از کل مصرف برق در سال ۱۴۰۴ به یک‌میلیون بشکه معادل نفت خام برسد[۸]. وابستگی روزافزون زندگی بشر به انرژی موجب شده است تا این عامل به طور بالقوه و بالفعل در کارکرد بخش‌های مختلف اقتصادی نیز نقش بسیار مهمی ایفا کند. از این‌رو 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 رو افزون 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 اشتباكات 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 [۶، ۲۶]. در حال حاضر مدل‌سازی و پیش‌بینی مصرف انرژی موضوع گستره‌های 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 حمل و نقل به آن، پیش‌بینی میزان این انرژی با به کارگیری 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 اقتصادستنجی و پژوهش‌هایی که با روش هوش مصنوعی و شبکه‌های عصبی انجام شده است[۴، ۱۰].

برای پیش‌بینی مصرف انرژی برق با به کارگیری 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 پیچیده‌های است و به سادگی امکان‌پذیر نیست. بنابراین استفاده از سیستم‌های هوشمند نظری شبکه‌های عصبی که در سال‌های اخیر مورد توجه 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 سکوهای 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

گارناچی و همکاران(۲۰۱۵) با به کارگیری روش شبکه‌های عصبی و روش تحلیل سری‌های زمانی، مصرف انرژی در بخش حمل و نقل عمومی را پیش‌بینی کردند. هدف این مطالعه مقایسه معایب و مزایای این دو روش بهوسیلهٔ معیارهای مشخص است. مسافت پیموده شده، دمای هوا، طول روز، تعطیلات یا روزهای عادی هفته و زمان‌بندی (تابستان/زمستان) و رودی‌های 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 آب و هوا به عنوان متغیرهای ورودی مدل انتخاب شده‌اند. اطلاعات هر ۱۵ دقیقه یک بار 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 بهمنظور مدیریت رفتار حرارتی یک ساختمان مناسب است. ستو و هونگ^(۲۰۱۳) بهمنظور به دست آوردن الگوی مصرف انرژی الکتریکی در فصل تابستان برای ساختمان‌های مسکونی از روش Arima^۱ استفاده کرده‌اند. بهمنظور صرفه‌جویی در مصرف انرژی الکتریکی در ساختمان‌های مسکونی، تحلیل دقیق و پیش‌بینی الگوی مصرف انرژی الکتریکی باید انجام شود. به این منظور اطاعت 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^(۲۰۱۲)، به مصرف انرژی شهر هبی^۲ 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 آب و هوای به عنوان 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 به طور جدایانه دارد. مصرف انرژی در هی در طی ۵ سال آینده و در سال ۲۰۱۳/۲۸، ۲۸۸۵۶ میلیون تن زغال‌سنگ استاندارد است و نرخ رشد سالیانه در طول سال‌های ۲۰۱۳–۲۰۰۹ ۲/۸ درصد است. چیخونیان، قادری و پیلتون^(۲۰۱۰) با به‌کارگیری روش شبکه‌های عصبی و روش ARIMA، مصرف سالیانه انرژی الکتریکی در صنایع فلزات پایه را پیش‌بینی کرده‌اند. ارزش افزوده تولید، قمت گاز، قیمت انرژی الکتریکی، تعداد افراد شاغل و سرمایه‌گذاری کل به عنوان 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 اصغریزاده(۱۳۹۴) با استفاده از شبکه‌های عصبی خودسامانده و خوشبندی کا میانگین، به تعیین سطح سرآمدی شرکت‌های پتروشیمی کشور مبادرت نمودند. نتایج این پژوهش گویای آن بود که سه خوش، تعداد بهینه خوش در این زمینه محسوب می‌شد.

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 هوای میانگین رطوبت نسبی، تعداد مسافر، تعداد سفر، تعداد حرکت قطارها و تعداد روزهای تعطیل در هرماه در خطوط ۱ و ۲ متروی تهران در نظر گرفته شد. مدل شبکه عصبی به مراتب خطای کمتری را نسبت به مدل Arima نشان می‌داد. یاسمن گرمابدری(۱۳۹۳) با به کارگیری روش شبکه‌های عصبی مصنوعی، مصرف انرژی متروی تهران را برای ۱۰ ماه پیش‌بینی کرد. تعداد مسافر، تعداد سفر، دمای هوای میانگین رطوبت نسبی ورودی‌های مدل شبکه عصبی مصنوعی هستند. با توجه به بررسی‌های به عمل آمده 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 بخشدید. مهرجردی و همکارانش(۱۳۹۱) به الگوسازی و پیش‌بینی مصرف انرژی بخش حمل و نقل ایران با به کارگیری 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 حمل و نقل کشور به عنوان 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 حمل و نقل کشور برخوردار است. ابراهیمی و آل مراد(۱۳۹۰) به پیش‌بینی تقاضای انرژی برای بخش حمل و نقل ایران در افق زمانی ۱۴۰۴ با به کارگیری مدل Arima پرداختند. از داده‌های مربوط به تقاضای انرژی برای بخش حمل و نقل طی سال‌های ۱۳۴۶ تا سال ۱۳۸۸ استفاده شده است. نتایج پژوهش نشان می‌دهد که تقاضای انرژی در بخش حمل و نقل ایران به سرعت 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^۱ GMDH

در میان روش‌های شناسایی مختلف، الگوریتم دسته‌بندی گروهی داده‌های عددی که به اختصار GMDH خوانده می‌شود، سیستمی خود سازمانده بوده که توسط پروفسور ایوانخنکو به عنوان روش آنالیز چندگانه برای مدل‌سازی و شناسایی سیستم‌های پیچیده توسعه یافته. به عبارت دیگر 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 زده شده توسط هر دو نرون انتخاب شده در لایه پیشین است که به ازای N خروجی سیستم اصلی مجددًا مدل می‌شوند.^[۲۸] به طور کلی مسائل شناسایی سیستم این‌گونه مطرح می‌شوند: فرض شود رابطه نامشخصتابع (f) میان متغیرهای X=(x₁, x₂, x₃, ..., 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 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 به صورت تابعی خطی و یا غیرخطی از متغیرهای ورودی سیستم باشد. نگاشتی که بین متغیرهای ورودی و خروجی توسط GMDH برقرار می‌شود، یک تابع غیرخطی به صورت زیر است.^[۲۱, ۲۵]

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

1. Group Method of Data Handling

که به نام سری ولترا^۱ شناخته می‌شود و ضرایب a ، ضرایب سری ولترا در مدل GMDH هستند. الگوریتم GMDH بر اساس تجزیه سری توابع ولترا به چندجمله‌ای‌های درجه دوم دو متغیره پایه‌ریزی شده است. درواقع هدف این الگوریتم یافتن ضرایب مجهول (a) در سری توابع ولترا است. به این منظور با تجزیه آن به چندجمله‌ای‌های درجه دوم دو متغیره به گونه‌ای این ضرایب مجهول در عوامل تجزیه شده پخش می‌شوند، لذا ضرایب مجهول در این چندجمله‌ای‌های درجه دوم تنظیم می‌شوند.

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

تابع y دارای شش ضریب مجهول است، لذا باید طوری تنظیم شود که به ازای تمام نمونه‌های دو متغیره وابسته به سیستم $\{(x_{ip}, x_{iq}), i=1,2,3,\dots,N\}$ در حالی که $p,q \in \{1,2,\dots,m\}$ باشد، خروجی مطلوب $\{y_i\}$ برقرار می‌شود. به همین دلیل تابع G بر اساس قاعده کمترین مربعات خطأ^۲ پایه‌ریزی می‌شود.

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

با ضرایب 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 ترانهاده ماتریس ضرایب است.

$$a = \{a_{0+} a_{1+} a_{2+} a_{3+} a_{4+} a_{5+}\} \quad (7)$$

$$Y = \{y_{1+} y_{2+} y_{3+} \dots y_N\}^T \quad (8)$$

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

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^۱ 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 انباسته (ARIMA)

یکی از روش‌های معروف مدل‌سازی و پیش‌بینی سری زمانی، روش خود رگرسیون میانگین متحرک انباسته (ARIMA) است. فرایند عمومی مدل ریاضی (ARIMA(p,d,q)) را می‌توان به صورت زیر نوشت. ε_t در این رابطه جزء اخلال 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 فرایند ARIMA(p,d,q)، p و q به ترتیب بیان‌گر تعداد جملات فرایند خود رگرسیون، مرتبه انباستگی و تعداد جملات فرایند میانگین متحرک هستند. یکی از مسائل مهم در این فرایند ساکن بودن سری زمانی است. یک سری زمانی در صورتی ساکن است که قدر مطلق ریشه‌های آن بزرگ‌تر از واحد باشد. در صورتی که سری زمانی مورد مطالعه مانا باشد d برابر صفر خواهد بود که درنتیجه فرایند ARIMA تبدیل به فرایند ARMA(p,q) می‌شود. در صورت غیر ساکن بودن سری زمانی، برای مانا کردن آن نیاز به تفاضل گیری از سری زمانی است. ازانجاکه اغلب متغیرهای اقتصادی نا مانا هستند، برای این متغیرها برابر تعداد تفاضل گیری‌ها است. برای تخمین الگوی ARIMA یا ARMA از روش باکس جنکیتر استفاده می‌شود که دارای چهار مرحله است [۲۴]. مرحله اول شناسایی است که در این مرحله مقادیر واقعی p و q باید تعیین می‌شوند. در این مرحله از آزمون‌های متعددی بهره گرفته می‌شود. از جمله این آزمون‌های می‌توان به نمودار خودهمبستگی^۲ یا نمودار خودهمبستگی جزئی^۳ و آزمون دیکی فولر^۴ 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 برآورده 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 کاربرده شده در این پژوهش، از شاخص‌های آماری مانند میانگین مربعات مجذور خطأ^۱، ضریب تعیین^۲ و میانگین قدر مطلق خطأ^۳ استفاده شده است که به ترتیب :

$$RMSE = \sqrt{\sum_{i=1}^n \left(\frac{(obs - pre)}{n} \right)^2} \quad (12)$$

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

$$MAPE = \frac{1}{n} \sum \left| \frac{X_k - X_{0k}}{X_k} \right|, \text{ for } k = 1, 2, \dots, n \quad (14)$$

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، X_{0k}: مقدار واقعی دوره K و X₀: 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. Coefficieon of Determination
 4. Mean absolute Percentage error

بودن مقادیر مشاهده و پیش‌بینی شده 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) به‌منظور 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 موردنرسی قرار گرفته که در هر مدل با توجه به تعداد متغیرهای پذیرفته شده و زائد توسط الگوریتم GMDH، شبکه مورداستفاده 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 موردنیاز گردآوری گردید. داده‌های مربوط به دمای هوای میانگین رطوبت نسبی ماهیانه برگرفته از سایت اداره کل هواشناسی استان تهران است.

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

متغیرها	شرح
As	مساحت سکوهای هر ایستگاه
At	میانگین دمای ماهیانه هوای شهر تهران
Ncs	تعداد مراکز خدمت‌رسانی به مشتریان
Arh	میانگین رطوبت نسبی ماهیانه شهر تهران
Acu	مساحت واحدهای تجاری در هر ایستگاه
Np	تعداد مسافر در هرماه در خط یک
Nt	تعداد سفر در هرماه در خط یک
Ntm	تعداد حرکت قطارها در هرماه در خط یک
Nse	تعداد پله‌های برقی در هر ایستگاه
Ndc	تعداد روزهای تعطیل در هرماه
Ne	تعداد آسانسورها در هر ایستگاه
Nm	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 موردنبررسی قرارگرفته 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. درواقع الگوریتم GMDH خود متغیرهای مؤثر و زائد در هر مدل را شناسایی می‌کند و متغیر زائد را حذف می‌کند.

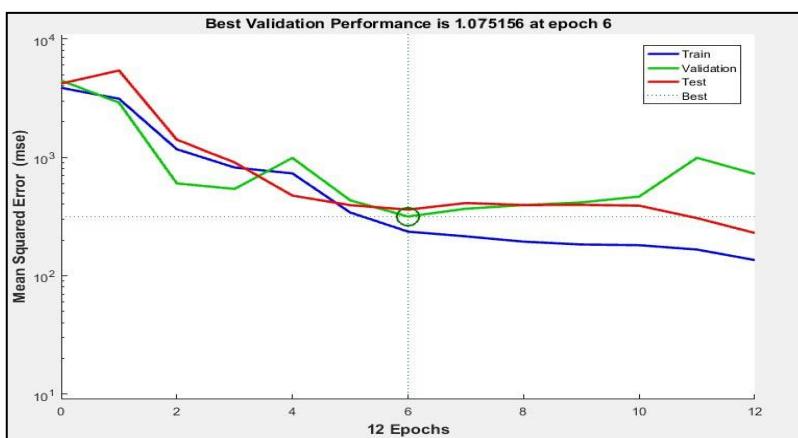
جدول ۲. نتایج حاصل از پیش‌بینی میزان مصرف انرژی خط یک متروی تهران

داده‌های آزمایشی	داده‌های آموزشی	داده‌های آزمایشی	داده‌های آموزشی	مؤثرترین متغیر	متغیرهای مدل	مدل
r^2	r^2	RMSE	MAPE	RMSE	MAPE	
۰.۷۰۳	۰.۷۱۴	۰.۸۶۷	۱۴.۵۴۶	۰.۸۴۵	۱۴.۲۱۳	At, Np, Nt As, At Arh, Np Nse, Nt ۱
۰.۷۴۳	۰.۷۶۶	۰.۷۹۵	۱۴.۰۱۲	۰.۷۸۷	۱۳.۹۵۶	Nc, Np, Nmt, At Nm, Ne, At, Nt m Np, Acu Ncs ۲
۰.۸۱۵	۰.۸۳۱	۰.۵۵۲	۱۳.۶۴۷	۰.۵۱۳	۱۳.۲۶۵	Nc, Np, Nmt, At As, Ncs At, Ntm Np, Arh Ne, Nse Nm ۳
۰.۹۲۳	۰.۹۵۲	۰.۳۹۳	۱۰.۷۱۸	۰.۳۴۲	۹.۲۸۴	Nc, At, Np, Nt, Nmt, Ndc Np, Acu Arh, Nt Ncs, At As, Ndc Nc, Nse Na, Nmt ۴

مأخذ: نتایج تحقیق

با توجه به نتایج بدست آمده، مدل چهارم که دارای مجذور میانگین مربعات خطأ، 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 بليت، میانگین دمای هوای ماهیانه شهر تهران، تعداد مسافر در هرماه در خط یک، تعداد سفر در هرماه در خط یک، تعداد حرکت قطارها در هرماه در خط یک و تعداد روزهای تعطیل در هرماه؛ 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، درنهایت در بهینه‌ترین 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 خطأ و برآش

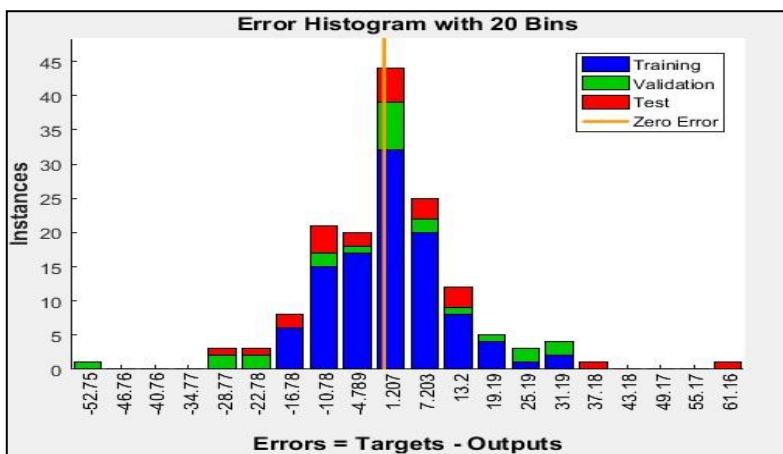
رگرسیون کنترل می‌شود. سرانجام لایه خروجی شامل یک نرون است. شبکه با هشت نرون در لایه میانی و در تکرار ششم با کمترین مقدار MSE بهترین عملکرد را دارد.



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

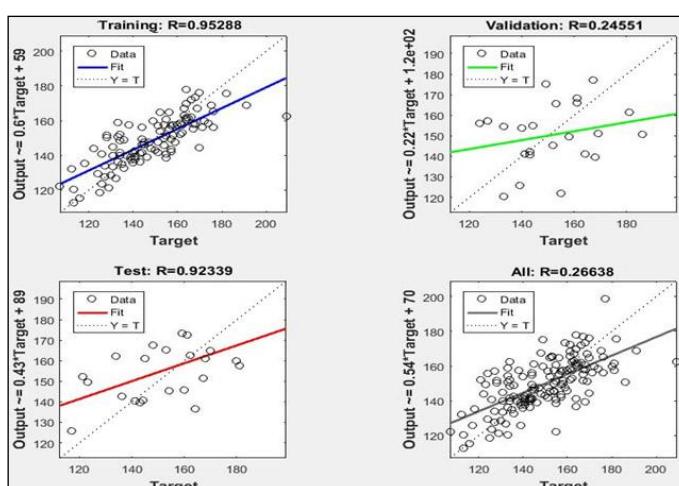
بنابراین، با انتخاب شبکه‌ای با هشت نرون در لایه میانی، همه خطای شبکه برای داده‌های آموزشی در اطراف صفر توزیع پیدا می‌کنند و توزیع خطاهای بایاس چندانی به طرف خاصی ندارد و این نشان‌دهنده عمل کرد بسیار خوب شبکه در تعلیم داده‌های تمرینی^۱ است شکل (۲).

1. Train data



شکل ۲. عمل کرد شبکه (منبع: یافته های تحقیق)

پس از عرضه نمونه های آموزشی به شبکه، وزن شبکه (پارامترهای آزاد) به گونه ای اصلاح می شوند که تفاوت پاسخ مطلوب و خروجی واقعی شبکه کمینه شود. این فرآیند با نمونه های ورودی تکرار می شود تا اینکه شبکه به حالت پایدار برسد و تغییر زیادی در وزن ها رخ ندهد [۱۵]. در شکل (۳) مقادیر خطای برای هر یک از داده های آموزشی، آزمایشی و اعتبار سنجی و مجموع کل داده ها نشان داده شده است.



شکل ۳. دقت شبکه عصبی جهت پیش بینی در مرحله آموزشی

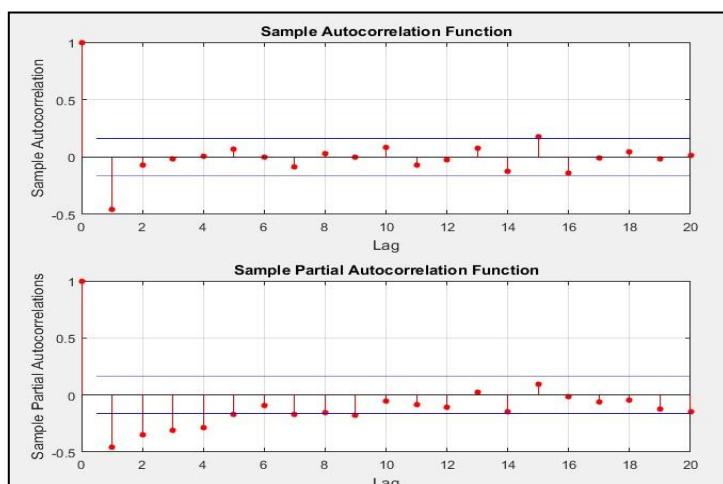
مدل سازی با استفاده از الگوی سری زمانی ARIMA

در این بخش به مدل سازی و پیش‌بینی میزان مصرف انرژی خط یک متروی تهران با استفاده از مدل آریما پرداخته شده است. در مدل ARIMA جهت برآورد الگو از نرم‌افزار MATLAB R2016a و از داده‌های فروردین سال ۱۳۹۰ تا اسفند سال ۱۳۹۵ استفاده شده است؛ بدین صورت که داده‌های فروردین ۱۳۹۰ تا آذر ۱۳۹۴ جهت مدل سازی و از داده‌های دی ۱۳۹۴ تا اسفند ۱۳۹۵ جهت ارزیابی عملکرد مدل در پیش‌بینی به کار گرفته شده است. متغیرهای پژوهش نیز به عنوان ورود مدل در نظر گرفته شده است. برای اینکه بهترین مدل ARIMA را برای پیش‌بینی میزان مصرف انرژی شناسایی کنیم نیازمند آن هستیم که داده‌ها را در وهله اول به حد ایستایی برسانیم. با انجام دو مرحله دیفرانسیل‌گیری، داده‌ها به حد ایستایی رسیده‌اند؛ 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. عموماً در این مرحله، برآوردهایی با درجات بالاتر انجام شده و بهترین الگو از بین آن‌ها با توجه به معیارهای آکائیک و شوارتز و همچنین نویه سفید بودن جملات پسماند انتخاب می‌شود. برای انتخاب الگوی مناسب از معیار آکائیک و شوارتز استفاده شده که بر این اساس الگوی ARIMA(1,1,1) انتخاب شده است. اما از آنجاکه هدف اصلی برآورد این الگوهای پیش‌بینی است، میزان خطای پیش‌بینی از اهمیت بیشتری در انتخاب الگو برخوردار است که همان الگویی که با معیار آکائیک انتخاب شد یعنی ARIMA(1,1,1) کمترین خطای پیش‌بینی را دارد. 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 معنی‌دار هستند و همین طور با توجه به نمودار خودهمبستگی و خودهمبستگی جزئی مدل‌های فراوانی برآورد شده و با اعمال قواعد مدل‌سازی با روش ARIMA و با توجه به معیار آکاییک و شوارتر، 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: یافته‌های تحقیق)

پس از انتخاب بهترین مدل، ازان جهت پیش‌بینی در دوره دی ۱۳۹۴ تا اسفند ۱۳۹۵ استفاده شده است. نتایج حاصل از پیش‌بینی در مدل ARIMA با توجه به معیارهای موردنظر در جدول ۴ ارائه شده است.

جدول ۴. خطای پیش‌بینی میزان مصرف انرژی در مدل ARIMA

داده‌های آزمایشی	داده‌های آموزشی	داده‌های آزمایشی		داده‌های آموزشی		مدل
r^2	r^2	RMSE	MAPE	RMSE	MAPE	
۰.۶۳۸	۰.۶۸۲	۰.۹۴۸	۱۷.۶۵۹	۰.۹۲۹	۱۶.۹۸۵	AR(1)

۵. نتیجه‌گیری

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 دقیق 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 ARIMA در مدل‌های GMDH به ترتیب ۰.۸۶۷، ۰.۷۹۵، ۰.۵۵۲ و در مدل RMSE ۰.۳۹۳ 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 نشان‌دهنده قدرت خوب پیش‌بینی این مدل است. درنتیجه 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 به کارگیری 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 به کارگیری 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 به کارگیری شبکه عصبی پرسپترون چندلایه، وابستگی غیرخطی میان مصرف انرژی با پارامترهای مربوط به ویژگی‌های طراحی ایستگاه‌های مترو و پارامترهای هواشناسی مدل‌سازی دست یافتد 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 به کارگیری روش شبکه‌های عصبی و روش تحلیل سری‌های زمانی مصرف انرژی در بخش حمل و نقل 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 هر ماه مورد استفاده قرار گرفته و از این رو نقطه قوت این پژوهش استفاده از متغیرهای دیگر علاوه بر این متغیرهایی است؛ 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 سکوهای هر ایستگاه است که در هر ایستگاه به‌طور جداگانه موردنبررسی قرار گرفته و در مدل به کار رفته 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 موردنیاز؛ 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؛ غنیمی‌فرد، حجت‌الله؛ احراری. مهدی و منیزه رضایی (۱۳۸۹)، پیش‌بینی قیمت گازوئیل خلیج فارس، مبنی بر تحلیل تکنیکی و شبکه‌های عصبی، *فصلنامه مطالعات اقتصاد انرژی*، سال هفتم، شماره ۲۴، ص ۱۷۱-۱۹۲.
- [۳] اصغری اسکوئی، 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 مهارلوی (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] داغیندان، 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] رمضانی، رضا (۱۳۸۳)، مقایسه عملکرد پیش‌بینی در مدل‌های شبکه عصبی مصنوعی و ARIMA (موردمطالعه: تقاضای ماهیانه برق در ایران)، پایان‌نامه کارشناسی ارشد علوم اقتصادی، دانشگاه تهران.
- [۸] شاه حسینی، امید؛ سلیمانی، زهره؛ گودرزی، رضا و محمد علیمردانی (۱۳۸۹)، پیش‌بینی تقاضای انرژی الکتریکی در بخش حمل و نقل ایران توسط مدل MAED تا سال ۱۳۹۵، نشریه انرژی ایران، دوره ۱، ص ۱۱-۲۴.
- [۹] صادقی، حسین؛ افضلیان، علی‌اکبر؛ حقانی، محمود و حسین شهرابی 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] طخاری، محمدحسین؛ بابایی، حمید و روح‌الله تقی‌زاده (۱۳۹۱)، الگوسازی و پیش‌بینی مصرف انرژی بخش حمل و نقل 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] گرمابدی، یاسمون (۱۳۹۳)، پیش‌بینی مصرف انرژی در متروی تهران با استفاده از شبکه‌های عصبی، پایان‌نامه کارشناسی ارشد، دانشگاه آزاد اسلامی واحد علوم و تحقیقات.
- [۱۳] محمدمقی‌ها، علی و فرشید کریمی (۱۳۹۲)، بهینه‌سازی مصرف انرژی در حمل و نقل شهری در افق ایران ۱۴۰۴ با تأکید بر توسعه مترو، مجله حمل و نقل و توسعه، دوره ۷۴، ص ۴۱-۴۷.
- [۱۴] منهاج، محمدباقر؛ کاظمی، عالیه؛ شکوری، حامد؛ مهرگان، محمدرضا و محمد رضا تقی‌زاده (۱۳۸۸)، پیش‌بینی تقاضای انرژی بخش حمل و نقل با استفاده از شبکه‌های عصبی: مطالعه موردی در ایران، پژوهش‌های مدیریت در ایران، ۲۰۳، ص ۲۰-۲۲.
- [۱۵] مهدی‌زاده، 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” *Appplie 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 GroupMethod 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 Production*. 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] Kavaklıoglu 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

علام 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	خودرگرسیون میانگین متخرک انشا شده
SNE	Solving Normal Equation	حل معادلات نرمال
PAC	Partial auto correlation	خودهمبستگی جزئی
AC	Auto correlation	خودهمبستگی
RMSE	Root mean square error	میانگین مربعات مجدد خطای
R ²	Coefficient of Determination	ضریب تعیین
MAPE	Mean absolute Percentage error	متوجه درصد خطای مطلق
ADF	Augmented Dicky Fuller	آزمون دیکی فولر
LSE	Least Squares Error	کمترین مربعات خطای
نمادها		
X _i	Input to Model	متغیر ورودی
A _i	Volterra series Coefficients	ضرایب سری ولترا در مدل GMDH
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
Np	Number of passengers	تعداد مسافر در هر ماه در خط یک
Nt	Number of travel	تعداد سفر در هر ماه در خط یک
Ntm	Number of train movements	تعداد حرکت قطارها در هر ماه در خط یک
Nse	Number of stairs electric	تعداد پلههای برقی در هر ایستگاه
Nh	Number of holidays	تعداد روزهای تعطیل در هر ماه
Ne	Number of elevators	تعداد آسانسورها در هر ایستگاه
Nm	Number of machines	تعداد ماشینهای فروش بلیط