

پیش‌بینی مصرف انرژی ایران با استفاده از مدل ترکیبی الگوریتم ژنتیک - شبکه عصبی مصنوعی و مقایسه آن با الگوهای سنتی

سید حیدر میرفخرالدینی^{۱*}، حمید بابایی میبیدی^۲، علی مروتی شریف‌آبادی^۳

۱. دانشیار گروه مدیریت، دانشکده اقتصاد، مدیریت و حسابداری، دانشگاه یزد، یزد، ایران
۲. کارشناس ارشد مدیریت صنعتی، دانشکده اقتصاد، مدیریت و حسابداری، دانشگاه یزد، یزد، ایران
۳. استادیار گروه مدیریت، دانشکده اقتصاد، مدیریت و حسابداری، دانشگاه یزد، یزد، ایران

پذیرش: ۹۱/۱۱/۱

دریافت: ۹۰/۹/۹

چکیده

در دهه‌های اخیر، انرژی در کنار سایر عوامل تولید نقش تعیین‌کننده‌ای در رشد اقتصادی کشورها داشته و اهمیت آن همچنان رو به افزایش است. وابستگی روزافزون به انرژی موجب تعامل این بخش با سایر بخش‌های اقتصادی شده و سرعت در روند رشد و توسعه اقتصادی را وابسته به سطح مصرف انرژی کرده است، به طوری که در دهه‌های اخیر، رشد اقتصادی جهان و روند صنعتی شدن موجب افزایش تقاضا و مصرف انرژی شده است. در این صورت به منظور کنترل پارامترهای عرضه و تقاضای انرژی و برنامه‌ریزی صحیح در هدایت مصرف آن باید مصرف انرژی را به صورت دقیق پیش‌بینی نمود.

هدف از این مقاله کاربست مدل ترکیبی شبکه‌های عصبی مصنوعی و الگوریتم ژنتیک در پیش‌بینی مصرف انرژی ایران می‌باشد. بنابراین در این بررسی از داده‌های سالیانه مصرف انرژی کشور به عنوان متغیر خروجی مدل پیش‌بینی و از داده‌های سالیانه جمعیت کل کشور، تولید ناخالص داخلی، واردات و صادرات به عنوان متغیرهای ورودی مدل‌های پیش‌بینی استفاده شده است.

در پایان به منظور مقایسه نتایج پیش‌بینی مدل ترکیبی مذکور با مدل‌های شبکه عصبی و رگرسیون چند متغیره، از شاخص‌های ارزیابی خطای استاندارد نسبی (RSE)، میانگین خطا (ME) و مجذور میانگین مربعات خطا (RMSE) استفاده شد. نتایج ارزیابی نشان داد که الگوی ترکیبی شبکه‌های عصبی و الگوریتم ژنتیک (ANN-GA)، نسبت به سایر مدل‌ها دارای بالاترین دقت در پیش‌بینی مصرف انرژی کشور می‌باشد.

کلیدواژه‌ها: مصرف انرژی، شبکه‌های عصبی مصنوعی، الگوریتم ژنتیک.

۱. مقدمه

تأمین امنیت عرضه انرژی در دنیا از مسائل استراتژیک پیش روی تمامی دولت‌ها می‌باشد. در کنار محور مدیریت سمت عرضه انرژی، بخشی که کمتر از آن نامی به میان می‌آید، مدیریت سمت تقاضای انرژی است. امروزه تلاش‌ها درون کشور ما در جهت مدیریت سمت عرضه انرژی بوده و کمتر به مدیریت سمت تقاضای انرژی توجه می‌شود، در حالی که مدیریت تقاضای انرژی و تلاش در جهت استفاده بهینه از انرژی در تمامی کشورهای پیشرفته دنیا از مهم‌ترین عوامل پیشرفت صنعتی پایدار بوده است [۱، صص ۲۷۱-۲۹۱]. 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 حمل‌ونقل کشور را به نحو مطلوب کنترل کنند. مدلسازی و پیش‌بینی مصرف انرژی نقش بسیار مهمی را در توسعه و پیشرفت کشورها برای سیاست‌گذاران و سازمان‌های مرتبط بازی می‌کند. بی‌توجهی به مصرف، منجر به قطع بالقوه انرژی می‌شود که نابودی زندگی و اقتصاد را در پی دارد. تخمین اضافی انرژی ممکن است منجر به ایجاد ظرفیت بیهوده و غیرضروری شود که این به معنای تلف شدن منابع مالی است. بنابراین بهتر است به منظور اجتناب از اشتباهات هزینه بر از مدل‌هایی استفاده شود که مصرف انرژی را با دقت بالاتری تخمین بزنند. هم‌چنین بهتر است مدل‌هایی به کار گرفته شود که بتواند از داده‌های مصرف انرژی که ماهیت غیرخطی دارند، در پیش‌بینی استفاده کرد [۲، صص ۲۷۱۹-۲۷۲۷].

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 می‌باشد [۳، صص ۱۰۰۳-۱۰۱۲]. در این خصوص برنامه‌ریزی انرژی

بدون داشتن دانش قابل قبولی از مصرف انرژی گذشته و حال و تقاضای احتمالی آینده امکان‌پذیر نیست [۴، صص ۶۴۹۱-۶۵۰۵]. تخمین تقاضای انرژی مبتنی بر شاخص‌های اقتصادی و غیراقتصادی می‌باشد که ممکن است با استفاده از روش‌های آماری خطی و غیرخطی، ریاضیات و مدل‌های شبیه‌سازی به دست بیاید. غیرخطی بودن این شاخص‌ها و تقاضای انرژی منجر به جستجو برای راه‌حل‌های هوشمند نظیر الگوریتم ژنتیک، رگرسیون فازی و شبکه‌های عصبی شده است [۵، صص ۲۶۳۷-۲۶۴۴]. با توجه به مطالعات گذشته، تحلیل رگرسیون به عنوان پرترفدارترین روش در پیش‌بینی مصرف انرژی مورد توجه قرار گرفته است. اما رویکرد شبکه‌های عصبی مصنوعی (ANN)، برای کاربران بالقوه نظیر مهندسان انرژی جذاب‌تر و دارای اهمیت بیشتری است؛ زیرا صرف نظر از کاهش زمان مورد نیاز، امکان ایجاد با ثبات‌تر کاربردهای انرژی را فراهم می‌کند. همچنین این رویکرد دارای مزیت‌هایی مانند محاسبه سریع، هزینه پایین قابلیت انجام و طراحی آسان به وسیله اپراتورهایی با تجارب فنی کم می‌باشد. بنابراین استفاده از ANN به منظور مدل‌سازی و پیش‌بینی، هدفی است که به طور فزاینده‌ای در دهه اخیر مورد توجه قرار گرفته است که می‌توان گفت این مسئله عمدتاً به این دلیل است که ANN مزایای بیشتری نظیر زمان پردازش سریع، توسعه کوتاه و قابلیت‌های بسیار خوبی برای تخمی ندارد [۶، صص ۱۸۳-۲۰۱؛ ۷، صص ۱۳۰-۱۳۶؛ ۸، صص ۳۱۶۵-۳۱۷۲].

استفاده بهتر از شبکه عصبی، مستلزم بهینه‌سازی پارامترهای مورد استفاده در آن می‌باشد. برای تعیین بهترین مقادیر پارامترهای شبکه‌های عصبی مانند تعداد لایه‌ها و نرون‌های در هر شبکه، زمان زیادی صرف واسنجی این پارامترها به روش آزمون و خطا می‌شود. به همین منظور در این تحقیق از الگوریتم ترکیبی شبکه عصبی و الگوریتم ژنتیک به عنوان یک روش بهینه‌سازی- که دستیابی به مقادیر مطلوب پارامترهای شبکه عصبی میسر می‌شود- برای میزان مصرف انرژی کشور پیش‌بینی شده است تا در نهایت بتوان میزان کارایی این روش را نسبت به دیگر روش‌ها در پیش‌بینی مصرف انرژی بررسی نمود. نتایج حاصل از این تحقیق، مواد اصلی و مهم را در ارزیابی الگوهای مصرف انرژی برای شرکت‌های نافع فراهم می‌کند. همچنین امکان انتخاب رویکرد دقیق‌تری را برای تخمین مصرف انرژی در آینده ارائه می‌دهد.

۲. سابقه پژوهش

موضوع رابطه علی- معلولی بین مصرف انرژی و شاخص‌های اقتصادی و جمعیتی، به خوبی در ادبیات اقتصاد انرژی مورد مطالعه قرار گرفته است [۶، صص ۱۸۳-۲۰۱]. مدلسازی همراه با تکنیک هم‌انباشتگی و یا تحلیل رگرسیون چند متغیره در تعداد زیادی از مطالعات انجام شده در کشورهای مختلف مورد استفاده قرار گرفته است تا به بررسی تأثیر عوامل مختلف بر مصرف انرژی بپردازد. همچنین از روش‌های مختلفی به منظور پیش‌بینی مصرف انرژی استفاده شده که برخی از این مطالعات انجام شده به شرح زیر می‌باشند:

گلاشور و لی به بررسی رابطه علی- معلولی دو طرفه بین مصرف انرژی و تولید ناخالص داخلی با استفاده از مدل‌های هم‌انباشتگی و خطاگیری پرداختند. آنان بررسی خود را در کشورهای کره جنوبی و سنگاپور انجام دادند [۹، صص ۱۷-۲۵]. اوزترک و آکاراچی با استفاده از متغیرهای سرانه مصرف انرژی، سرانه مصرف برق و سرانه تولید ناخالص داخلی واقعی به بررسی رابطه علی- معلولی بین انرژی و رشد اقتصادی پرداختند. محدوده زمانی مورد مطالعه آنها از سال ۱۹۸۰ تا ۲۰۰۶ را در بر می‌گرفت و بررسی خود را در کشورهای آلبانی، بلغارستان، مجارستان و رومانی انجام دادند [۱۰، صص ۱۹۳۸-۱۹۴۳]. نارایان و همکاران فرضیه صفری را در مورد مصرف انرژی در کشورهای قاره استرالیا مورد آزمون قرار دادند. آنها دریافتند شواهد زیادی وجود دارد که شوک‌های تحمیل شده بر مصرف انرژی، اثر موقتی بر مصرف انرژی در استرالیا دارد [۱۱، صص ۳۲۹۴-۳۲۹۸]. همچنین آنها در مطالعه دیگری برای هفت پانل که متشکل از ۹۳ کشور می‌باشد، رابطه بلندمدت‌علیت گرنجر بین مصرف برق و تولید ناخالص داخلی واقعی را مورد بررسی قرار دادند [۱۲، صص ۱۹۵۳-۱۹۶۲].

مدلسازی مصرف و تقاضای انرژی معمولاً مبتنی بر مصرف گذشته و رابطه این مصرف با متغیرهای دیگر نظیر متغیرهای اقتصادی، جمعیتی، آب و هوا و قیمت انرژی می‌باشد. هم‌اکنون به بررسی چندی از مطالعات انجام شده است که به منظور مدلسازی و پیش‌بینی مصرف انرژی با استفاده از مدل‌های مختلف صورت گرفته، پرداخته می‌شود. امین ناصری و کوچک‌زاده یک مدل مبتنی بر تکنیک طراحی آزمایش‌ها برای طراحی بهینه معماری شبکه عصبی با یادگیری تحت نظارت، با توجه به اثر متقابل بین عوامل ذکرشده، ارائه کردند. در

این تحقیق از مدل پیشنهادی برای طراحی معماری شبکه عصبی به منظور پیش‌بینی مصرف نفت گاز کل کشور استفاده شده است. 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 شده است. همچنین برای مقایسه عملکرد شبکه عصبی با روش‌های آماری، دو مدل با استفاده از رگرسیون و ARIMA طراحی شده‌اند.

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 [۱۳، صص ۶۹-۹۵]. ابریشمی و همکاران از شبکه عصبی GMDH برای پیش‌بینی قیمت گازوئیل مبتنی بر قواعد تحلیل تکنیکی، شامل میانگین‌های متحرک کوتاه مدت و بلند مدت به عنوان ورودی شبکه در دوره‌های مختلف بازار استفاده کردند. در این بررسی نیز پیش‌بینی‌های شبکه عصبی نسبت به روش سری زمانی از خطای کمتر و دقت بالاتری برخوردار بود [۱۴، صص ۱۷۱-۱۹۲]. صادقی و همکاران با استفاده از شبکه عصبی مصنوعی مبتنی بر انتظارات قیمتی برای داده‌های روزانه، به مدلسازی و پیش‌بینی روزانه قیمت سبده نفت خام اوپک پرداختند و نتایج آن با مقادیر پیش‌بینی شده به وسیله مدل ARIMA براساس معیارهای اندازه‌گیری دقت پیش‌بینی، مورد مقایسه قرار گرفته است. نتایج تحقیق نشان می‌دهد که شبکه عصبی مورد استفاده نسبت به مدل ARIMA از قدرت پیش‌بینی بهتری برخوردار است [۱۵، صص ۲۵-۴۷].


پااو با استفاده از مدل‌های خطی و غیرخطی آماری از جمله روش ANN، به بررسی تأثیر چهار عامل اقتصادی (درآمد ملی، جمعیت، تولید ناخالص داخلی، شاخص قیمت مصرف‌کننده) بر مصرف برق تایوان پرداخت و سپس یک مدل پیش‌بینی اقتصادی را توسعه داد [۱۶، صص ۲۱۲۹-۲۱۴۱]. جیم و راپر یک مدل ANN پیشنهاد کردند که دارای چهار متغیر مستقل نظیر تولید ناخالص داخلی، جمعیت، میزان واردات و صادرات است که می‌تواند به طور مؤثر تقاضای انرژی کره جنوبی را برآورد کند [۱۷، صص ۴۰۴۹-۴۰۵۴]. اکونومو یک مدل ANN شامل دمای سالیانه محیط، ظرفیت برق نصب شده، مصرف سالیانه برق مسکونی و تولید ناخالص داخلی که مصرف انرژی بلند مدت یونان را پیش‌بینی می‌کند، ارائه داد [۱۸، صص ۵۱۲-۵۱۷]. ادیجر و تات لیدل به منظور پیش‌بینی اولیه تقاضای انرژی ترکیه

یک روشی را ارائه دادند که از تحلیل الگوهای تناوبی خط منحنی گذشته استفاده می‌کند [۱۹، صص ۴۷۳-۴۸۷]. سیلان و اوزترک براساس شاخص‌های اقتصادی از جمله تولید ناخالص ملی، جمعیت، میزان واردات و صادرات تقاضای انرژی ترکیه را برآورد کردند. مدل پیش‌بینی آنها ثابت کرد که پیش‌بینی تقاضای انرژی با استفاده از الگوریتم ژنتیک بهتر از مدل دولت است [۲۰، صص ۲۵۲۵-۲۵۳۷]. کنیورت و همکاران تقاضای آینده انرژی ترکیه را که مبتنی بر تولید ناخالص داخلی، جمعیت، و میزان واردات و صادرات می‌باشد، با استفاده از روش الگوریتم ژنتیک مدلسازی کردند [۲۱، صص ۱۳۱۳-۱۳۲۰]. ادیجر و آکا به منظور تخمین اولیه تقاضای آینده انرژی ترکیه از سال ۲۰۰۵ تا سال ۲۰۲۰ از روش‌های اتورگرسیون و میانگین متحرک استفاده کردند [۲۲، صص ۱۷۰۱-۱۷۰۸]. تاکساری از الگوریتم بهینه‌سازی کلونی مورچگان به‌منظور تعیین تقاضای انرژی ترکیه استفاده نمود. متغیرهای مستقل آن عبارتند از تولید ناخالص داخلی، جمعیت و میزان واردات و صادرات [۲۳، صص ۳۹۸۴-۳۹۹۰]. سوزن و آرکاکلیوگلو در مطالعه دیگری به‌منظور تعیین میزان مصرف انرژی آینده ترکیه با استفاده از روش ANN به معادله‌ای مبتنی بر شاخص‌های اقتصادی (GDP, GNP) و افزایش جمعیت دست پیدا کردند [۲۴، صص ۴۹۸۱-۴۹۹۲]. آنلر مدلی را ارائه داد که از متغیرهای مستقل مختلف شامل تولید ناخالص داخلی، جمعیت و همچنین واردات و صادرات به منظور پیش‌بینی مصرف انرژی ترکیه استفاده می‌کند. او از الگوریتم بهینه‌سازی هجوم ذرات به‌منظور پیش‌بینی تقاضای انرژی استفاده نمود [۲۵، صص ۱۹۳۷-۱۹۴۴].

۳. شبکه عصبی مصنوعی

شبکه 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 آن گاه تولید یک خروجی می‌باشد [۲۶، ص ۲۱].

ایجاد یک شبکه عصبی خوب برای یک کاربرد خاص بسیار مهم است. ایجاد یک شبکه مطلوب، انتخاب یک معماری مناسب، تعداد لایه‌ها، تعداد واحدها در هر لایه و ارتباط‌های بین واحدها، انتخاب توابع تبدیل واحدهای میانه به واحدهای ستاده، طراحی الگوریتم آموزش، انتخاب وزن‌های اولیه و به شکل خاص و قانون توقف را در بر می‌گیرد [۲۷، صص ۱۷-۳۴]. یکی از متداول‌ترین شبکه‌های عصبی مورد استفاده، شبکه عصبی پرسپترون چند لایه می‌باشد (شکل ۱). پرسپترون چند لایه یک ترکیب استاندارد از ورودی‌ها، واحدهای عصبی خطی و غیر خطی 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 غیر خطی و پیوسته مشتق‌پذیر دیگری می‌توان استفاده کرد. معمولاً برای افزایش سرعت آموزش، نرون‌های لایه خروجی خطی انتخاب می‌شود.



شکل ۱ ساختار پرسپترون با یک لایه پنهان

مسئله 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 پیکره‌بندی غیرخطی شبکه‌های عصبی دارند [۲۸، صص ۱۵۹-۱۷۵]. در تعیین تعداد گره‌های ورودی استفاده از روش آزمون و خطا بیش‌ترین کاربرد را دارد. اما به طور کلی تعداد نرون‌های لایه ورودی بیانگر تعداد متغیرهای

ورودی است [۲۹، صص ۱۶۸-۱۸۰]. در این مورد نیلسون (۱۹۸۷) ثابت کرد که در شبکه‌های عصبی با یک لایه مخفی با تابع سیگموئید $f(x) = \frac{1}{1+e^{-x}}$ در لایه میانی و تابع خطی در لایه خروجی قادر به تقریب تمامی توابع مورد نظر با هر درجه تقریب خواهد بود، مشروط به اینکه به اندازه کافی نرون در لایه مخفی وجود داشته باشد، این قضیه به تقریب ساز جهانی معروف می‌باشد [۳۰، ص ۵۴].

۴. الگوریتم ژنتیک

الگوریتم ژنتیک^۱ نخستین بار به وسیله هلند در سال ۱۹۷۵ مطرح شد و در سال‌های بعد توسط محققان دیگر توسعه پیدا کرد. الگوریتم ژنتیک بخشی از نظریه محاسبه تکاملی است که در حال حاضر به عنوان بخشی از هوش مصنوعی به سرعت در حال رشد است. ایده اصلی این الگوریتم در نظریه تکاملی داروین نهفته است. از نظر کاربردی، الگوریتم ژنتیک یکی از روش‌های بهینه‌سازی مسائل است که اساس آن بر انتخاب طبیعی (عامل اصلی تکامل زیستی) و برخی از مفاهیم مهم از علم ژنتیک استوار است. در این روش برای بهینه‌سازی تابع هدف (تابع شایستگی) مسئله، از یک جمعیت اولیه کروموزوم‌ها^۲ (افراد) که در حقیقت پاسخ‌های اولیه مسئله هستند، به یک جمعیت جدید از کروموزوم‌ها یا یک نسل جدید که در حقیقت پاسخ‌های ثانویه مسئله 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 [۳۱، صص ۱۵۷-۱۷۷].

۴-۱- جزئیات اجرایی الگوریتم ژنتیک

۴-۱-۱- نمایش رشته‌ها

نمایش مناسب رشته‌ها به ویژگی‌های فضای جست‌وجو بستگی دارد؛ ولی معمولاً به صورت رشته‌های دودویی^۳ نشان داده می‌شوند. در این مقاله متغیرها به صورت دودویی و با طول رشته ثابت کدگذاری شده‌اند.

رشته‌های مورد استفاده در الگوریتم ژنتیک را می‌توان به صورت گسسته یا پیوسته کد کرد [۳۲، صص ۹-۱۲]. با توجه به گسسته بودن نوع متغیرهای مورد استفاده در این پژوهش، هر بیت^۴ از کروموزوم‌های مربوط به هر نسل، معرف یکی از متغیرهای استفاده شده است؛ به این ترتیب که در هر کروموزوم، صفر بودن بیت به معنای حضور نداشتن متغیر متناظر با آن و یک به معنای حضور متغیر متناظر با آن، در ترکیب انتخاب شده نهایی است.

۴-۱-۲- محاسبه‌ی برازندگی

تابع برازندگی از اعمال تبدیل مناسب روی تابع هدف که قرار است بهینه شود، به دست می‌آید. این تابع هر رشته را با یک مقدار عددی ارزیابی می‌کند که کیفیت آن را مشخص نماید. هر چه کیفیت رشته جواب بالاتر باشد، مقدار برازندگی جواب بیشتر است و احتمال مشارکت برای تولید نسل بعدی افزایش پیدا می‌کند. در مسئله این پژوهش، مقدار تابع برازندگی با معکوس خطاهای حاصل از آموزش شبکه عصبی در مورد هر رشته، برابر قرار داده شده است؛ به این معنا که هر رشته که نماینده ترکیبی از متغیرهاست، به شبکه عصبی متناظر با آن وارد شده، شبکه با داده‌های مربوط به آن آموزش می‌بیند و در نهایت، خطای آموزش شبکه محاسبه می‌گردد. معکوس این خطای محاسبه شده با تابع برازندگی الگوریتم ژنتیک برابر قرار داده شده است [۳۳، ص ۴۷].

ج - اندازه جمعیت

گلدبرگ برای محاسبه بهترین اندازه جمعیت برای کدهای دودویی متغیرهای پیوسته با طول حداکثر، شصت رشته پیشنهاد می‌کند [۳۳، ص ۴۷].

۴-۲- عملگرهای الگوریتم ژنتیک^۵

۴-۲-۱- انتخاب^۶

پس از اینکه برازندگی تمام افراد یک نسل مشخص شد، طبق اصول طبیعی، فرزندان که از زوج‌های برازنده تر به وجود می‌آیند، برازندگی بیشتری دارند و همان طور که در طبیعت، افرادی

که برتری‌هایی نسبت به دیگران دارند، به زوج‌های برتری دست پیدا می‌کنند، الگوریتم ژنتیک این فرایند را شبیه‌سازی می‌کند و به افراد برانده‌تر شانس تولید مثل بیشتری می‌دهد. ساده‌ترین روش انتخاب، استفاده از گردونه شانس^۷ است. در این روش، چرخ با قطاع‌های نامساوی طوری در نظر گرفته می‌شود که هر فرد قطاعی با زاویه مرکزی $\frac{2\pi f_i}{\sum f_i}$ داشته باشد. حال عددی تصادفی در بازه $[0, 2\pi]$ در نظر گرفته، رشته‌ای انتخاب می‌شود که عدد تصادفی در قطاع مربوط به آن قرار گیرد، به طوری که قطاع‌ها بزرگ‌تر، شانس بیشتری برای انتخاب شدن دارند [۳۳، ص ۴۷].

۴-۲-۲- پیوند

پیوند^۸ مهم‌ترین عملگر الگوریتم ژنتیک و کلید موفقیت آن است. عملگر انتخاب برای کشف نواحی جدید فضای جست‌وجو^۹ ابزاری ندارد و اگر تنها به نسخه برداری ساختارهای قدیمی بدون تغییر آن اکتفا شود، نمی‌توان به بررسی موارد جدید پرداخت. پیوند، عملگری است که اطلاعات بین رشته‌ها را به طور اتفاقی مبادله می‌کند. ساده‌ترین حالت این عملگر، پیوند تک نقطه‌ای است. در پیوند ساده نخست عددی تصادفی در فاصله بین $[1-e^{-L}, 1]$ انتخاب می‌شود سپس بیت‌های متناظر با آن در دو رشته‌ای که باید باهم ترکیب شوند، باهم عوض می‌شوند و به این ترتیب دو فرزند به وجود می‌آیند. عملگر پیوند می‌تواند دو نقطه‌ای باشد، در این صورت دو نقطه به طور تصادفی انتخاب می‌شوند و عمل پیوند بین آن دو اتفاق می‌افتد. معمولاً احتمال وقوع پیوند بین دو زوج بین $0/6$ تا 1 انتخاب می‌شود [۳۴، ص ۷۸].

۴-۲-۳- جهش

سومین عملگر مهم در الگوریتم ژنتیک جهش^{۱۰} نام دارد. اگرچه عملگرهای انتخاب و پیوند، جست‌وجوی مؤثری در فضای طراحی می‌کنند، گاهی باعث می‌شوند از بین خصوصیات مفید رشته‌ها بروند. عملگر جهش امکان دستیابی مجدد به این ویژگی‌های مثبتی را که در جمعیت نیست، فراهم می‌کند. رفتار عملگر جهش به صورت ساده، به این نحو است که برای هر فرد در مجموعه (معمولاً بعد از عمل پیوند) احتمال وقوع جهش که معمولاً کمتر از دو درصد است

بررسی شده، چنانچه باید جهش انجام شود نقطه‌ای در کروموزوم به صورت تصادفی انتخاب می‌شود و مقدار آن از صفر به یک و یا برعکس تبدیل می‌شود [۳۵، ص ۱۷۸].

۴-۲-۴ - همگرایی^{۱۱}

مسئله بهینه‌سازی کلی در حالت عمومی خود حل‌نشده است، بنابراین در زمان محدود نمی‌توان انتظار داشت به بهینه کلی^{۱۲} تابع دست پیدا کرد؛ با این حال معمولاً علاقه داریم که به عنوان عاملی اطمینان‌بخش الگوریتم بهینه‌سازی ما با احتمال یک به بهینه کلی تابع همگرا شود. ردلف^{۱۳} در مقاله خود به بررسی رفتار الگوریتم ژنتیک ساده از لحاظ همگرایی پرداخته است. تحلیل ردلف نشان می‌دهد که الگوریتم ژنتیک ساده در زمان بینهایت به بهینه کلی خود همگرا نمی‌شود. این نتیجه چندان نگران‌کننده نیست، زیرا اولاً الگوریتم همیشه در زمان محدود اجرا می‌شود و در نتیجه معمولاً ناچاریم به تقریب بهینه کلی اکتفا کنیم. دوم، این نتیجه به آن معنا نیست که الگوریتم هرگز به بهینه کلی خود نمی‌رسد بلکه به این معنی است که الگوریتم به بهینه کلی می‌رسد و از آن خارج می‌شود. در واقع به طور متوسط این پیشامد در زمان محدود رخ می‌دهد. در زمان بینهایت، الگوریتم بینهایت بار به بهینه کلی می‌رسد و از آن خارج می‌شود. مسئله‌ای که از همگرایی الگوریتم در بینهایت مهم‌تر است، زمانی است که باید صرف شود تا الگوریتم برای اولین بار، به بهینه کلی برسد. با توجه به نکته‌ای که در مورد محدود بودن زمان متوسط عبور الگوریتم از بهینه کلی بیان شد، ردلف نشان داده است که اگر بهترین فرد جمعیت در طول اجرای الگوریتم در حافظه‌ای جدا از جمعیت ذخیره شود، الگوریتم در زمان بینهایت به بهینه کلی همگرا می‌شود. بهترین فرد را می‌توان در یکی از دو مرحله قبل و یا بعد از انتخاب در جمعیت یافت و ذخیره کرد [۳۶، ص ۵۴؛ ۳۷، ص ۴۹]. قبل از ردلف، چند بررسی دیگر در این زمینه انجام شده است که از آن جمله می‌توان به کارابین و همکارانش اشاره کرد. در این بررسی، نویسندگان به حالت‌های کلی‌تری از الگوریتم‌های بهینه‌سازی با عنوان الگوریتم ژنتیک انتزاعی^{۱۴} توجه کرده و نشان داده‌اند که با استفاده از انتخاب نخبه‌گرا^{۱۵} می‌توان در زمان بینهایت به بهینه کلی تابع رسید.



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

الگوریتم ژنتیک یک روش برنامه‌نویسی است که از تکامل ژنتیکی به عنوان الگوی حل مسئله استفاده می‌کند [۳۸، صص ۲۳۶-۲۵۱]. در این روش نخست برای تعدادی ثابت که جمعیت نامیده می‌شود، مجموعه‌ای از داده‌ها و پارامترهای هدف به صورت اتفاقی تولید می‌شود و افراد در برابر این مجموعه از داده‌ها مورد آزمایش قرار گرفته و مناسب‌ترین آنها باقی مانده و نسل جدید را شکل می‌دهند. این فرایند برای نسل‌های بعدی تا ارضای معیار همگرایی تکرار می‌شود.

مراحل ترکیب و توسعه مدل تلفیقی شبکه عصبی و الگوریتم ژنتیک برای پیش‌بینی مصرف انرژی ایران به شرح ذیل می‌باشد [۳۹، صص ۹۴۲-۹۵۴].

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.

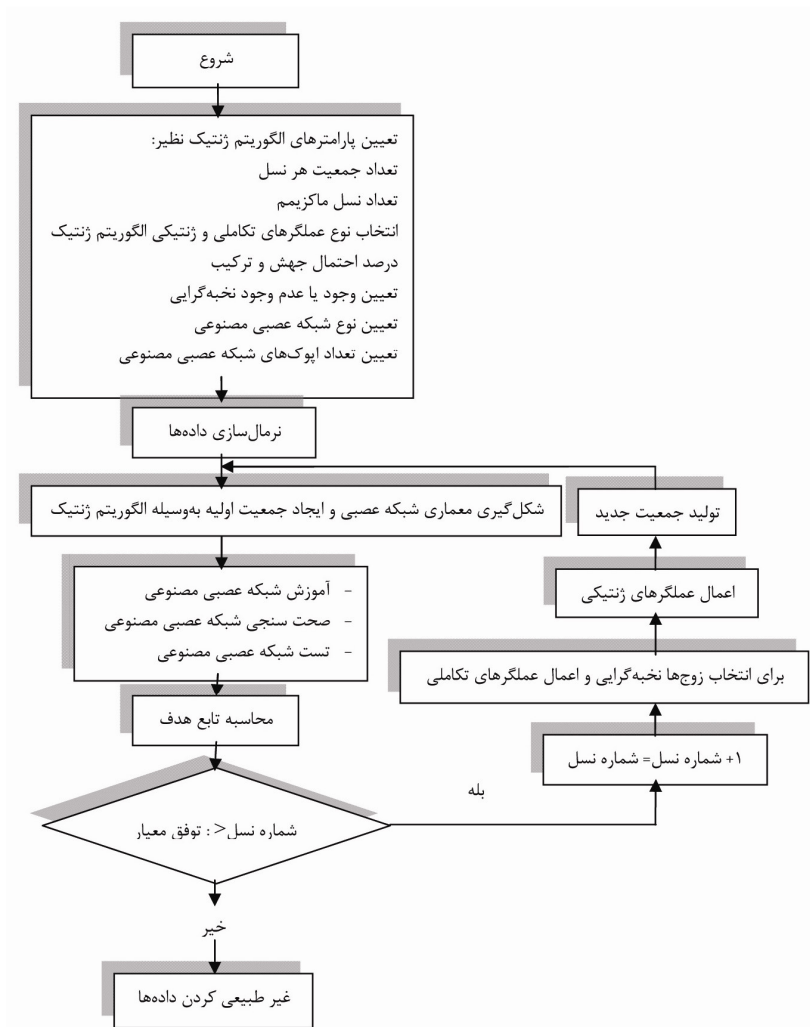
مرحله ۲: در این مرحله شاکل شبکه عصبی مصنوعی با استفاده از مقادیر ژن‌های موجود در هر جمعیت ایجاد شده تعیین می‌شود.

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 برای 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 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. روش اجرایی مدل در شکل ۲ نشان داده شده است:



شکل ۲ الگوریتم کلی اجرای مدل



۶. شاخص‌های ارزیابی مدل

در این تحقیق به منظور ارزیابی عملکرد مدل‌های شبکه عصبی / ژنتیک، شبکه عصبی مصنوعی و رگرسیون چند متغیره از پارامترهای خطای استاندارد نسبی (RSE) و میانگین خطا (ME)، مجذور میانگین مربعات خطا (RMSE) که از روابط زیر قابل محاسبه می‌باشند استفاده شد.

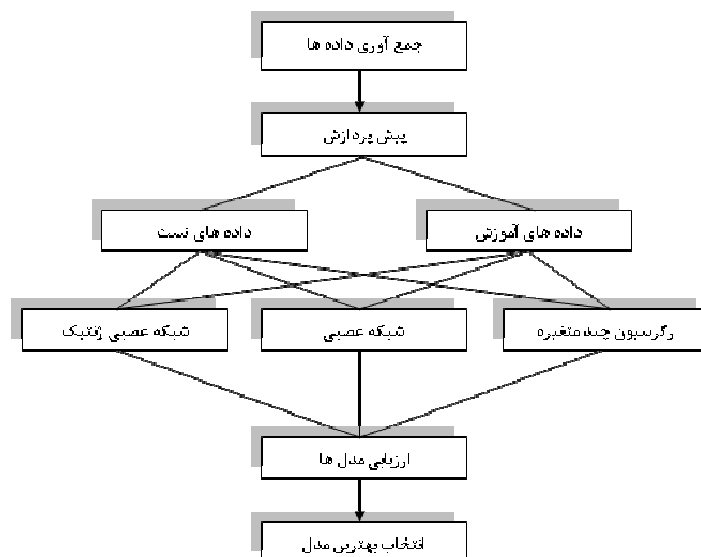
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Z_i - Z_P)^2} \quad (1) \quad RSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (Z_i - Z_P)^2}}{Z_{ave}} \quad (2)$$

$$ME = \frac{1}{n} \sum (Z_i - Z_P) \quad (3)$$

که در آنها: Z_i مقادیر پیش‌بینی شده، Z_P مقادیر مشاهداتی، Z_{ave} متوسط مقادیر مشاهداتی و n تعداد داده‌ها می‌باشد.

۷. جمع‌آوری داده‌ها

از آن جایی که شبکه‌های عصبی مصنوعی مبتنی بر داده هستند، آماده‌سازی داده‌ها یک قدم مهم و درواقع کلید موفقیت در استفاده از شبکه عصبی است. هر چه قدر تعداد داده‌ها بیشتر باشد، می‌توان در خصوص تقریب ساختار نهفته در مدل، اطمینان بیشتری حاصل کرد. در این تحقیق از داده‌های سالیانه مصرف انرژی کشور (اعم از انرژی برق، گاز طبیعی و فراورده‌های نفتی) به عنوان متغیر خروجی مدل‌های پیش‌بینی و از داده‌های سالیانه جمعیت کل کشور، تولید ناخالص داخلی، واردات و صادرات به عنوان متغیرهای ورودی مدل‌های پیش‌بینی استفاده شد که بازه زمانی این متغیرها از سال ۱۳۴۶ تا سال ۱۳۸۷ تشکیل می‌دهد. لازم به ذکر است که داده‌های سالیانه این متغیرها از منابع آماری وزارت نیرو و بانک مرکزی گردآوری شد. این تحقیق دارای چندین مرحله می‌باشد که به صورت روندنما ارائه شده است (شکل ۳).



شکل ۳ روند انجام پژوهش

۸. نتایج

۸-۱- پیش پردازش

در آغاز با استفاده از نرم افزار MINITAB داده‌های پرت از کل داده‌ها حذف شد. با توجه به اینکه تحقیقات بسیاری در پیشینه تحقیق مرور شد، در بسیاری از این مطالعات چهار عامل تولید ناخالص داخلی، جمعیت، واردات و صادرات را به عنوان عوامل مؤثر بر مصرف انرژی به منظور پیش‌بینی بیان کردند. در نتیجه در این تحقیق نیز این چهار عامل به منظور مدلسازی مصرف انرژی و به عنوان ورودی هر سه مدل پیش‌بینی برگزیده شد. در ادامه لازم است که داده‌ها نرمالیز شوند. اصولاً استفاده از داده‌ها به صورت خام، باعث کاهش سرعت و دقت شبکه می‌شود. به منظور جلوگیری از چنین حالتی و همچنین به منظور یکسان کردن ارزش داده‌ها برای شبکه، عمل نرمال‌سازی صورت می‌گیرد. عمل نرمال‌سازی مانع از کوچک شدن بیش از حد وزن‌ها و سبب جلوگیری از اشباع زود هنگام نرون‌ها می‌شود. پس داده‌های ورودی و خروجی را با استفاده از معادله ۱ نرمالیز شدند.

$$y = 0.8 \times \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} + 0.2 \quad (1)$$

بعد از انتخاب پارامترهای مؤثر و نرمال‌سازی داده‌ها، آنها را به دو دسته تقسیم شدند، به طوری که ۸۰ درصد داده‌ها برای آموزش و بقیه داده‌ها، یعنی ۲۰ درصد برای اعتبارسنجی اختصاص داده شد [۳۹، ص ۱۷۸؛ ۴۰، صص ۵۵۱-۵۵۹]. در این تحقیق داده‌های سال ۱۳۴۶ تا ۱۳۷۹ برای آموزش، و داده‌های سال ۱۳۸۰ تا ۱۳۸۷ برای اعتبارسنجی اختصاص داده شد.


۸-۲- نتایج رگرسیون چند متغیره خطی

برای تعیین رگرسیون چند متغیره پارامتر مورد مطالعه، رابطه رگرسیونی مربوطه با استفاده از داده‌های آموزش تعیین شد (معادله ۲). این رابطه سپس روی داده‌های آزمون اعمال شد و نتایج ریشه مربعات خطا، خطای استاندارد نسبی، میانگین خطا و ضریب تعیین به ترتیب ۰/۰۲۱۱، ۰/۰۷۰۳، ۰/۰۱۲۶ و ۰/۹۹۳ به دست آمد. مقادیر ضرایب رگرسیونی دارای عدد پی کوچکتر ۰/۰۱ می‌باشد، همچنین جدول تجزیه واریانس نیز برای رگرسیون محاسبه شد که نتایج از معنادار بودن معادله برازش داده شده حکایت دارد ($p < 0.01$). در نهایت پراکنش مقادیر خطا محاسبه شد، که نشان‌دهنده صحت مدل رگرسیونی و عدم وجود هم‌راستایی در بین پارامترهای ورودی دارد (جدول ۱). در نمودار ۱ دیاگرام پراکنش در داده‌های تست برای مدل رگرسیون آورده شده است.

$$EC = 0.05332 + 0.450 P + 0.454 GDP - 0.175 I + 0.354 E \quad (2)$$

جدول ۱ نتایج تجزیه واریانس برای رگرسیون

مقدار پی	اف فیشر	میانگین مربعات	مجموع مربعات	درجه آزادی	منابع
۰/۰۰۰ < ۰/۰۱	۱/۱۴۹	۰/۴۷۲	۱/۸۸۷	۴	رگرسیون
		۰/۰۰۰	۰/۰۱۲	۲۹	باقیمانده خطا
			۱/۸۹۹	۳۳	کل



نمودار ۱ نمودار پراکنش برای مقادیر مشاهده و پیش‌بینی شده با استفاده از روش رگرسیون


۸-۳- نتایج شبکه عصبی

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 شود. در تعیین این موارد، روش‌های سیستماتیکی وجود ندارد؛ بنابراین بهترین طراحی شبکه با استفاده از تجربه و آزمایش و خطا به دست می‌آید.

در این پژوهش پس از تعیین مجموعه داده‌های تست و آموزش، داده‌های ورودی به شبکه با استفاده از رابطه ۱ استانداردسازی شدند. در صورتی که داده‌ها به صورت خام وارد شبکه شود، به علت تغییرات زیاد داده‌ها، تأثیر متفاوتی 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 پیش‌بینی مدل پایین خواهد آمد [۴۰]. از این رو در آغاز داده‌ها را با استفاده از رابطه ۱ استاندارد کردند؛ یعنی بین یک دامنه عددی که معمولاً (۰/۹ و ۰/۱) می‌باشد، قرار می‌گیرند.


در این تحقیق از شبکه پرسپترون چند لایه با یک لایه مخفی که دارای تابع فعال‌سازی سیگموئید در لایه مخفی و تابع فعال‌سازی خطی در لایه خروجی بود، استفاده شد. تعداد نرون‌های آن از یک تا ۱۰ نرون متغیر بوده و بهترین تعداد نرون به صورت سعی و خطا تعیین گردید. همچنین به علت کارایی، سادگی و سرعت بالا در این تحقیق، الگوریتم آموزشی

لونیبرگ مارکوارت استفاده شد. برای پیش‌بینی مصرف انرژی، ورودی‌های شبکه جمعیت، تولید ناخالص داخلی، واردات و صادرات بود. برای این ویژگی مقادیر RMSE در شکل ۴ ارائه شده است. با توجه به شکل ملاحظه می‌شود که حداقل مقدار RMSE مربوط به شبکه با نرون نه در لایه مخفی می‌باشد. همان‌طور که در شکل دیده می‌شود تغییرات RMSE دارای روند مشخصی نمی‌باشد، چون شبکه عصبی یک مدل جعبه سیاه است و وزن‌ها به طور تصادفی انتخاب می‌شوند، در این صورت نمی‌توان این روند موجود را به طور کامل توضیح داد. فقط باید با سعی و خطا بهترین ساختار را به دست آورد. اما توجهی که می‌شود بیان کرد این است که با پیچیده‌تر شدن مدل، شبکه عصبی بیش از حد آموزش می‌بیند و قادر به برازش مناسب روی داده‌های جدید نمی‌باشد.



شکل ۴ مقادیر RMSE برای تعداد نرون متفاوت

نمودار ۲ پراکنش داده‌های تست برای مدل شبکه عصبی با ساختار ۱-۹-۳ که بهترین عملکرد را به خود اختصاص داد، آورده شده است. با توجه به این شکل ملاحظه می‌شود بهترین خط برازش داده شده دارای زاویه‌ای نزدیک به ۴۵ درجه می‌باشد که نشان از دقت بالا می‌باشد.



نمودار ۲ نمودار پراکنش برای مقادیر مشاهده و پیش‌بینی شده با استفاده از روش شبکه عصبی نتایج ارزیابی خطا برای ساختار ۳-۹-۱ شبکه عصبی با شاخص‌های گوناگون خطا در جدول ۲ آمده است.

جدول ۲ نتایج ارزیابی خطا برای ساختار ۳-۹-۱ در روش شبکه عصبی


ارزش	نوع شاخص
۷۷/۵۰۱۵	RI
۰/۰۰۴۷	RMSE
۰/۰۰۱۳	ME
۰/۰۱۵۸	RSE

۸-۴- نتایج مدل ترکیبی الگوریتم ژنتیک- شبکه عصبی

در این مدل تعداد جمعیت اولیه ۵۰، حداکثر نسل ۱۰۰ و تعداد گردش برابر با ۱۰۰ دور در نظر گرفته شده است. همچنین احتمال جهش برابر با ۰/۱ و احتمال ترکیب برابر با ۰/۹ منظور شده است. انتخاب کروموزوم‌های برتر به منظور تولید نسل جدید براساس چرخ رولت انجام گرفت. به منظور توقف الگوریتم از معیار توقف طی تعداد نسل‌های معین بدون توجه به اینکه تغییری در جواب نهایی نسل‌های آخر ایجاد گردد، استفاده شد. مدل ANN به کار گرفته شده شبکه پرسپترون چند لایه با یک لایه مخفی است که دارای تابع فعال‌سازی سیگموئید در



لایه مخفی و تابع فعال‌سازی خطی در لایه خروجی بوده و تعداد نرون‌های آن از یک تا حداکثر ۱۰ نرون متغیر می‌باشد و از الگوریتم آموزشی لونیبرگ مارکوارت استفاده شد. نمودار پراکنش و نتایج خطای این مدل ترکیبی در نمودار و جدول ۳ آمده است.



نمودار ۳ نمودار پراکنش برای مقادیر مشاهده و پیش‌بینی شده با استفاده از مدل ترکیبی الگوریتم ژنتیک-شبکه عصبی

جدول ۳ نتایج ارزیابی خطا برای مدل ترکیبی الگوریتم ژنتیک-شبکه عصبی

نوع شاخص	ارزش
RI	۸۰/۲۰۹۲
RMSE	۰/۰۰۴۱
ME	۰/۰۰۱۶
RSE	۰/۰۱۳۹

۵-۸- ارزیابی مدل‌های پیش‌بینی

نتایج مربوط به مدل‌های ترکیبی الگوریتم ژنتیک-شبکه عصبی، شبکه‌های عصبی مصنوعی و رگرسیون چند متغیره مربوط به پارامتر مورد اندازه‌گیری در جدول‌های ۴ و ۵ ارائه شده است. با توجه به این جدول‌ها ملاحظه می‌شود که در کل بهترین عملکرد در پیش‌بینی ویژگی مورد مطالعه مربوط به مدل ترکیبی الگوریتم ژنتیک-شبکه عصبی است. از لحاظ هر چهار معیار بهتر از شبکه

عصبی و رگرسیون چند متغیره می‌باشد. بعد از مدل الگوریتم ژنتیک- شبکه عصبی، شبکه عصبی مصنوعی پس انتشار بهترین عملکرد را به خود اختصاص داده است. برای ارزیابی کارایی مدل‌ها می‌توان از شاخص RI استفاده کرد. این آماره نشان‌دهنده میزان کاهش خطا در مدل‌های مختلف نسبت به روش رگرسیون می‌باشد. همان‌طور که در جدول ۵ ارائه شده است، مدل الگوریتم ژنتیک- شبکه عصبی دقت پیش‌بینی را نسبت به روش رگرسیون خطی چندگانه برای مصرف انرژی به میزان ۸۰/۲۱ درصد افزایش داده است. همچنین مدل شبکه عصبی با ساختار ۳-۹-۱ دقت پیش‌بینی را نسبت به روش رگرسیون خطی چندگانه برای مصرف انرژی به میزان ۷۷/۵۰ درصد افزایش داده است. آماره مثبت میانگین خطا نیز نشان دهنده این است که تمام مدل‌ها به جز الگوریتم ژنتیک- شبکه عصبی مقداری بیش برآزش داشته‌اند.

جدول ۴ مقادیر واقعی و پیش‌بینی شده مصرف انرژی به وسیله مدل‌های مختلف

سال	مقادیر واقعی	REG	ANN	ANN-GA
۱۳۸۰	۰/۵۲۷۴	۰/۵۳۱۹	۰/۵۳۶۰	۰/۵۲۶۰
۱۳۸۱	۰/۲۰۸۷	۰/۲۲۵۰	۰/۲۰۹۴	۰/۲۰۹۱
۱۳۸۲	۰/۱۷۱۵	۰/۱۸۷۸	۰/۱۷۵۱	۰/۱۷۵۹
۱۳۸۳	۰/۵۰۲۴	۰/۵۰۱۱	۰/۴۹۵۰	۰/۴۹۹
۱۳۸۴	۰/۱۱۹۹	۰/۱۲۳۵	۰/۱۱۶۸	۰/۱۱۴۴
۱۳۸۵	۰/۴۶۶۵	۰/۵۰۸۲	۰/۴۶۷۳	۰/۴۶۷۵
۱۳۸۶	۰/۱۸۹۹	۰/۲۲۳۱	۰/۱۹۳۲	۰/۱۹
۱۳۸۷	۰/۲۲۳۷	۰/۲۱۰۲	۰/۲۲۸۰	۰/۲۱۵

جدول ۵ عملکرد مدل‌های مختلف در پیش‌بینی مصرف انرژی

	ANN	REG	ANN-GA
RMSE	۰/۰۰۴۷	۰/۰۲۱۱	۰/۰۰۴۱
RSE	۰/۰۱۵۸	۰/۰۷۰۳	۰/۰۱۳۹
ME	۰/۰۰۱۳	۰/۰۱۲۶	-۰/۰۰۱۶
RI	۷۷/۵۰۱۵	۰/۰۰	۸۰/۲۰۹۲

۹- نتیجه‌گیری

رشد و حتی بقای بیشتر فعالیت‌های اقتصادی کشورهای در حال توسعه به مسئله تأمین انرژی بستگی دارد. از این رو مسئولان آن کشورها سعی می‌کنند تا 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 الگوریتم ژنتیک- شبکه عصبی، شبکه عصبی مصنوعی و رگرسیون چند متغیره مقادیر انرژی مصرفی ایران برآورد شد.

نتایج این پژوهش نشان داد که در تمام شاخص‌های ارزیابی، شبکه‌های عصبی مصنوعی نسبت به معادلات رگرسیونی کارایی بهتر داشته است، به طوری که نتایج مطالعات گذشته انجام شده در حوزه پیش‌بینی قیمت و مصرف انرژی همچون امین ناصری و کوچک‌زاده (۱۳۸۷)، ابریشمی و همکاران (۱۳۸۹)، صادقی و همکاران (۱۳۹۰)، پاو (۲۰۰۶) و گیم و روپر (۲۰۰۹) مبنی بر دقت بیشتر مدل‌های شبکه عصبی بر مدل‌های رگرسیونی را تأیید می‌کند.

در این تحقیق نیز سعی بر آن شد تا با کاربرد الگوریتم ژنتیک- شبکه عصبی برای پیش‌بینی در حوزه انرژی، نتایج آن با الگوهای شبکه‌های عصبی و رگرسیون مقایسه شود تا کارایی روش پیشنهادی با دیگر روش‌ها مقایسه شود.

نتایج بررسی نشان داد که مدل ترکیبی الگوریتم ژنتیک- شبکه عصبی نسبت به دیگر مدل‌های مورد بررسی، دارای بالاترین دقت در پیش‌بینی مصرف انرژی می‌باشد. بعد از این مدل شبکه‌های عصبی مصنوعی نسبت به معادلات رگرسیونی پایه کارایی بهتر داشته است. در پایان باید اذعان داشت که با توجه به بهینه شدن وزن‌های اولیه تصادفی به وسیله الگوریتم ژنتیک، به نظر می‌رسد کارایی بالاتر مدل الگوریتم ژنتیک- شبکه عصبی در پیش‌بینی مصرف انرژی به همین علت باشد. تحقیق حاضر به بررسی کارایی مدل‌های مذکور در پیش‌بینی مصرف انرژی ایران پرداخته شد. پیشنهاد می‌شود در تحقیقات آینده به پیش‌بینی مصرف انرژی برای تفکیک بخش‌های مختلف اقتصادی پرداخته شود و کارایی مدل‌های مذکور سنجش شود. همچنین تحقیقات آینده می‌تواند با ترکیب شبکه‌های عصبی و مجموعه‌های فازی، میزان دقت آن با مدل‌های پیش‌بینی این تحقیق مقایسه شود.

۱۰- پی‌نوشت‌ها

1. Genetic algorithms
2. Chromosomes
3. Binary strings
4. bit
5. Genetic operators
6. Selection
7. Roulette wheel
8. Crossover
9. Search space
10. Mutation
11. Convergence
12. Global optimum
13. Rudolph
14. Abstract genetic algorithm
15. Elitist selection

۱۱- منابع

- [۱] مبینی دهکردی ع؛ جعفری ح. ، حمیدی‌نژاد ح. و ع؛ «بررسی وضعیت شاخص‌های مدیریت انرژی»؛ فصلنامه راهبرد، سال هجدهم، شماره ۵۱، ۱۳۸۸
- [2] Kavaklioglu K., Ceylan H., Ozturk HK., Canyurt OE ; "Modeling and prediction of Turkey's electricity consumption using artificial neural networks"; *Energy Convers Manage*, Vol. 50, 2009.
- [3] Ozturk HK., Ceylan H., Canyurt OE., Hepbasli A.; "Electricity estimation using genetic algorithm approach: A case study of Turkey"; *Energy*, Vol 30, 2005.
- [4] Sozen A., Gulseven Z., Arcaklioglu E.; "Forecasting based on sectoral energy consumption of GHGs in Turkey and mitigation policies"; *Energy Policy*, Vol 35, 2007.
- [5] Azadeh A., Ghaderi SF., Sohrabkhani S.; "A simulated-based neural network algorithm for forecasting electrical energy consumption in Iran"; *Energy Policy*, Vol. 36, 2008.
- [6] Sozen A., Arcaklioglu E.; "Prospects for future projections of the basic energy



- sources in Turkey, *Energy Sources*"; *B: Econ, Plann, Policy*, Vol. 2, 2007.
- [7] Sozen A., Arcaklioglu E., Ozkaymak M.; "Modeling of the Turkey's net energy consumption using artificial neural network"; *Int J Comput Appl Technol*, Vol. 22, 2005.
- [8] Murat YS., Ceylan H.; "Use of artificial neural networks for transport energy demand modeling"; *Energy Policy*, Vol. 34, 2006.
- [9] Glasure YU., Lee AR; "Cointegration, error-correction, and the relationship between GDP and electricity: The case of South Korea and Singapore"; *Resour Energy Econ*, Vol. 20, 1997.
- [10] Ozturk I., Acaravci A.; The causal relationship between energy consumption and GDP in Albania, Bulgaria, Hungary and Romania: Evidence from ARDL bound testing approach"; *Appl Energy*, Vol. 87, 2010.
- [11] Narayan PK., Narayan S., Popp S.; "Does electricity consumption panel Granger cause GDP? A new global evidence"; *Appl Energy*, Vol. 87, 2010.
- [12] Narayan PK., Narayan S., Popp S.; "Energy consumption at the state level: the unit root null hypothesis from Australia"; *Appl Energy*, Vol 87, 2010.
- [۱۳] ناصری ا.، کوچکزاده م. و ا.؛ «مدل طراحی بهینه معماری برای شبکه‌های عصبی مصنوعی و به کارگیری آن در پیش‌بینی مصرف ماهانه نفت گاز کل کشور»؛ مجله *مدرس علوم انسانی*، دوره دوازدهم، شماره ۴، ۱۳۸۷.
- [۱۴] ابریشمی ح.؛ غنیمی فرد، ح.، احراری م.، رضایی م.؛ پیش‌بینی قیمت گازوئیل خلیج فارس، مبتنی بر تحلیل تکنیکی و شبکه‌های عصبی؛ *فصلنامه مطالعات اقتصاد انرژی*، سال هفتم، ش. ۲۴، ۱۳۸۹.
- [۱۵] صادقی ح.؛ ذوالفقاری م.، الهامی‌نژاد م.؛ «مقایسه عملکرد شبکه‌های عصبی و مدل ARIMA در مدلسازی و پیش‌بینی کوتاه‌مدت قیمت سبب نفت خام اوپک (با تأکید بر انتظارات تطبیقی)»؛ *فصلنامه مطالعات اقتصاد انرژی*، سال هشتم، ش. ۲۸، ۱۳۹۰.
- [16] Pao HT.; "Comparing linear and nonlinear forecasts for Taiwan's electricity consumption"; *Energy*, Vol 31, 2006.
- [17] Geem ZW., Roper WE; "Energy demand estimation of South Korea using artificial neural network"; *Energy Policy*, Vol. 37, 2009.

- [18] Ekonomou L.; "Greek long-term energy consumption prediction using artificial neural network"; *Energy*, Vol. 35, 2010.
- [19] Ediger VS., Tatlidil H.; "forecasts the primary-energy demand in Turkey and analysis of cyclic patterns"; *Energy Convers Manage*; Vol 43, 2002.
- [20] Ceylan H., Ozturk HK ; "Estimating energy demand of Turkey based on economic indicators using genetic algorithm approach"; *Energy Convers Manage*, Vol. 45, 2004.
- [21] Canyurt OE., Ceylan H., Ozturk HK., Hepbasli A. ; "Energy demand estimation based on two-different genetic algorithm approaches"; *Energy Sources*, Vol. 26, 2004.
- [22] Ediger VS., Akar S.; "ARIMA forecasting of primary energy demand by fuel in Turkey"; *Energy Policy*, Vol. 35, 2007.
- [23] Toksari MD; "Ant colony optimization approach to estimate energy demand of Turkey"; *Energy Policy*, Vol. 35, 2007.
- [24] Sozen A., Arcaklioglu E.; "Prediction of net energy consumption based on economic indicators (GNP and GDP) in Turkey"; *Energy Policy*, Vol. 35, 2007.
- [25] Uner A.; "Improvement of energy demand forecasts using swarm intelligence: the case of Turkey with projections to 2025"; *Energy Policy*, Vol. 36, 2008.
- [۲۶] البرزی م؛ آشنایی با شبکه عصبی؛ تهران: انتشارات علمی شریف، ۱۳۸۰.
- [27] Gorr W. L., Nagin D.; "Comparative study of artificial neural network and statistical models for predicting student grade point averages"; *International Journal of Forecasting*, Vol. 10, 1994.
- [28] Zhang G.P.; "Time series forecasting using a hybrid ARIMA and neural network model"; *Neurocomputing*, Vol. 50, 2003.
- [29] Malik F., Nasereddin M.; "Forecasting output using oil prices: A cascaded artificial neural network approach"; *Journal of Economics and Business*, Vol. 58, 2006.

- [۳۰] منهاج، م. ب.؛ مبانی هوش محاسباتی؛ جلد ۱ و ۲، چاپ اول، تهران: نشر دانشگاه صنعتی امیرکبیر، ۱۳۷۹.
- [۳۱] قنبری ع.، خضری م.، اعظمی آ.؛ «شبیه‌سازی تابع تقاضای بنزین و نفت گاز در حمل و نقل زمینی ایران، با استفاده از روش الگوریتم ژنتیک»، *فصلنامه اقتصاد مقداری (بررسی‌های اقتصادی سابق)*، ش. ۴، ۱۳۸۷.
- [32] Chakraborty M. Chakraborty U.K.; "An analysis of linear Ranking and Binary Tournament selection in Genetic Algorithms"; IEEE Transactions, Proceeding of International Conference on Information, Communication and Signal Processing, ICIS'97, Singapore, 9-12 Sep, 1997.
- [33] Goldberg D.E ; "Genetic algorithm in search"; Optimization and Machine Learning, Addison Wesley Publishing Co, 1989.
- [34] Colt W., David & Ealice Smith; "Using a neural network as a function evaluator during GA search for reliability optimization"; Department of Industrial Engineering University of Pittsburg, Pittsburg, 1999.
- [35] Charboneaw P. ; "Introduction to genetic algorithms for numerical Optimization"; *National Center For Atmospheric Research Boulder, Colorado*, 1997.
- [36] Reeves R., Colin E., Jonathan P.; "Genetic algorithm principle and perspectives"; Kluwer Academic Publishers, 2003.
- [37] Verna B., Mounita G.; "A neural – evolutionary approach for feature architecture selection in online handwriting recognition"; School of Information Technology, Griffidh University Cold Coast Campus, 2002.
- [38] Ahmad S., Simonovic S.P.; "An artificial neural network model for generating hydrograph from hydro meteorological parameters"; *J. Hydrol*, Vol. 315, 2005.
- [۳۹] زارع‌زاده مهریزی م.، بزرگ حداد ا.؛ «شبیه‌سازی و پیش‌بینی آبدهی با استفاده از الگوریتم ترکیبی ANN-GA»، *نشریه آب و خاک*، ش. ۲۴، ۱۳۸۹.
- [۴۰] منهاج م. ب.؛ مبانی شبکه‌های عصبی. انتشارات دانشگاه صنعتی امیرکبیر، چاپ سوم، ۱۳۸۴.