

پیش‌بینی مصرف انرژی بخش کشاورزی ایران

با استفاده از مدل ترکیبی الگوریتم ژنتیک و شبکه‌های عصبی مصنوعی

روح‌اله تقی‌زاده مهرجردی*^۱، احمد فتاحی اردکانی^۱، محمد حسین طهاری^۲، حمید بابایی^۳

تاریخ دریافت: ۹۴/۰۳/۲۵ تاریخ پذیرش: ۹۴/۰۷/۱۴

چکیده

هدف از این مقاله ارزیابی الگوی ترکیبی شبکه‌های عصبی مصنوعی و الگوریتم ژنتیک در پیش‌بینی تقاضای انرژی بخش کشاورزی ایران می‌باشد. برای این منظور، از داده‌های سالانه مصرف انرژی بخش کشاورزی کشور به عنوان متغیر خروجی مدل‌های پیش‌بینی و از داده‌های سالانه جمعیت کل کشور و کل تولیدات بخش کشاورزی کشور به عنوان متغیرهای ورودی مدل‌های پیش‌بینی استفاده شد. در پایان به منظور مقایسه نتایج پیش‌بینی مدل ترکیبی مذکور با مدل‌های شبکه‌های عصبی مصنوعی و برنامه‌ریزی ژنتیک، از شاخص‌های ارزیابی خطای استاندارد نسبی، میانگین خطا، میانگین قدر مطلق درصد خطا و مجذور میانگین مربعات خطا استفاده شد. نتایج ارزیابی نشان داد که الگوی ترکیبی شبکه‌های عصبی و الگوریتم ژنتیک، نسبت به مدل شبکه عصبی مصنوعی و برنامه‌ریزی ژنتیک دارای بالاترین دقت در پیش‌بینی تقاضای انرژی بخش کشاورزی کشور می‌باشد. پیشنهاد می‌شود در تحقیقات آتی با استفاده از مدل ترکیبی مذکور به پیش‌بینی مصرف انرژی در سایر بخش‌های اقتصادی پرداخته شود و کارایی آن سنجیده شود.

طبقه‌بندی *JEL*: C53, Q47

واژه‌های کلیدی: مصرف انرژی، بخش کشاورزی ایران، برنامه‌ریزی ژنتیک، شبکه‌های عصبی مصنوعی، الگوریتم ژنتیک.

۱- استادیار گروه اقتصاد کشاورزی دانشگاه اردکان.

۲- کارشناسی ارشد مدیریت صنعتی، دانشگاه علمی و کاربردی میبد.

۳- دانشجوی دکتری مدیریت صنعتی دانشگاه تربیت مدرس.

* نویسنده‌ی مسئول مقاله، rtaghizadeh@ardakan.ac.ir

پیشگفتار

آگاهی از میزان مصرف حامل‌های انرژی در بخش کشاورزی در آینده از چند بعد حائز اهمیت است و مطالعه‌ی روش مناسب، پیش‌بینی مصرف آن را به یک ضرورت تبدیل می‌کند (آرمن و زارع، ۱۳۸۸). نخست اینکه به عنوان یک نهاده‌ی مهم در تولید، به دنبال تجاری شدن هر چه بیشتر این بخش، وابستگی نیز به آن بیشتر شده و نقش کلیدی‌تری در تولید خواهد یافت. مطلب دیگر، ملاحظات زیست محیطی است که به تازگی بیشتر مورد توجه قرار گرفته است و انتظار می‌رود که آگاهی از میزان مصرف منابع انرژی در زمینه‌ی اتخاذ سیاست‌های زیست محیطی مناسب‌تر، مفید واقع شود. افزون بر این، آگاهی از میزان مصرف انرژی می‌تواند در برنامه‌ریزی سیاست‌های کلی و کلان بخش کشاورزی نیز رهنمون‌های مفیدی ارائه دهد (موسوی و همکاران، ۱۳۸۹). بنابراین مسئولان کشور باید تلاش کنند تا با پیش‌بینی هرچه دقیق‌تر مصرف انرژی در این بخش و برنامه‌ریزی صحیح در هدایت مصرف، پارامترهای عرضه و تقاضای انرژی در بخش کشاورزی کشور را به نحو مطلوب کنترل کنند.

امروزه استفاده از تکنولوژی‌های هوشمند برای حل مسائل عملی پیچیده در بخش‌های مختلف صنعتی مورد توجه بسیار قرار گرفته اند. این سیستم‌ها با انجام محاسبات بر اساس داده‌های تجربی، قوانین کلی را فرا می‌گیرند. از این رو به آنها سیستم‌های هوشمند می‌گویند. شبکه‌های عصبی مصنوعی جز دسته‌ای از سیستم‌های هوشمند هستند که دانش نهفته در ورای داده‌ها را با پردازش داده‌های تجربی به ساختار شبکه منتقل می‌کنند. بزرگ‌ترین مزیت شبکه‌های عصبی، توانایی آن‌ها در مدل کردن روابط غیرخطی پیچیده، بدون در نظر گرفتن فرضیات قبلی است. شبکه‌های عصبی به دلیل عملکرد موفق در زمینه تشخیص و شناسایی مدل، در بسیاری از مسائل پیش‌بینی، مورد استفاده قرار گرفته‌اند که به طور نمونه می‌توان به موارد زیر اشاره نمود.

امین ناصری و کوچک زاده (۱۳۸۷)، یک مدل مبتنی بر تکنیک طراحی آزمایش‌ها برای طراحی بهینه معماری شبکه عصبی با یادگیری تحت نظارت، با توجه به اثر متقابل بین عوامل ذکر شده ارائه کردند. در این تحقیق، از مدل پیشنهادی برای طراحی معماری شبکه عصبی به منظور پیش‌بینی مصرف نفت گاز کل کشور استفاده شد. به منظور مقایسه عملکرد مدل پیشنهادی با استفاده از روش سعی و خطا به عنوان یکی از روش‌های مرسوم در طراحی معماری، یک مدل شبکه عصبی برای پیش‌بینی مصرف نفت گاز توسعه داده شده و طی آن برتری مدل پیشنهادی نشان داده شد. همچنین برای مقایسه عملکرد شبکه عصبی با روش‌های آماری، دو مدل با استفاده از رگرسیون و ARIMA طراحی شدند. نتایج به دست آمده در پیش‌بینی مصرف نفت گاز در این بخش نیز نشان می‌دهد که پیش‌بینی با شبکه عصبی طراحی شده جواب‌های بهتری دارد.

ابریشمی و همکاران (۱۳۸۹)، از شبکه‌ی عصبی GMDH، برای پیش‌بینی قیمت گازوئیل مبتنی بر قواعد تحلیل تکنیکی، شامل میانگین‌های متحرک کوتاه‌مدت و بلندمدت، به عنوان ورودی شبکه، طی دوره‌های مختلف بازار، استفاده کردند. در این بررسی نیز پیش‌بینی‌های شبکه‌ی عصبی نسبت به روش سری زمانی، از خطای کمتر و دقت بالاتری برخوردار است.

شکیبایی و همکاران (۱۳۸۸)، سعی کردند علاوه بر پیش‌بینی تولید نفت خام در یازده کشور تولیدکننده، با استفاده از دو مدل رگرسیون خطی و شبکه‌های عصبی، نتایج به دست آمده در هر کشور به طور مجزا مقایسه شود. تخمین‌ها حاکی از آن است که شبکه‌های عصبی پیش‌بینی‌های بهتری نسبت به مدل‌های رگرسیون خطی ارائه می‌کنند.

آذری و همکاران (۱۳۸۷)، از شبکه عصبی مصنوعی به سبب قابلیت فوق‌العاده آن در تقلید از نگاشت غیرخطی ورودی‌ها به خروجی‌ها برای پیش‌بینی کوتاه مدت میزان مصرف گاز طبیعی شهر تهران استفاده کردند. مقایسه نتایج حاصل از پیش‌بینی با مقادیر واقعی مصرف گاز حاکی از آن است که دقت مدل در خصوص مصرف روزانه و ماهانه گاز به ترتیب حدود ۹۳ و ۹۹ درصد می‌باشد. بنابراین مدل‌های طراحی شده، برای تخمین مصرف گاز شهر تهران بزرگ مناسب می‌باشد.

پورکاظمی و اسدی (۱۳۸۸)، به پیش‌بینی پویای قیمت نفت خام با استفاده از شبکه‌های عصبی مصنوعی و روش اقتصادسنجی ARIMA پرداختند. نتایج این پژوهش حاکی از این بود که پیش‌بینی‌های شبکه‌ی عصبی در مقایسه با روش ARIMA از خطای کمتر برخوردار است. منهای و همکاران (۱۳۸۹)، با استفاده از شبکه‌های عصبی مصنوعی و با در نظر گرفتن شاخص‌های اقتصادی و اجتماعی، تقاضای انرژی بخش حمل و نقل کشور در سال‌های ۱۳۸۶ تا ۱۴۰۰ پیش‌بینی کردند. در پژوهش آنها از شبکه‌های عصبی پیش‌خور با ناظر برای پیش‌بینی و الگوریتم پس انتشار برای آموزش شبکه‌ها استفاده شده است. نتایج حاصل از پیش‌بینی با این روش در مقایسه با روش رگرسیون چندمتغیره، نشان دهنده خطای به مراتب کمتری است. به طوری که درصد میانگین قدرمطلق خطا از ۱۵ درصد به ۶ درصد کاهش یافت.

صادقی و همکاران (۱۳۹۰)، با استفاده از شبکه‌ی عصبی مصنوعی مبتنی بر انتظارات قیمتی برای داده‌های روزانه، به مدلسازی و پیش‌بینی روزانه‌ی قیمت سبد نفت خام اوپک پرداختند و نتایج آن با مقادیر پیش‌بینی شده توسط مدل ARIMA بر اساس معیارهای اندازه‌گیری دقت پیش‌بینی، مورد مقایسه قرار گرفته است. نتایج تحقیق نشان می‌دهد که شبکه‌ی عصبی مورد استفاده، نسبت به مدل ARIMA از قدرت پیش‌بینی بهتری برخوردار است.

دشتی رحمت آبادی و همکاران (۱۳۹۰)، در پژوهشی به معرفی الگوهای مطلوب پیش‌بینی برای قیمت نفت خام ایران پرداختند. الگوهای مورد استفاده برای پیش‌بینی، شامل چهار الگوی شبکه‌ی عصبی و یک الگوی رگرسیونی (خودرگرسیون میانگین متحرک) بود. شبکه‌های منتخب شامل شبکه‌ی پیشخور پس انتشار، شبکه‌ی آبخاری پس انتشار، شبکه‌ی المان پس انتشار و شبکه‌ی رگرسیون تعمیم یافته می‌باشد. یافته‌های به دست آمده نشان می‌دهد برای پیش‌بینی ۱۰ درصد از داده‌های قیمت نفت خام، الگوهای شبکه‌ی رگرسیون تعمیم یافته و شبکه‌ی آبخاری پس انتشار با تابع آموزش شبه نیوتنی، به ترتیب با خطایی کمتر از ۱ و کمتر از ۲ درصد دارای بهترین عملکرد هستند. برای پیش‌بینی ۲۰ درصد داده‌های قیمت نفت خام ایران، شبکه‌ی پیشخور پس انتشار و شبکه‌ی المان پس انتشار با تابع آموزش لونیبرگ-مارکوات، دارای عملکرد بهتر می‌باشند. در مورد ۳۰ درصد از داده‌ها نیز شبکه‌ی پیشخور پس انتشار مطلوبتر ارزیابی شده است. همچنین نتایج نشان می‌دهد به طور نسبی با افزایش درصد داده‌های مورد استفاده در پیش‌بینی، دقت پیش‌بینی‌ها به ویژه با افزایش از ۱۰ درصد به ۲۰ درصد رو به افول می‌رود. دقت پیش‌بینی خود رگرسیون میانگین متحرک نیز پایین تر از الگوهای شبکه‌ی عصبی ارزیابی می‌شود. کالگیرا (۲۰۰۰)، از تکنیک شبکه‌های عصبی مصنوعی برای پیش‌بینی میزان انرژی گرمایی مصرفی در ساختمان‌ها و پیش‌بینی مصرف انرژی در یک ساختمان خورشیدی غیرفعال استفاده نمود (جبری و اینیاب، ۲۰۰۶).

نصر و همکاران (۲۰۰۳) نیز با استفاده از شبکه‌های عصبی و الگوریتم پس انتشار به پیش‌بینی مصرف بنزین در کشور لبنان پرداختند.

مورات و سیلان (۲۰۰۶)، با استفاده از یک شبکه‌ی عصبی سه لایه و الگوریتم پس انتشار انرژی بخش حمل و نقل کشور ترکیه را پیش‌بینی کردند. در بررسی آنها از شاخصهای تولید ناخالص داخلی، جمعیت و تعداد خودرو در هر کیلومتر به عنوان ورودی‌های شبکه‌ی عصبی در نظر گرفته شده است (شکیبایی و همکاران، ۱۳۸۸).

سازن و همکاران (۲۰۰۷)، به منظور پیش‌بینی مصرف فرآورده‌های نفتی در ترکیه یک مدل شبکه عصبی ارائه کردند. در پژوهش آنها سه مدل مختلف طراحی و در پایان با استفاده از معیارهای خطا یک مدل را به عنوان مدل مناسب برای پیش‌بینی مصرف فرآورده های نفتی در ترکیه انتخاب کردند. تحقیقات یو و همکاران (۲۰۰۸)، همچنین از جمله این مطالعات هستند که یافته‌های آنها حاکی از برتری شبکه‌ی عصبی بر خود رگرسیون میانگین متحرک در پیش‌بینی است. به طور کلی می‌توان گفت استفاده از شبکه‌ی عصبی در پیش‌بینی قیمت حامل های انرژی، بیشتر مورد توجه بوده و دقت بالاتر آن نیز در مطالعات مقایسه ای مورد تاکید قرار گرفته است.

کولکاری و حیدر (۲۰۰۹)، در پژوهشی به پیش بینی قیمت نفت خام برای سه روز آینده پرداختند و آنها این طور نتیجه گیری کرده اند که یک مدل دینامیک با ۱۳ تأخیر برای پیش بینی کوتاه مدت قیمت نقطه ای نفت خام، مناسب است. همچنین دقت پیش بینی به ترتیب ۶۶، ۷۸ و ۵۳ درصد برای یک، دو و سه روز آینده تخمین زده شد.

اکبری و همکاران (۲۰۱۴) با استفاده از روش های اقتصادسنجی و هوش مصنوعی (شبکه عصبی مصنوعی و الگوریتم ژنتیک) اقدام به پیش بینی میزان صادرات خرمای ایران برای دوره های ۱۳۹۵-۱۳۶۴ نمودند. نتایج ایشان کارایی بالای روش های هوش مصنوعی را تایید نمود.

همچنین مهرابی بشرآبادی و کوچک زاده (۲۰۰۹) نیز توانایی بالای روش شبکه عصبی مصنوعی را جهت پیش بینی صادرات بخش کشاورزی تایید نمودند. همان طور که ملاحظه می شود، با توجه به اهمیت موضوع انرژی، پژوهش های متعددی درباره پیش بینی قیمت و مصرف انرژی انجام شده است که در هر کدام از آنها، بررسی و پیش بینی با استفاده از روش خاصی انجام شده است. پژوهش های مذکور، به دو گروه تقسیم می شود: بررسی هایی که با روش اقتصادسنجی و پژوهش هایی که با روش هوش مصنوعی و شبکه های عصبی انجام شده است. در همه پژوهش های مذکور، کارایی و دقت بالاتر الگوهای شبکه عصبی تایید گردیده است. با توجه به این تحقیقات استفاده بهتر از شبکه عصبی، مستلزم بهینه سازی پارامترهای مورد استفاده در آن می باشد. برای تعیین بهترین مقادیر پارامترهای شبکه های عصبی مانند تعداد لایه ها و نرون های در هر شبکه، زمان زیادی صرف واسنجی این پارامترها به روش آزمون و خطا می شود.

به همین منظور، در این پژوهش از ترکیب شبکه های عصبی مصنوعی و الگوریتم ژنتیک جهت برآورد مصرف انرژی بخش کشاورزی کشور استفاده شده است و سپس نتایج آن با مدل های شبکه عصبی مصنوعی و برنامه ریزی ژنتیک مورد ارزیابی و مقایسه قرار گرفته است.

مبانی نظری و روش تحقیق

برنامه ریزی ژنتیک

برنامه ریزی ژنتیک (GP): در برنامه ریزی ژنتیک، ابتدا بلوک های موجود که شامل متغیرهای ورودی و هدف و نیز تابع ارتباط دهنده آنها می باشند، تعریف گردیده و سپس ساختار مناسب مدل و ضرایب آن تعیین می شود. این روش شامل یک معادله ارتباط دهنده بین متغیرهای ورودی و خروجی بوده، لذا قادر به انتخاب خودکار متغیرهای مناسب مدل و حذف متغیرهای غیر مرتبط است که این امر سبب کاهش ابعاد متغیرهای ورودی خواهد شد. انتخاب ورودی های یکی از مهم ترین مواردی است که باید مورد توجه قرار گیرد. این امر در شرایطی که از داده های ورودی مختلفی نیز بهره برده می شود، از اهمیت مضاعفی برخوردار خواهد بود. چرا که ارائه داده های

ورودی غیرمرتبط، سبب کاهش دقت مدل و ایجاد مدل‌های پیچیده‌تری می‌گردد که تفسیر آنها با دشواری‌های بیشتری مواجه است. فرآیند گام به گام برنامه‌ریزی ژنتیک به صورت مراحل زیر است:

(۱) یک جمعیت اولیه از توابع مرکب نشان دهنده مدل‌های پیش‌بینی، به صورت تصادفی در نظر گرفته می‌شود (ایجاد کروموزوم‌ها).

(۲) معرفی جمعیت اولیه (کروموزوم‌ها) به رایانه و ارزیابی هر یک از افراد (ژن) جمعیت مذکور با استفاده از توابع برازش (شناسایی موثرترین افراد در ماهیت پدیده).

(۳) انتخاب ژن‌های موثر به منظور تکثیر، جهش، جفت‌گیری و تولید مثل افراد جدید با صفات اصلاح شده (فرزندان).

(۴) اعمال فرایند توسعه‌ای تکراری بر روی فرزندان در هر تولید (گلدبرگ، ۱۹۸۹).

شبکه عصبی مصنوعی

الگوهای گوناگونی از جمله روش‌های سنتی، آماری مانند میانگین متحرک، میانگین موزون و ARIMA به منظور پیش‌بینی سری‌های زمانی وجود دارند. الگوهای خطی با وجود برخی مزیت‌ها، با ضعف‌هایی از جمله عدم توانایی در بیان روابط غیر خطی، روبرو هستند. به طوری که برای جبران این ضعف‌ها، چندین روش غیرخطی در این رابطه پیشنهاد شده است. در سال‌های اخیر شبکه‌های عصبی مصنوعی برای پیش‌بینی سری‌های زمانی به کار رفته است. به طوری که یکی از بزرگ‌ترین مزیت‌های شبکه‌های عصبی، انعطاف‌پذیری آن برای پیش‌بینی انواع مدل‌های غیر خطی است (زهانگ، ۲۰۰۳).

شبکه‌ی عصبی مصنوعی یک روش شبیه‌سازی می‌باشد که از مطالعه سیستم مغز و شبکه عصبی موجودات زنده الهام گرفته است. قدرت بالای عملکرد سیستم‌های بیولوژیک ناشی از طبیعت موازی برنامه‌ریزی نرون‌های آنها می‌باشد، یک شبکه عصبی مصنوعی این ساختار را با توزیع شبیه‌سازی در واحدهای پردازشگر کوچک و ساده به هم پیوسته (که نرون نامیده می‌شود) انجام می‌دهد. نقش اصلی یک نرون بیولوژیک عمل جمع ورودی‌های خود تا جایی است که مجموع ورودی‌های آن از حدی که به آن آستانه می‌گوییم تجاوز نکند و آنگاه تولید یک خروجی می‌باشد (منهاج، ۱۳۸۴).

یکی از مدل‌های شبکه‌های عصبی مورد استفاده، شبکه عصبی پرسپترون چندلایه با الگوریتم پیشخور یادگیری می‌باشد (شکل ۱). پرسپترون چند لایه یک ترکیب استاندارد از ورودی‌ها، واحدهای عصبی خطی و غیرخطی و خروجی‌ها می‌باشد. خروجی تمام واحدهای پردازش از هر لایه به تمام واحدهای پردازش لایه بعدی انتقال داده می‌شود. واحدهای پردازش لایه ورودی همگی خطی هستند، ولی در لایه مخفی از نرون‌ها با تابع تانژانت سیگموئید، هایپربولیک یا هر تابع

غیرخطی و پیوسته مشتق پذیر دیگری می‌توان استفاده کرد. معمولاً برای افزایش سرعت آموزش، نرون‌های لایه خروجی خطی انتخاب می‌گردد. شبکه‌های عصبی با لایه‌های پنهان که به شبکه‌های پرسپترون چند لایه معروفاند، دارای توانایی‌های بیشتری نسبت به شبکه‌های عصبی دو لایه هستند که علامه بر لایه‌های ورودی و خروجی دارای لایه‌های پنهان نیز می‌باشند. بر خلاف واحدهای ورودی و خروجی واحدهای پنهان هیچ مفهومی را نشان نمی‌دهند. واحدهای پنهان تفسیر یا معنی خاصی ندارند و صرفاً یک نتیجه میانی در فرایند محاسبه ارزش خروجی هستند. واحدهای پنهان شبیه واحدهای خروجی رفتار می‌کنند. برای نمونه، آن‌ها مجموع موزونی از متغیرهای ورودی را محاسبه و سپس با استفاده از یک تابع فعال‌سازی که در بیشتر مواقع لجستیک است، نتیجه را پردازش می‌کنند.

مساله اصلی در این شبکه‌ها تعیین تعداد لایه‌های پنهان و تعداد نرون‌های آنها می‌باشد که در این رابطه نظرات متفاوتی وجود دارد. تعداد گره‌های مخفی به این علت اهمیت دارد که گره‌های مخفی نقشی قابل توجه در خاصیت پیکره بندی غیرخطی شبکه‌های عصبی دارند (زهانگ، ۲۰۰۳). در تعیین تعداد گره‌های ورودی استفاده از روش آزمون و خطا بیشترین کاربرد دارد. اما به طور کلی تعداد نرون‌های لایه ورودی بیانگر تعداد متغیرهای ورودی است (مالیک و ناصرالدین، ۲۰۰۶). در این مورد نیلسون (۱۹۸۷) ثابت کرد که در شبکه‌های عصبی با یک لایه مخفی با تابع سیگموئید

$$f(x) = \frac{1}{1+e^{-x}}$$

(X مجموع وزن‌های ورودی است و e لگاریتم طبیعی است) در لایه میانی و تابع خطی در لایه خروجی قادر به تقریب تمامی توابع مورد نظر با هر درجه تقریب خواهد بود، مشروط به این که به اندازه کافی نرون در لایه مخفی وجود داشته باشد. این قضیه به تقریب ساز جهانی^۱ معروف می‌باشد (منهاج، ۱۳۸۴؛ حمید و اقبال، ۲۰۰۴).

در طراحی مدل شبکه عصبی، در واقع باید اندازه مجموعه یادگیری و آزمایشی، نرمال کردن داده‌ها، تعداد لایه‌های پنهان شبکه، تعداد نرون‌های هر لایه، الگوریتم‌های یادگیری، تابع تبدیل، تابع عملکرد، نرخ یادگیری و تعداد تکرارها مشخص گردد. در تعیین این موارد، روش‌های سیستماتیکی وجود ندارد، بنابراین، بهترین طراحی شبکه با استفاده از تجربه و آزمایش و خطا به دست می‌آید. در صورتی که داده‌ها به صورت خام وارد شبکه شود، به علت تغییرات زیاد داده‌ها، تاثیر متفاوتی بر روی شبکه گذاشته، به طوری که برخی از نرون‌های خیلی زود به حد آتش رسیده، در حالی که برخی دیگر از نرون‌ها حتی به آستانه فعالیت نیز نرسیده‌اند و این باعث خواهد شد که توان پیش بینی مدل پایین خواهد آمد (منهاج، ۱۳۸۴). لذا در ابتدا باید داده‌ها با استفاده

1 Universal Approximation

از رابطه زیر استاندارد شده، یعنی بین یک دامنه عددی که معمولا (۰/۱ و ۰/۹) می باشد، قرار گیرند.

$$y = 0.8 \times \frac{X_i - X_{min}}{X_{max} - X_{min}} + 0.1 \quad (1)$$

که در آن: X_{min} کوچکترین داده و X_{max} بزرگترین داده سری داده‌های ورودی می‌باشد. با استفاده از این رابطه، داده‌های ورودی بین ۰/۱ و ۰/۹ قرار می‌گیرد.

مدل ترکیبی شبکه عصبی و روش الگوریتم ژنتیک (ANN-GA)

الگوریتم ژنتیک یک روش برنامه نویسی است که از تکامل ژنتیکی به عنوان الگوی حل مساله استفاده می‌کند. الگوریتم ژنتیک بخشی از نظریه محاسبه تکاملی است که در حال حاضر به عنوان بخشی از هوش مصنوعی به سرعت در حال رشد می‌باشد. ایده اصلی این الگوریتم در نظریه تکاملی داروین نهفته است. از نظر کاربردی، الگوریتم ژنتیک یکی از روش‌های بهینه‌سازی مسائل است که اساس آن در بر انتخاب طبیعی و برخی از مفاهیم مهم از علم ژنتیک استوار است. در این روش برای بهینه‌سازی تابع هدف مسئله، از یک جمعیت اولیه کروموزوم‌ها که در حقیقت پاسخ‌های اولیه مسئله هستند، به یک جمعیت جدید از کروموزوم‌ها یا یک نسل جدید که در حقیقت پاسخ‌های ثانویه مساله مفروض است، می‌رسد. با تکرار این عملیات و تولید جمعیت جدید از جمعیت قبلی در هر مرحله و در نتیجه رسیدن به نسل‌های موفق، جمعیت به سمت یک پاسخ بهینه رشد خواهد کرد. در حقیقت در این روش ابتدا برای تعدادی ثابت که جمعیت نامیده می‌شود مجموعه‌ای از داده‌ها و پارامترهای هدف بصورت اتفاقی تولید می‌شود و افراد در برابر این مجموعه از داده‌ها مورد آزمایش قرار گرفته و مناسبترین آنها باقی مانده، نسل جدید را شکل می‌دهند و این فرآیند برای نسل‌های بعدی تا ارضای معیار همگرایی تکرار می‌شود.

مراحل ترکیب و توسعه مدل تلفیقی شبکه عصبی و الگوریتم ژنتیک جهت پیش‌بینی تقاضای انرژی در بخش کشاورزی ایران به شرح ذیل می‌باشد (گلدبرگ، ۱۹۸۹):

مرحله ۱: تعداد جمعیت موجود در هر نسل و تعداد نسل حداکثر در مرحله اول مشخص می‌شود و در این مرحله یک جمعیت اولیه تصادفی به وجود می‌آید.

مرحله ۲: در این مرحله شاکله شبکه عصبی مصنوعی با استفاده از مقادیر ژن‌های موجود در هر جمعیت ایجاد شده تعیین می‌گردد.

مرحله ۳: شبکه طراحی شده با استفاده از داده‌های نرمال شده ورودی آموزش می‌بیند. بعد از آموزش شبکه، مراحل واسنجی و آموزش شبکه نیز در این گام صورت می‌گیرد.

مرحله ۴: پس از انجام پیش‌بینی با استفاده از شبکه طراحی شده معیار میانگین مجذور خطا محاسبه می‌شود. با محاسبه این معیار تابع هدف مسئله که در این پژوهش حداقل کردن میانگین مربعات خطا می‌باشد، تعیین می‌شود.

مرحله ۵: به منظور ایجاد نسل بعد از عملگرهایی نظیر عملگرهای ژنتیکی و تکاملی مانند ترکیب و جهش ژنی و نیز چرخه رولت جهت انتخاب نسل بعد در الگوریتم ژنتیک استفاده می‌شود. در این مرحله از نخبه‌گرایی نیز استفاده می‌شود که با استفاده از آن برخی از بهترین‌های جمعیت نسل حاضر به نسل بعد منتقل می‌شود.

مرحله ۶: در این مرحله جمعیت جدید ایجاد شده جایگزین جمعیت قبلی شده تا نسل جدید به وجود آید. در این مرحله به شماره نسل مقدار ۱ اضافه می‌شود و تا زمانی که شماره نسل به مقدار ماکزیمم خود برسد، مراحل فوق تکرار می‌شوند.

شاخص‌های ارزیابی مدل‌ها

در این تحقیق، به منظور ارزیابی عملکرد مدل‌های شبکه عصبی/ژنتیک، شبکه عصبی مصنوعی و برنامه‌ریزی ژنتیک از پارامترهای خطای استاندارد نسبی (RSE)، میانگین خطا (ME)، مجذور میانگین مربعات خطا (RMSE) و میانگین قدر مطلق درصد خطا (MAPE) که از روابط زیر قابل محاسبه می‌باشند استفاده گردید.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Z_0 - Z_p)^2} \quad (2) \quad RSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (Z_0 - Z_p)^2}}{Z_{ave}} \quad (3)$$

$$ME = \frac{1}{n} \sum (Z_0 - Z_p) \quad (4) \quad RI = \left(\frac{RMSE_a - RMSE_b}{RMSE_a} \right) \times 100 \quad (5)$$

$$MAPE = \frac{1}{n} \sum_{k=1}^N \frac{|Z_0 - Z_p|}{Z_0} \quad (6)$$

که در آنها: Z_0 مقادیر پیش‌بینی شده، Z_p مقادیر مشاهداتی، Z_{ave} متوسط مقادیر مشاهداتی و n تعداد داده‌ها می‌باشد. در رابطه ۵، $RSME_a$ بیانگر مجذور میانگین مربعات خطای بدترین مدل و $RSME_b$ بیانگر مجذور میانگین مربعات خطای سایر مدل‌ها است. هر چه مقدار خطای استاندارد نسبی، میانگین خطا، مجذور مربعات خطا و میانگین قدر مطلق درصد خطا کمتر و در مقابل مقدار بهبود نسبی بیشتر باشد، نشان‌دهنده دقت بالاتر مدل می‌باشد.

داده‌ها

با توجه به اینکه شبکه‌های عصبی مصنوعی مبتنی بر داده هستند، آماده‌سازی داده‌ها یک قدم مهم و در واقع کلید موفقیت در استفاده از شبکه عصبی است. هر چقدر تعداد داده‌ها بیشتر باشد،

می‌توان در خصوص تقریب ساختار نهفته در مدل، اطمینان بیشتری حاصل نمود. در این تحقیق از داده‌های سالانه مصرف انرژی بخش کشاورزی کشور (اعم از انرژی برق، گاز طبیعی و فرآورده‌های نفتی) به عنوان متغیر خروجی مدل‌های پیش‌بینی و از داده‌های سالانه جمعیت کل کشور و تولیدات بخش کشاورز (شامل کل تولیدات بخش زراعت و دامپروری) به عنوان متغیرهای ورودی مدل‌های پیش‌بینی استفاده شد که بازه زمانی این متغیرها، از سال ۱۳۵۴ تا سال ۱۳۸۷ تشکیل می‌شود. انتخاب ورودی‌ها بر اساس مرور منابع می‌باشد (نصر و همکاران، ۲۰۰۳). در این تحقیق از ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد دیگر به منظور تست استفاده شد. لازم به ذکر است که داده‌های سالانه این متغیرها از منابع آماری وزارت نیرو و بانک مرکزی گردآوری گردید و تحلیل داده‌ها با استفاده نرم افزارهای Minitab و Neuro solution صورت گرفت.

نتایج و بحث

نتایج برنامه‌ریزی ژنتیک

نتایج مدل برنامه‌ریزی ژنتیک نشان داد که معیار توقف اجرای برنامه در مرحله ۱۷۰ می‌باشد. میزان تولید جمعیت در هر یک از مراحل اجرای برنامه ۴۰۰، تعداد اجرای برنامه برای رسیدن به ضریب همبستگی مطلوب ۲۰۰ و حداکثر برنامه‌هایی که باید مورد ارزیابی قرار گیرد ۲۱۱ به دست آمد. نتایج آنالیز حساسیت مدل نیز نشان داد که متغیر ورودی تولیدات بخش کشاورزی دارای اهمیت بسیار بیشتری نسبت به داده‌های سالانه جمعیت جهت پیش‌بینی مصرف انرژی در بخش کشاورزی می‌باشد. همچنین جمعیت اولیه مدل ۲۲۰، نرخ جهش ۰.۹۵٪ و نرخ تلاقی ۲۰٪ انتخاب شد. رابطه به دست آمده در معادله (۷) ارائه شده است. در نهایت، رابطه بدست آمده، بر روی داده‌های آزمون (۲۰٪) اعمال گردید و نتایج ریشه مربعات خطا و ضریب تبیین به ترتیب ۲/۴۷ و ۰/۹۴ به دست آمد.

$$Y = 0.0005X_2 - 1.37 - 4.26\sin(3.25 + 0.007X_1 + 0.00007X_2^2) + \sin\left(0.13 + \frac{0.017}{0.004X_2 - 116 - 0.0003X_1^2}\right) + \sin(1.08 + 0.0009X_1) - 0.0001X_2^2 \quad (7)$$

که در این رابطه X_1 داده‌های سالانه جمعیت و X_2 تولیدات بخش کشاورزی می‌باشد.

نتایج شبکه عصبی

توپولوژی شبکه، یک فاکتور اساسی در طراحی شبکه عصبی مصنوعی می‌باشد. تعداد لایه‌های مخفی و تعداد نرون‌ها جزء اجزای اصلی شبکه‌های پرسپترون چندلایه می‌باشد. بجز توپولوژی شبکه عصبی مصنوعی که ذکر گردید تعداد اپوک در مرحله یادگیری بسیار حائز اهمیت می‌باشد.

تعداد نرون‌ها در لایه‌های ورودی و خروجی ثابت بوده و بسته به تعداد ورودی (متغیرهای مستقل) و خروجی مدل به کار گرفته شده دارد. لایه‌ی ورودی شبکه شامل ۲ ورودی می‌باشد. لایه‌ی خروجی شامل یک نرون می‌باشد. تعداد نرون‌ها و لایه‌های مخفی بستگی به پیچیدگی مساله مورد نظر دارد. در اینجا یک لایه مخفی برای ایجاد شبکه پرسپترون چندلایه مورد استفاده قرار گرفت. تعداد نرون‌های لایه مخفی و همچنین تعداد اپوک در فرآیند آموزش و به صورت سعی و خطا به دست آمدند. به طور اختصاصی در این مساله‌ی مورد نظر، تعداد نرون دو تا ۱۰ و تعداد اپوک ۱۰۰ تا ۱۰۰۰ مورد آزمایش قرار گرفت. برای تعیین بهترین ترکیب از شاخص میانگین مربعات خطا استفاده گردید. نتایج نشان داد که تعداد نرون ۵ و تعداد اپوک ۵۸۰ دارای بهترین ترکیب برای پیش‌بینی میزان مصرف انرژی در بخش کشاورزی می‌باشد. در نتیجه ساختار ۱-۵-۲ برای پیش‌بینی متغیر مورد نظر پیشنهاد می‌گردد. بعد از تعیین اوزان شبکه عصبی مصنوعی، آن را بروی داده‌های آزمون بررسی کرده و نتایج حاکی از دقت بالا و قابل قبول مدل بهینه شده می‌باشد. به طوری که مقدار ریشه مربعات خطا، خطای استاندارد نسبی، میانگین خطا و ضریب تبیین برای تقاضای انرژی در بخش کشاورزی ایران، به ترتیب ۰/۰۱، ۰/۰۷، ۳/۰۱ و ۰/۹۴۲ به دست آمد. پژوهشگران مختلفی کارایی بالای مدل‌های شبکه عصبی مصنوعی را تایید نموده‌اند (نصر و همکاران، ۲۰۰۳؛ اکبری و همکاران، ۲۰۱۴).

نتایج مدل ترکیبی شبکه‌های عصبی و الگوریتم ژنتیک

در این روش ابتدا برای مجموعه‌ای از داده‌ها که جمعیت نامیده می‌شود، پارامترهای هدف به صورت اتفاقی تولید و افراد در برابر این مجموعه از داده‌ها، مورد آزمایش قرار گرفته و مناسب‌ترین نسل جدید را شکل می‌دهند و این فرآیند برای نسل‌های بعدی تا ارضای معیار همگرایی تکرار می‌شود. در این روش از الگوریتم ژنتیک به عنوان روش بهینه‌سازی وزن‌های شبکه عصبی مصنوعی استفاده گردید. در این تحقیق با استفاده از روش سعی و خطا، تعداد جمعیت اولیه ۵۰، تعداد نسل ۵ و تعداد گردش برابر با ۱۰۰ دور به عنوان پارامترهای بهینه به دست آمد. نتایج خطای این روش بر اساس مقدار ریشه مربعات خطا، خطای استاندارد نسبی، میانگین خطا و ضریب تبیین برای تقاضای انرژی در بخش کشاورزی ایران، به ترتیب ۱/۷۸، ۰/۰۶، ۱/۲۹ و ۰/۹۶۷ به دست آمد. مطابق با انتظار، نتایج نشان داد که ترکیب دو تکنیک شبکه عصبی مصنوعی و الگوریتم ژنتیک می‌تواند دقت پیش‌بینی را نسبت به روش شبکه عصبی مصنوعی و برنامه‌ریزی ژنتیک افزایش دهد. در حقیقت استفاده از الگوریتم ژنتیک باعث می‌شود که شبکه عصبی مصنوعی در حین فرآیند آموزش در کمینه محلی قرار نگیرد (احمد و سیمونوویچ، ۲۰۰۵). همچنین نتایج آنالیز حساسیت این مدل نشان داد که مهم‌ترین پارامتر ورودی، تولیدات بخش کشاورزی می‌باشد.

ارزیابی مدل‌ها

نتایج مربوط به مدل‌های شبکه‌های عصبی ژنتیک، شبکه‌های عصبی و برنامه‌ریزی ژنتیک مربوط به پیش بینی تقاضای انرژی در جداول ۱ و ۲ ارائه شده است. با توجه به این جدول ملاحظه می‌شود که در کل بهترین عملکرد در پیش‌بینی تقاضای انرژی بخش کشاورزی مربوط به مدل شبکه عصبی ژنتیک می‌باشد که از لحاظ هر چهار معیار ارزیابی بهتر از شبکه عصبی و برنامه‌ریزی ژنتیک می‌باشد. بعد از مدل شبکه عصبی ژنتیک، شبکه عصبی مصنوعی پس انتشار و برنامه‌ریزی ژنتیک بهترین عملکرد را به خود اختصاص داده است. مقدار پایین RMSE برای اکثر مدل‌ها، پایین بودن خطا و دقت بالای مدل‌های برازش داده شده را نشان می‌دهد. همچنین نتایج نشان داد که در سطح ۵٪ (با استفاده از مقایسه دانکن) تفاوت معنی‌داری بین مدل‌هایی که مصرف انرژی را تخمین زده اند، وجود ندارد. در چنین شرایطی برای ارزیابی کارایی مدل‌ها می‌توان از شاخص RI که از رابطه ۵ به دست می‌آید استفاده نمود. این آماره نشان‌دهنده میزان کاهش خطا در مدل‌های مختلف نسبت به روش برنامه‌ریزی ژنتیک می‌باشد. همانطور که در جدول ۲ ارائه شده، مدل شبکه‌های عصبی ژنتیک دقت پیش‌بینی را نسبت به روش برنامه‌ریزی ژنتیک برای پیش‌بینی تقاضای انرژی به میزان ۱/۷۵ افزایش داده است.

نتیجه‌گیری و پیشنهادات

در بحث‌های اقتصادی علاوه بر نهاده‌های کار و سرمایه، انرژی نیز به‌عنوان یکی از نهاده‌های مهم تولید مطرح است. به طوری که در کنار سایر عوامل تولید، نقش تعیین‌کننده‌ای در حیات اقتصادی کشورها دارد. اهمیت انرژی در فرآیند تولید محصولات مختلف، از یک سو و کمیابی آن از سوی دیگر، توجه هر چه بیشتر فعالان اقتصادی را برای استفاده کارآمد از این عامل می‌طلبد. از این رو مسئولان آن کشورها سعی می‌کنند با پیش‌بینی هرچه دقیق‌تر مصرف انرژی و برنامه‌ریزی صحیح در هدایت مصرف، پارامترهای عرضه و تقاضای انرژی را به نحو مطلوب کنترل کنند. در این پژوهش با استفاده از مدل‌های شبکه‌های عصبی ژنتیک، شبکه‌های عصبی و برنامه‌ریزی ژنتیک مقادیر انرژی مصرفی در بخش کشاورزی ایران پیش‌بینی گردید. در این مطالعه، از داده‌های سالانه مصرف انرژی بخش کشاورزی کشور به عنوان متغیر خروجی مدل‌های پیش‌بینی و از داده‌های سالانه جمعیت کل کشور و تولیدات بخش کشاورزی (شامل کل تولیدات بخش زراعت و دامپروری) به عنوان متغیرهای ورودی مدل‌های پیش‌بینی استفاده شد. نتایج این بررسی نشان داد که در تمام شاخص‌های ارزیابی، شبکه‌های عصبی مصنوعی نسبت به معادلات رگرسیونی غیر خطی حاصل از برنامه‌ریزی ژنتیک کارایی بهتر داشته است. به طوری که نتایج مطالعات گذشته انجام شده در حوزه پیش‌بینی قیمت و مصرف حامل‌های انرژی همچون امین ناصری و کوچک زاده (۱۳۸۷)،

ابریشمی و همکاران (۱۳۸۹)، شکیبایی و همکاران (۱۳۸۸)، آذری و همکاران (۱۳۸۷)، پورکاظمی و اسدی (۱۳۸۸)، منهج و همکاران (۱۳۸۹)، صادقی و همکاران (۱۳۹۰)، دشتی رحمت آبادی و همکاران (۱۳۹۰) و تحقیقات یو و همکاران (۲۰۰۸) مبنی بر دقت بیشتر مدل‌های شبکه عصبی بر مدل‌های رگرسیونی را تایید می‌کند. در این تحقیق نیز سعی بر آن شد تا با کاربرد الگوی ترکیبی شبکه‌های عصبی و الگوریتم ژنتیک برای پیش‌بینی در حوزه انرژی، نتایج آن با الگوهای شبکه‌های عصبی و برنامه‌ریزی ژنتیک مقایسه شود تا کارایی روش پیشنهادی با دیگر روش‌ها مقایسه شود. نتایج بررسی نشان داد که مدل شبکه‌ی عصبی ژنتیک دارای بالاترین دقت در پیش‌بینی تقاضای انرژی می‌باشد. بعد از این مدل شبکه‌های عصبی مصنوعی نسبت به معادلات برنامه‌ریزی ژنتیک کارایی بهتر داشته است. تحقیق حاضر، به بررسی کارایی مدل‌های مذکور در پیش‌بینی تقاضای انرژی در بخش کشاورزی ایران پرداخته شد. پیشنهاد می‌شود در تحقیقات آتی به پیش‌بینی مصرف انرژی در سایر بخش‌های اقتصادی پرداخته شود و کارایی مدل‌های مذکور سنجیده شود. همچنین تحقیقات آینده می‌تواند با ترکیب شبکه‌های عصبی و مجموعه‌های فازی برای پیش‌بینی، میزان دقت آن با مدل‌های پیش‌بینی این تحقیق مقایسه شود.


فهرست منابع

1. Abrishami, H., Ghanimifard, H., Ahrari, M., Rezaei, M. 2010. Persian Gulf oil price forecasting based on technical analysis and neural networks. *Energy Economic Reviw.* 24: 171-192.
2. Akbari, A., Hadad-Zadeh, MS., Mehrabi, H. 2014. Prediction of Palm export using artificial intelligence and econometric methods. *Research in Agricultural Economic.* 5: 99-120.
3. Amin Naseri, M., Koochakzadeh, A. 2008. An Architecture Design model for artificial Neural Networks and its Application to Forecasting Monthly Consumption of Gas Oil in Iran, *Human Sciences Modares.* 59: 69-96.
4. Armen, S., Zare, R. 2009. Energy consumption in different parts of Iran and its relationship with economic growth. *Energy Economic Review.* 21: 67-92.
5. Azari, A., Shariati, M., Alborzi, M., Bakhtiriyari, A. 2008. Assessment of Natural Gas Demand Load for Tehran Using Artificial Neural Network. *Journal of Engineering.* 8: 961-968.
6. Dashti Rahmat Abadi, S., Mohammadi, H., Farajzadeh, Z. 2011. Forecasting Iranian Crude Oil Price Using Artificial Neural Network and ARIMA Models. *Energy Economic Review.* 28: 97-118.
7. Fazlzadeh, A., Tajvidi, M. 2008. Industrial Energy Management in Iran. *Energy Economic Review.* 19: 147-162.
8. Goldberg D.E. 1989. "Genetic algorithm in search"; Optimization and Machine Learning, Addison Wesley Publishing Co.
9. Hamid, S.A., Iqbal, Z. 2004. Using neural networks for forecasting volatility of S&P 500 Index futures prices, *Journal of Business Research.*, No. 57, PP. 1116– 1125.
10. Jebaraj S., and Iniyamb S. 2006. A review of energy models. *Renewable and Sustainable Energy Reviews*, 10: 281-311.
11. Kalogirou, S.A. 2000. Applications of artificial neural networks for energy systems, *Applied Energy*, 67, 17–35
12. Kulkarni S., and Haidar I. 2009. Forecasting Model for Crude Oil Price Using Artificial Neural Networks and Commodity Futures Prices. *International Journal of Computer Science and Information Security*, 2: 1-8.

13. Malik F., and Nasereddin M. 2006. Forecasting output using oil prices: A cascaded artificial neural network approach. *Journal of Economics and Business*, 58: Menhaj, M. 2005. *Fundamentals of Neural Networks*. Amirkabir University Press. Third Edition.
14. Mehrabi Boshrahadi, H., Koochakzadeh, S. 2009. Modeling and Forecasting of Agricultural Products Export in Iran: Application of Artificial Neural Networks. *Journal of Economics and Agricultural Development*. 23: 49-58.
15. Menhaj, M., Kazemi, A., Shakori, H., Mehregan, M., Taghizadeh, M. 2010. Transport Energy Demand Forecasting Using Neural Networks: Case Study Iran, *Human Sciences Modares*. 66: 203-220.
16. Mousavi, S., Mokhtari, Z., Farajzadeh, Z. 2011. Forecasting Energy Consumption in the Agriculture Sector of Iran Using ARIMA and ARCH Models. *Energy Economic Review*. 27: 181-195.
17. Murat Y. and Ceylan H. 2006. Use of artificial neural networks for transport energy demand modeling. *Energy Policy*, 34: 3165-3172.
18. Nasr G.E., Badr E.A., and Joun C. 2003. Back propagation neural networks for modeling gasoline consumption. *Energy Conversion and Management*, 44: 893-905.
19. Porkazemi, M., Asadi, M. 2009. Forecasting of Crude Oil Prices Using Neural Networks and OECD Inventories. *Journal of Economic Research*. 88: 25-46.
20. Sadegi, H., Zolfaghari, M., Elhaminezh, M. 2011. Comparison of Neural Networks and ARIMA in Modeling and Forecasting of Short Run Pricing of the OPEC Crude Oil Basket (With Focus on Comparative Expectations). *Energy Economic Review*. 28: 25-48.
21. Shakibayee, A., Nezamabadi-pour, H., Hosseini, S. 2009. Prediction Crude Oil Supply in the Eleven Producing Countries: Use of Neural Networks and Linear Regression (1980-2006), *Journal of knowledge & development*. 27: 98-119.
22. Sozen A., and Arcaklioglu E. 2007. Prediction of net energy consumption based on economic indicators (GNP and GDP) in Turkey. *Energy Policy*, 35: 4981-4992.

23. Yu L., Wang S., and Lai K. K. 2008. Forecasting Crude Oil Price with an EMD-Based Neural Network Ensemble Learning Paradigm. *Energy Economics*, 30: 2623–2635.
24. Zarezadeh, M., Bozorghadad, A. 2011. Inflow Simulation and Forecasting Optimization Using Hybrid ANN-GA Algorithm. *Journal of water and soil*. 24: 942-954.
25. Zhang G.P. 2003. Time series forecasting using a hybrid ARIMA and neural network model. *Neuro computing*, 50: 159-175.

پیوست‌ها



شکل ۱- ساختار شبکه پرسپترون چند لایه با یک لایه پنهان

جدول ۱- مقادیر واقعی و پیش بینی شده مصرف انرژی
(میلیون بشکه معادل نفت خام) به وسیله مدل های مختلف

سال	مقادیر واقعی	GP	ANN	GA/ANN
۱۳۸۳	۳۳/۱۴۲	۳۲/۲۳	۲۹/۵۸	۲۹/۷۵۲
۱۳۵۷	۱۶/۶۰۳	۱۷/۳۰	۱۵/۷۶۷	۱۶/۳۴۵
۱۳۵۴	۱۰/۴۱۳	۱۴/۷۶	۱۰/۵۲۲	۱۳/۰۰۷
۱۳۷۲	۳۰/۲۷۱	۳۳/۰۲	۳۱/۶۳۱	۳۰/۰۰۱
۱۳۵۵	۱۲/۷۰۱	۱۰/۵۲	۱۱/۷۸۳	۱۳/۶۰۱
۱۳۶۲	۲۱/۱۸۹	۲۳/۴۵	۲۳/۶۴۷	۲۲/۱۵۵
۱۳۵۸	۱۶/۷۱۸	۱۹/۱۱	۱۴/۲۲۵	۱۵/۲۳۸

جدول ۲- عملکرد مدل های مختلف در پیش بینی مصرف انرژی

	GP	ANN	GA/ANN
RMSE	۲/۴۷	۲/۰۱	۱/۷۸
RSE	۰/۰۹	۰/۰۷	۰/۰۶
ME	۶/۰۹	۳/۰۱	۱/۲۹
R²	۰/۹۴	۰/۹۴	۰/۹۶
MAPE	۰/۱۴	۰/۰۷	۰/۰۸
RI	۰	۱/۶۵	۱/۷۵