

## کاربرد شبکه عصبی مبتنی بر الگوریتم ژنتیک در پیش‌بینی تقاضای بلندمدت انرژی

حسین صادقی

دانشیار اقتصاد دانشگاه تربیت مدرس، Sadeghih@modares.ac.ir

حسین سهرابی‌وفا\*

کارشناس ارشد اقتصاد پردیس شهید عباسپور، SohrabiVafa@gmail.com

فاطمه نوری

کارشناس ارشد اقتصاد دانشگاه مفید، Nfatemeh67@yahoo.com

تاریخ دریافت: ۹۲/۱/۲۸ تاریخ پذیرش: ۹۲/۴/۲۹

### چکیده

پیش‌بینی تقاضای انرژی جهت عرضه به موقع، تنظیم بازار، هدفگذاری میزان صادرات و ایجاد امنیت انرژی اهمیت ویژه‌ای دارد. روش‌های مختلفی برای پیش‌بینی تقاضای انرژی معرفی شده است که در این بین با توجه به روند غیرخطی و پرنوسان تقاضای انرژی، تکنیک‌های غیرخطی نتایج مطلوب‌تری داشته است. شبکه‌های عصبی و الگوریتم ژنتیک از مهمترین و پرکاربردترین تکنیک‌های غیرخطی در این زمینه می‌باشند که هر یک نقاط ضعف و قوت خاصی دارند. در این مطالعه با ترکیب شبکه عصبی و الگوریتم ژنتیک، نقایص مذکور مرتفع شده و با الگوریتم ترکیبی معرفی شده به پیش‌بینی تقاضای انرژی در ایران پرداخته شده است. نتایج مطالعه در پیش‌بینی تقاضای انرژی طی سال‌های ۱۳۴۶ تا ۱۳۹۰ نشان دهنده قدرت پیش‌بینی بالاتر تکنیک ترکیبی در کنار قدرت توضیح‌دهندگی متغیرهای توضیحی بکار رفته است.

**کلمات کلیدی:** شبکه عصبی، الگوریتم ژنتیک، پیش‌بینی، تقاضا، انرژی

**طبقه‌بندی JEL:** Q41, Q40, C69, C53, C45, C22

---

\* نویسنده مسئول

## ۱- مقدمه

امروزه علاوه بر نهاده نیروی کار و سرمایه، انرژی نیز به عنوان یکی از نهاده‌های مهم تولیدی در بخش‌های مختلف اقتصادی ایفای نقش می‌نماید. به طوری که تغییر در میزان مصرف آن در کاهش یا افزایش سطح تولید به طور قابل توجهی تاثیرگذار می‌باشد بنابراین، بررسی و پیش‌بینی روند تقاضای انرژی جهت اتخاذ سیاست‌های اقتصادی مناسب و مدیریت تقاضای این نهاده اهمیت فراوانی دارد. در این راستا محققین روش‌های مختلفی را برای پیش‌بینی تقاضای انرژی مورد استفاده قرار داده‌اند که در این بین، روش‌های هوشمند بخصوص شبکه‌های عصبی مصنوعی<sup>۱</sup> (ANN) و الگوریتم ژنتیک<sup>۲</sup> (GA) قابلیت‌های خود را در مدلسازی فرآیندهای مختلف بخوبی نشان داده‌اند. با این وجود، هر یک از این تکنیک‌ها دارای نقاط ضعفی نیز می‌باشند. برای مثال، در استفاده از الگوریتم ژنتیک به دلیل تحمیل فرم تبعی خاص بصورت خطی، درجه دوم، نمایی<sup>۳</sup> و یا هر فرم تبعی دیگر، امکان عدم شناسایی روابط پیچیده غیرخطی وجود دارد (آزاده و همکاران<sup>۴</sup>، ۲۰۰۹). از سوی دیگر شبکه‌های عصبی مصنوعی اگر چه نیاز به تعیین فرم تبعی خاص ندارند اما در این روش نیز معایبی همچون عدم وجود یک روش استقرایی جامع در انتخاب الگوریتم یادگیری شبکه، توقف الگوریتم در مینیمم محلی<sup>۵</sup> و همچنین نیاز به منبع غنی داده‌ها برای یادگیری شبکه وجود دارد. در این مطالعه با توجه به روند غیرخطی تقاضای انرژی و محدودیت داده‌ها، برای نخستین بار تکنیک ترکیبی الگوریتم ژنتیک و شبکه عصبی چندلایه پرسپترون<sup>۶</sup> (MLP) جهت پیش‌بینی تقاضای بلند مدت انرژی در دوره زمانی ۱۳۴۶ تا ۱۳۹۰ ادغام شده است.

جنبه‌های نوآوری این مطالعه علاوه بر معرفی یک الگوریتم ترکیبی برای نخستین بار در مطالعات داخلی و خارجی به منظور پیش‌بینی هرچه دقیق‌تر تقاضای انرژی در شرایط محدودیت داده‌ها، استفاده از متغیرهای توضیحی متفاوت نیز است. متغیرهای توضیحی در این مطالعه، تولید ناخالص داخلی، جمعیت، نرخ شهرنشینی، ساختار اقتصادی و ساختار مصرف انرژی در ایران هستند که علت استفاده هر یک در ادامه بحث می‌شود.

<sup>۱</sup> Artificial Neural Network(ANN)

<sup>۲</sup> Genetic Algorithm

<sup>۳</sup> Linear, Quadratic, Exponential

<sup>۴</sup> A. Azadeh *et al.*

<sup>۵</sup> Local minimum

<sup>۶</sup> Multi-Layer Perceptron (MLP)

بخش دوم این مقاله به پیشینه تحقیق می‌پردازد. مبانی نظری الگوریتم ژنتیک و شبکه‌های عصبی در بخش سوم مرور شده و در بخش چهارم الگوریتم ترکیبی پیشنهادی معرفی می‌شود. در بخش پنجم متغیرهای توضیحی معرفی و در بخش ششم تقاضای انرژی با استفاده از تکنیک‌های مختلف پیش‌بینی شده و با استفاده از معیارهای مختلف ارزیابی خطا، کارایی این تکنیک‌ها بررسی می‌شود و در نهایت در بخش هفتم نتایج مطالعه ارائه می‌شود.

## ۲- پیشینه تحقیق

انرژی نقش اساسی در ادامه حیات و توسعه جوامع بشری ایفا می‌نماید. نرخ رشد مصرف انرژی یکی از شاخص‌های توسعه تلقی شده<sup>۱</sup> و انرژی به عنوان یکی از عوامل تولیدی مهم و موثر بر رشد، از جایگاه ویژه‌ای برخوردار است (دانکرلی و همکاران<sup>۲</sup>، ۱۹۸۱). از این رو 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 مولفه اساسی به شمار می‌رود (بهاتاچاریا و تیمیلسینا<sup>۳</sup>، ۲۰۰۹). لذا در سال‌های اخیر مطالعات فراوانی در زمینه پیش‌بینی تقاضای انرژی با استفاده از تکنیک‌های نوین محاسباتی انجام شده که در ادامه و در جدول خلاصه‌ای از مطالعات انجام شده در این زمینه مرور شده است. با نگاهی بر مطالعات انجام شده می‌توان دریافت، مدل‌های غیرخطی و بخصوص شبکه‌های عصبی (NN<sup>۴</sup>) بیشترین کاربرد را در این مطالعات داشته‌اند. البته بکارگیری این روش‌ها با محدودیت‌هایی همچون محدودیت داده‌های آموزشی، توقف الگوریتم یادگیری در نقطه بهینه محلی و نیاز به تعیین فرم تبعی خاص همراه است. در این مطالعه برای نخستین بار در ادبیات مربوط به پیش‌بینی تقاضای انرژی به کمک ترکیب الگوریتم ژنتیک و شبکه عصبی سعی می‌شود معایب هر یک پوشش داده شده و از مزایای آنها در یک الگوریتم واحد استفاده شود. عدم نیاز به فرم تبعی خاص شبکه‌های عصبی و جستجوی نقاط بهینه سراسری الگوریتم ژنتیک در یادگیری شبکه با داده‌های محدود، مهمترین نقاط قوت این دو تکنیک است. از سوی دیگر استفاده از متغیرهای توضیحی متمایز و متناسب کشور ایران مزیت و تمایز دیگر این مطالعه خواهد بود.

<sup>۱</sup> برای مطالعه بیشتر در این زمینه مراجعه شود به: Barnes and Floor, (1996)

<sup>۲</sup> Dunkerley et al.

<sup>۳</sup> Bhattacharyya and Timilsina

<sup>۴</sup> Neural Network (NN)

جدول (۱): مطالعات انجام شده در زمینه پیش‌بینی تقاضای انرژی

متغیر توضیحی	متغیر هدف (کشور)	تکنیک	نویسنده (سال)
درآمد ملی، جمعیت، صادرات، واردات	انرژی (ترکیه)	الگوریتم ژنتیک	جان‌یورت و همکاران <sup>۱</sup> (۲۰۰۴)
تعداد خودروها	انرژی حمل‌ونقل (ترکیه)	الگوریتم ژنتیک	هالدنبیلن و جیلان <sup>۲</sup> (۲۰۰۵)
تعداد خودروها	انرژی حمل‌ونقل (ترکیه)	شبکه عصبی	مرات و جیلان <sup>۳</sup> (۲۰۰۶)
سری زمانی	انرژی الکتریکی (ایران)	شبکه عصبی	آزاده و همکاران <sup>۴</sup> (۲۰۰۷)
درآمد ملی، جمعیت، صادرات، واردات	انرژی (ترکیه)	الگوریتم انبوه ذرات	آنلر <sup>۵</sup> (۲۰۰۸)
سری زمانی	انرژی (تایوان)	شبکه عصبی	پاو <sup>۶</sup> (۲۰۰۹)
تولید ناخالص داخلی، جمعیت، صادرات، واردات	فراورده‌های نفتی (ایران)	الگوریتم ژنتیک و الگوریتم انبوه ذرات	عصاره و همکاران <sup>۷</sup> (۲۰۱۰)
متغیرهای تولید ناخالص داخلی، جمعیت، قیمت سوخت، تعداد خودروهای، میزان حمل‌ونقل	بخش حمل‌ونقل (کره جنوبی)	رگرسیون معمولی، شبکه عصبی	همکاران <sup>۸</sup> (۲۰۱۰)
تولید ناخالص داخلی، جمعیت، تعداد خودروها	بخش حمل‌ونقل (کره جنوبی)	برنامه‌ریزی ژنتیک	فروزان‌فر و همکاران <sup>۹</sup> (۲۰۱۲)
اندازه خانه، تعداد ساکنین، بهره‌وری از تجهیزات گرمایشی، شدت انرژی	بخش خانگی (امریکا)	رگرسیون معمولی، شبکه عصبی	کیالاشکی و ریسل <sup>۱۰</sup> (۲۰۱۳)


منبع: سهرابی‌وفا (۱۳۹۱)

<sup>1</sup> Canyurt *et al.*<sup>2</sup> Haldenbilen and Ceylan<sup>3</sup> Murat and Ceylan<sup>4</sup> Azadeh *et al.*<sup>5</sup> Ünler<sup>6</sup> Pao<sup>7</sup> Assareh *et al.*<sup>8</sup> Geem<sup>9</sup> Forouzanfar *et al.*<sup>10</sup> Kialashaki and Reisel

## ۲- مبانی نظری شبکه‌های عصبی و الگوریتم ژنتیک

## ۳-۱- شبکه عصبی

پس از شناخت توانایی سلول‌های عصبی در مغز انسان، مفهوم شبکه‌های عصبی مصنوعی در سال ۱۹۴۳ توسط مک‌کلاک<sup>۱</sup> (عصب‌شناس) و پیت<sup>۲</sup> (ریاضیدان) مطرح شد و بعدها به طور گسترده‌ای مورد اقبال عمومی پژوهشگران در مدل‌سازی تجری فرایندهای غیرخطی قرار گرفت (هکین<sup>۳</sup>، ۱۹۹۹). اولین شبکه عصبی مصنوعی را روزنبلات<sup>۴</sup> (۱۹۵۸) به نام پرسپترون<sup>۵</sup> طراحی و بکار گرفت. پس از آنکه در سال ۱۹۸۲ هاپفیلد<sup>۶</sup> با طراحی شبکه عصبی به همین نام-هاپفیلد- توانست یکی از پیچیده‌ترین مسائل بهینه سازی موسوم به فروشنده دوره‌گرد<sup>۷</sup> (TSP) را حل کند، قدرت شبکه‌های عصبی در مدل‌سازی مسائل غیرخطی مورد توجه قرار گرفت و بعدها مک‌کلند و راملهارت<sup>۸</sup> (۱۹۸۶) با ارائه الگوریتم پس-انتشارخطا<sup>۹</sup> (BP) شبکه‌های عصبی چند لایه پیشخور<sup>۱۰</sup> با نام پرسپترون چندلایه (MLP) را توسعه بخشیدند. یک شبکه عصبی پیشخور سه لایه که (شکل (۱) به عنوان ساختار پایه برای شبکه عصبی مورد استفاده در این مطالعه در نظر گرفته شده است. در شبکه عصبی پیشخور جریان اطلاعات یک‌سویه از ورودی به خروجی برقرار می‌باشد.



شکل (۱): ساختار شبکه عصبی پیشخور سه لایه  
منبع: سهرابی و وفا (۱۳۹۱)

<sup>1</sup> McCulloch

<sup>2</sup> Pitts

<sup>3</sup> Haykin

<sup>4</sup> Rosenblatt

<sup>5</sup> Perceptron

<sup>6</sup> Hopfield

<sup>7</sup> Traveling Salesman Problem

<sup>8</sup> McClelland and Rumelhart

<sup>9</sup> Back Propagation (BP)

<sup>10</sup> Feed Forward Neural Network

در مطالعات مختلف اشاره شده است که چنین ساختار شبکه‌ای دارای قابلیت بسیار بالایی در نگاشت میان ورودی و خروجی بوده و در صورت استفاده از نرون‌های کافی در لایه پنهان قادر به تخمین هر نوع تابع پیوسته غیرخطی با دقت مطلوب می‌باشد (هورنیک<sup>۱</sup>، ۱۹۹۱). خروجی چنین شبکه‌ای را می‌توان به صورت تابع (۱) نشان داد:

$$y(k) = \sum_{j=1}^m w_j f_j \left( \sum_{i=1}^n w_{ij} x_i(k) + w_{j0} \right) + w_0 \quad (1)$$

در تابع فوق  $x_i(k) = [x_1(k), x_2(k), \dots, x_n(k)]^T$  بردار متغیرهای ورودی در زمان  $k$ ،  $y(k)$  متغیر هدف،  $w_j$  ضریب اتصال نرون پنهان  $j$ ام به لایه آخر،  $w_0$  اریبی لایه خروجی،  $w_{j0}$  اریبی لایه ورودی،  $w_{ij}$  ضرایب اتصال ورودی  $i$ ام به نرون  $j$ ام لایه پنهان و  $f_j$  نیز تابع فعال‌سازی غیرخطی نرون  $j$ ام لایه پنهان می‌باشد. تابع هدف برای آموزش چنین شبکه‌ای بصورت رابطه (۲) قابل تعریف است:

$$f(w) = \frac{1}{M} \sum_{k=1}^M (y_k^{real} - y_k^{predict})^2 \quad (2)$$

در رابطه فوق که نشان دهنده میانگین مجذور خطاهای پیش‌بینی می‌باشد،  $M$  نشان دهنده تعداد مشاهدات در زمان‌های مختلف،  $y_k^{real}$  نشان‌دهنده خروجی حقیقی برای هر ورودی در زمان  $k$  و  $y_k^{predict}$  نیز نشان‌دهنده خروجی شبکه به منظور پیش‌بینی مقدار خروجی حقیقی در زمان  $k$  می‌باشد. معمولاً هدف الگوریتم بهینه‌یابی در چنین مسائلی یافتن ضرایبی است که منجر به کمینه شدن رابطه فوق می‌گردد. الگوریتم پس‌انتشار خطا<sup>۲</sup> (BP) مهمترین و پرکاربردترین تکنیک بهینه‌یابی در آموزش شبکه‌های عصبی محسوب می‌شود. این الگوریتم در سال ۱۹۸۶ توسط رامله‌هارت و مک‌لند مطرح شد (مهنج، ۱۳۸۴). نام پس‌انتشار خطای یادگیری با توجه به اینکه خطای محاسبه شده از لایه خروجی به لایه میانی و نهایتاً به لایه ورودی بازگشت داده می‌شود، انتخاب شده است. پس از آموزش شبکه عصبی از داده‌های آزمون<sup>۳</sup> (تصدیق) به منظور بررسی میزان جامعیت شبکه شبکه و انتخاب بهترین شبکه آموزش دیده استفاده می‌شود (مهنج و همکاران، ۱۳۸۹). الگوریتم پس‌انتشار خطا را می‌توان تعمیم یافته قانون دلتا نامید. روبرط (۳) تا (۵) نحوه محاسبه وزن‌های شبکه بر اساس این قانون را نشان می‌دهد.

<sup>1</sup> K. Hornik

<sup>2</sup> Back Propagation (BP)

<sup>3</sup> Test set

$$e_k = y_k^{real} - y_k^{predict} \quad (۳)$$

$$\Delta w_t = \eta e_k p_{kj} \quad (۴)$$

$$w_{t+1} = w_t + \Delta w_t \quad (۵)$$

در روابط فوق  $\eta$ ،  $e_k$ ،  $w$  و  $p_{kj}$  به ترتیب نشان دهنده نرخ یادگیری<sup>۱</sup>، خطای مشاهده شده و وزن مربوط به اتصال نرون  $k$  و  $j$  می‌باشد. اثبات قانون فوق از روش گرادیان نزولی<sup>۲</sup> حاصل می‌شود که بیان می‌کند با حرکت‌های پی‌درپی خلاف جهت بردار گرادیان خطا، می‌توان به نقطه حداقل خطا رسید. این ادعا را می‌توان با استفاده از بسط تیلور نیز تایید کرد (هکین، ۱۹۹۹).

پس از معرفی الگوریتم پس انتشار خطا، الگوریتم لونبرگ-مارکوارت (LM<sup>۳</sup>) با سرعت هم-گرایی بیشتر در بهینه‌یابی اوزان شبکه عصبی ارائه شد که قاعده یادگیری آن بصورت رابطه (۶) می‌باشد:

$$w_{k+1} = w_k - [J'_k J_k + \mu I]^{-1} J'_k e_k \quad (۶)$$

که در آن  $w$ ،  $J$ ،  $\mu$ ،  $I$  و  $e$  به ترتیب نشان دهنده بردار وزن، ماتریس ژاکوبین<sup>۴</sup> (برابر مشتق‌های خطای متناظر هر وزن)، پارامتر ثابت، ماتریس واحد، و بردار خطا می‌باشد.

### ۳-۲- الگوریتم ژنتیک با کدینگ حقیقی

الگوریتم ژنتیک در مسائل مختلف از جمله بهینه‌یابی، طراحی، شبکه عصبی، سیستم خبره<sup>۵</sup> و غیره نتایج مطلوبی داشته است (استندر<sup>۶</sup>، ۱۹۹۳). ایده اصلی این الگوریتم در نظریه تکامل داروین نهفته است. الگوریتم ژنتیک در واقع شناخته‌شده‌ترین نوع از الگوریتم‌های تکاملی است. ایده محاسبات تکاملی<sup>۷</sup> در سال ۱۹۶۵ توسط رچنبرگ<sup>۸</sup> در کتابی با عنوان استراتژی-استراتژی‌های تکامل معرفی شد (صادقی و همکاران، ۱۳۹۱).

الگوریتم ژنتیک جستجو را با جمعیتی از راه‌حل‌های اولیه تصادفی آغاز کرده و چنانچه معیارهای توقف برآورده نشود، سه عملگر تکثیر<sup>۹</sup>، جهش<sup>۱۰</sup> و تقاطع<sup>۱</sup> به کار گرفته می‌شود

<sup>1</sup> Learning Rate

<sup>2</sup> Gradient Descent

<sup>3</sup> Levenberg-Marquardt

<sup>4</sup> Jacobian Matrix

<sup>5</sup> Expert systems

<sup>6</sup> Stender

<sup>7</sup> Evolutionary computing

<sup>8</sup> Rechenberg

<sup>9</sup> Production

<sup>10</sup> Mutation

تا جمعیت بروز شود. از آنجا که نمایش راه‌حل‌ها در این الگوریتم بسیار شبیه به کروموزوم‌های طبیعی است و همچنین به دلیل شباهت عملگرهای آن به عملگرهای ژنتیکی، روند فوق‌الگوریتم ژنتیک خوانده می‌شود (صادقی و همکاران، ۱۳۹۱).

الگوریتم‌های ژنتیک سنتی که در آنها از کدینگ باینری<sup>۲</sup> استفاده می‌شود برای بسیاری از مسائل پیوسته مناسب نمی‌باشند. اشکال عمده الگوریتم ژنتیک باینری در این است که پارامترها در آن بصورت طول رشته‌ای محدود کدگذاری می‌شوند که این خود زمان محاسباتی زیادی را در فرایند کدینگ و دیکدینگ به هدر می‌دهد. در عوض الگوریتم ژنتیک با کدینگ حقیقی<sup>۳</sup> (RGA) پارامترها را بصورت مستقیم و به همان ویژگی‌های خودشان بکار می‌برد که این امر موجب صرفه‌جویی زیادی در زمان محاسبات خواهد بود. از این رو کدینگ حقیقی الگوریتم ژنتیک بجای کدینگ باینری در مسائل بهینه‌یابی پیوسته بسیار مناسب خواهد بود (دیب و بری<sup>۴</sup>، ۱۹۹۹). از نظر اپراتورهای اصلی، میان الگوریتم ژنتیک با کدینگ باینری و الگوریتم ژنتیک با کدینگ حقیقی تفاوت چندانی وجود نداشته و تنها تفاوت آنها در نحوه بکارگیری عملگر جهش<sup>۵</sup> و تقاطع<sup>۶</sup> می‌باشد.

در مکانیزم تقاطع با کدینگ حقیقی نیز واحد جدید توسط ترکیب خطی از دو واحد اصلی ایجاد می‌شود. اگر چنین فرایندی بر روی دو واحد اصلی  $x'_A$  و  $x'_B$  انجام شود واحد جدید بصورت زیر ایجاد خواهد شد:

$$\begin{cases} x_A^{t+1} = \alpha x_B^t + (1-\alpha)x_A^t \\ x_B^{t+1} = \alpha x_A^t + (1-\alpha)x_B^t \end{cases} \quad (7)$$

در تابع فوق  $\alpha$  برای تقاطع حسابی زوج<sup>۷</sup> یک پارامتر ثابت است و برای تقاطع حسابی غیر زوج متغیر خواهد بود (یو و همکاران<sup>۸</sup>، ۲۰۱۲). در کدینگ حقیقی عملگر جهش باعث تولید تصادفی یک مقدار جدید در یک موقعیت خاص در کروموزوم می‌شود. در نتیجه این تغییرات تصادفی در جمعیت کروموزوم‌ها، نواحی بیشتری از فضای مسئله بررسی شده و از همگرایی محلی الگوریتم جلوگیری می‌شود. اگر  $s = (v_1, v_2, \dots, v_n)$  والد و

<sup>1</sup> Crossover

<sup>2</sup> Binary Coding

<sup>3</sup> Real Coded Genetic Algorithm (RGA)

<sup>4</sup> Deb and Beyer

<sup>5</sup> Mutation

<sup>6</sup> Crossover

<sup>7</sup> Even Arithmetic Crossover

<sup>8</sup> Yu *et al.*



$z = (z_1, z_2, \dots, z_n)$  نیز نسل بعد پس از عمل جهش باشد، در این فرایند، ابتدا فاکتور  $k$  در بردار والد انتخاب شده و سپس یک عدد تصادفی  $v'_k$  در بازه معین  $[a_k, b_k]$  انتخاب می‌شود تا برای  $z_i$  با  $v_k$  بصورت زیر تعویض شود.

$$z_i = \begin{cases} v_i & i \neq k \\ v'_i & i = k \end{cases} \quad (8)$$

### ۳-۴- تکنیک ترکیبی شبکه عصبی و الگوریتم ژنتیک

شبکه‌های عصبی در بسیاری از زمینه‌های مختلف مورد استفاده قرار گرفته است با این وجود، دستیابی به نتایج مطلوب تنها زمانی ممکن بوده است که منبع غنی داده‌ها با مشاهدات فراوان در اختیار باشد و زمانی که با داده‌های اندک برای آموزش شبکه مواجه بوده‌ایم، این تکنیک‌ها کارایی بالایی نداشته که این نقص کاربردهای آنها را بشدت محدود می‌کند (اندونی<sup>۱</sup>، ۲۰۱۰). تکنیک‌های هوشمند متنوعی جهت فائق آمدن بر مسئله محدودیت داده‌های آموزش ارائه شده است؛ ایجاد نمونه‌های آموزشی هوشمند<sup>۲</sup>، انتخاب ویژگی<sup>۳</sup>، تنظیم مناسب پارامترهای مدل استنباطی<sup>۴</sup> و دسته‌بندی گروهی داده‌ها<sup>۵</sup> از جمله جمله تکنیک‌های پیشنهادی در این زمینه بوده است که مطالعات مختلف از جمله مطالعات انجام شده توسط رانگفو و همکاران<sup>۶</sup> (۲۰۰۶)، لی و لیو<sup>۷</sup> (۲۰۰۹)، هوانگ و مورگا<sup>۸</sup> (۲۰۰۴)، مورگا<sup>۹</sup> (۲۰۰۴)، تسای و لی<sup>۹</sup> (۲۰۰۸)، سهرابی و وفا و همکاران (۱۳۹۱) هر یک با رویکردی خاص سعی در حل مسئله محدودیت داده‌ها داشته‌اند. ولی هر یک از تکنیک‌های پیشنهادی در این زمینه دارای نقاط ضعف متعددی می‌باشند؛ امکان‌پذیر نبودن ایجاد نمونه‌های هوشمند و وجود نداشتن چنین نمونه‌هایی در واقعیت، اندک بودن متغیرها در واقعیت برای انتخاب ویژگی، انتخاب مدل نامناسب، محدودیت در ترکیب متغیرهای ورودی و استفاده از تکنیک‌های خطی در تنظیم پارامترهای مدل غیرخطی از جمله مسائل پیش-روی این تکنیک‌ها بوده است. از این رو در این مطالعه به منظور غلبه بر مسائل فوق، به کمک الگوریتم ژنتیک به آموزش شبکه عصبی پرداخته و سپس کارایی آنها با تکنیک‌های

<sup>1</sup> Andonie

<sup>2</sup> Generate Artificial Training Samples

<sup>3</sup> Feature Selection

<sup>4</sup> Parameter Fine-Tuning of the Inferred Model

<sup>5</sup> Group Method of Data Handling

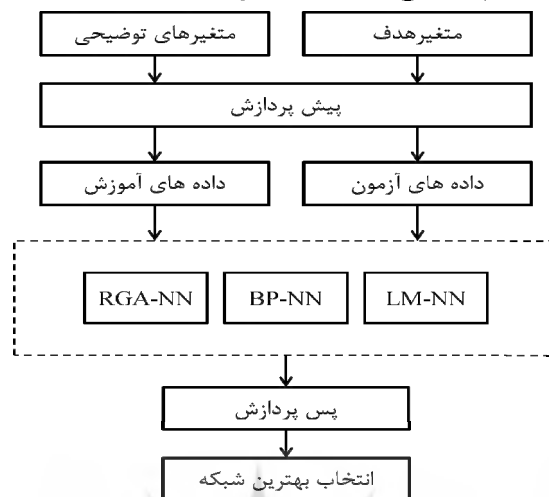
<sup>6</sup> Rongfu *et al.*

<sup>7</sup> Li and Liu

<sup>8</sup> Huang and Moraga

<sup>9</sup> Tsai and Li

رایج مقایسه شده و بهترین روش در پیش‌بینی تقاضای بلند مدت انرژی معرفی می‌شود. مراحل اجرای این الگوریتم ترکیبی در شکل نشان داده شده است.



شکل (۲): فلوچارت الگوریتم ترکیبی پیش‌بینی کننده تقاضای انرژی

منبع: سهرابی و فا (۱۳۹۱)

در شکل نمادهای RGA-NN، BP-NN و LM-NN به ترتیب نشان دهنده شبکه‌های عصبی مبتنی بر الگوریتم ژنتیک، الگوریتم پس‌انتشار خطا و الگوریتم لونیبرگ مارکوارت می‌باشد. در شکل پس از تفکیک داده‌ها به دو دسته داده‌های آموزش و آزمون و نرمال‌سازی، این داده‌ها به موتور پیش‌بینی ارسال می‌شود که در این قسمت پس از آموزش، خروجی هر تکنیک به مقیاس واقعی برگردانده شده و از میان آنها بهترین خروجی بر اساس داده‌های آزمون انتخاب می‌شود.

#### ۴- بررسی مدل

در ابتدا بررسی متغیرهای موثر بر تقاضای انرژی ضروری به نظر می‌رسد. جمعیت کل نه تنها بر مقدار مصرف انرژی تاثیرگذار است بلکه بر منابع مصرف سرانه انرژی و الگوی مصرف انرژی نیز مستقیماً اثر می‌گذارد و در نتیجه رشد بالای جمعیت محرک مصرف انرژی می‌باشد (یو و همکاران، ۲۰۱۲). در مطالعات مختلف از جمعیت به عنوان متغیر توضیحی در مدل‌سازی تقاضای انرژی استفاده شده است که از جمله آنها می‌توان به مطالعات انجام شده توسط محمد و بدجر<sup>۱</sup> (۲۰۰۵)، بیانکو و همکاران<sup>۱</sup> (۲۰۰۹)، آزاده و همکاران (۲۰۱۰) و

<sup>1</sup> Mohamed and Bodger

همچنین عصاره و همکاران<sup>۲</sup> (۲۰۱۰) اشاره کرد. از سوی دیگر مناطق شهری و روستایی در مصرف انرژی دارای الگوی رفتاری متفاوتی می‌باشند. مناطق شهری به دلیل وجود زیرساخت‌های مناسب دارای دسترسی سریع و آسان به منابع انرژی می‌باشند. ولی مناطق روستایی در این زمینه‌ها دارای مزیت کمتری می‌باشند. در مناطق روستایی نحوه دسترسی به سوخت و الگوی مصرفی متفاوت است. از این رو رشد شهرنشینی نیز عامل دیگری است که باعث تشدید تقاضای انرژی خواهد شد (یو و همکاران، ۲۰۱۲). لذا نرخ شهرنشینی (سهام جمعیت شهری از کل جمعیت) نیز می‌تواند به عنوان یک عامل تاثیرگذار بر رشد مصرف انرژی در نظر گرفته شود.

بر اساس تئوری‌های اقتصادی افزایش درآمد منجر به افزایش قدرت خرید مصرف کنندگان شده و افزایش قدرت خرید منجر به افزایش مصرف کالاهای ضروری خواهد شد. روزنبرگ<sup>۳</sup> (۱۹۹۸) بیان می‌کند که شواهدی قوی برای اثرگذاری فرایند توسعه اقتصادی بر مصرف انرژی مشاهده می‌شود. فرگوسن و همکاران<sup>۴</sup> (۲۰۰۰) در مطالعه‌ای میان صد کشور نتیجه می‌گیرند که افزایش در میزان درآمد مستقیماً بر مصرف انرژی اثر می‌گذارد. بنابراین انتظار می‌رود با افزایش درآمد که مهمترین شاخص آن تولید ناخالص داخلی است، تقاضای انرژی نیز افزایش یابد. بر این اساس در مطالعات مختلف از متغیر تولید ناخالص داخلی نیز به عنوان متغیر توضیحی در مدلسازی تقاضای بلندمدت انرژی استفاده شده است که از جمله آنها می‌توان به مطالعات انجام شده توسط آنگ<sup>۵</sup> (۱۹۸۸)، لین<sup>۶</sup> (۲۰۰۳)، آماراویکراما و هانت<sup>۷</sup> (۲۰۰۷) و دیلاور و هانت<sup>۸</sup> (۲۰۱۱) اشاره کرد.

همچنین ساختار اقتصاد نیز یکی از عوامل موثر بر مصرف انرژی می‌باشد. منابع غنی نفت و گاز ایران اجرای سیاست‌های عرضه سوخت ارزان به صنایع منجر به کاهش کارایی انرژی و افزایش شدت انرژی در فعالیت‌های اقتصادی به خصوص صنایع این کشور شده است. از این رو بخش صنعت ایران کارایی انرژی پایینی دارد. در واقع وجود منابع ارزان قیمت انرژی سبب استفاده بسیار زیاد و وابستگی شدید صنایع کشور به این عامل تولیدی شده

<sup>1</sup> Bianco *et al*

<sup>2</sup> Assareh *et al*

<sup>3</sup> Rosenberg

<sup>4</sup> Ferguson *et al*

<sup>5</sup> Ang

<sup>6</sup> Lin

<sup>7</sup> Amarawickrama and Hunt

<sup>8</sup> Dilaver and Hunt

است (فضل‌زاده و تجویدی، ۱۳۸۷). زاهدی وفا (۱۳۸۷) بیان می‌کند که یکی از ویژگی‌های اصلی تولید صنعتی در ایران انرژی بر بودن تولیدات است، به نحوی که در صنایع با انرژی‌بری زیاد مثل فولاد، سیمان و محصولات شیمیایی اساسی عرضه فراوان در بازارهای جهانی مشاهده می‌شود. به عنوان نمونه می‌توان گروه فلزات اساسی را نام برد که شدت مصرف انرژی بسیار بالایی دارد و سهم عمده‌ای از کل صادرات صنعتی را به خود اختصاص داده است (کرامت‌فر، ۱۳۹۱).

از سوی دیگر ایران دارای منابع عظیم نفتی در جهان بوده و یکی از اعضای مهم کشورهای تولیدکننده نفت -اوپک- می‌باشد. همچنین این کشور به دلیل برخورداری از این مزیت منابع عظیم انرژی دارای مصرف بالای انرژی نیز می‌باشد. به منظور مقابله با این وضعیت جامعه و دولت ایران دو راه در پیشرو دارد؛ تغییر الگوی مصرف انرژی یا جایگزینی سوخت جدید. در این رابطه ایران راه دوم را برگزیده است، چراکه این کشور علاوه بر دارا بودن منابع عظیم نفتی دارای رتبه دوم ذخایر گازی در جهان نیز هست (مسرت<sup>۱</sup>، ۲۰۰۴). بنابراین ایران سعی در استفاده از گاز طبیعی به عنوان یک منبع انرژی جایگزین داشته که این امر ساختار انرژی کشور را دگرگون ساخته است. به گونه‌ای که در سال ۱۳۷۹ مصرف گاز طبیعی برای نخستین بار در تاریخ ایران بیشتر از فراوده‌های نفتی شده است (مسرت، ۲۰۰۴). با توجه به آنچه ذکر شد، سهم گاز طبیعی از کل مصرف انرژی به عنوان منعکس‌کننده ساختار انرژی نیز بر روند مصرف انرژی موثر خواهد بود.

با توجه به مطالب فوق و مطالعات تجربی و بر اساس مدل‌های استفاده شده توسط یو و همکاران (۲۰۱۲) که تقاضای بلندمدت انرژی را بر اساس متغیرهای تولید ناخالص داخلی، جمعیت، نرخ شهرنشینی، ساختار اقتصاد و ساختار انرژی مدلسازی و پیش‌بینی نموده‌اند در این مطالعه نیز تابع تقاضای بلندمدت انرژی به صورت رابطه (۹) در نظر گرفته می‌شود.

$$E = f(Gdp, Pop, Urb, ECstr, ENstr) \quad (9)$$

در معادله فوق، E نشان دهنده تقاضای سالانه انرژی معادل میلیون بشکه نفت خام بوده که از ترازنامه‌های انرژی استخراج شده است Gdp, Pop, Urb, ECstr, ENstr به ترتیب نشان دهنده تولید ناخالص داخلی به قیمت ثابت سال ۱۳۷۶ (هزارمیلیارد ریال)، جمعیت (میلیون نفر)، نرخ شهرنشینی (سهم جمعیت شهری از کل جمعیت کشور)، ساختار اقتصاد (سهم بخش صنعت از تولید) و ساختار انرژی (سهم گاز طبیعی از مصرف انرژی) می-

<sup>1</sup> Massarrat

باشند که اطلاعات مربوط به این متغیرها از ترازنامه انرژی و اطلاعات سری زمانی بانک مرکزی<sup>۱</sup> استخراج شده است.

### ۵- پیش‌بینی تقاضای انرژی

با توجه به این نکته که بازارهای انرژی همواره در حال رشد بوده و عوامل اثرگذار بر تقاضای آن دارای روندی غیرخطی بوده و بشدت در نوسان می‌باشند، لذا استفاده از الگوهای هوشمند غیرخطی در مدلسازی تقاضای انرژی اجتناب‌ناپذیر است. شبکه‌های عصبی یکی از تکنیک‌های محاسباتی هوشمند در مدلسازی فرایندهای غیرخطی است که در سال‌های اخیر به موازات پیشرفت‌های ابزار محاسبات و پردازش اطلاعات، از جایگاه پراهمیتی برخوردار گشته و در علوم مختلف دارای پیشرفت‌های روز افزون و نتایج مطلوبی بوده است. شبکه‌های عصبی پیشخور، کاربردی‌ترین نوع شبکه‌های عصبی مصنوعی می‌باشند. چرا که شبکه‌های عصبی پیشخور با یک لایه پنهان، تابع فعال‌سازی مناسب در لایه پنهان و تعداد نرون‌های کافی در لایه پنهان، قادرند هر تابعی را با دقت دلخواه تقریب بزنند (کوان و وایت<sup>۲</sup>، ۱۹۹۴). بر این اساس در این مطالعه از شبکه‌های عصبی پیشخور استفاده شده است و به منظور انجام پیش‌بینی و در واقع گرفتن خروجی از شبکه، برای آموزش و همگرایی سریع‌تر و دقت بیشتر شبکه ابتدا ورودی‌های آن (داده‌ها) با استفاده از تکنیک Min-Max استاندارد شده و به داده‌های نرمال در بازه  $[-1, +1]$  تبدیل می‌شوند.<sup>۳</sup>

$$x_n = 2 \times (x_r - x_{\min}) / (x_{\max} - x_{\min}) - 1 \quad (10)$$

در رابطه (۱۰)،  $x_r, x_n, x_{\max}, x_{\min}$  به ترتیب نشان دهنده مقادیر واقعی، نرمال شده، حداکثر و حداقل داده‌های تحت بررسی می‌باشند. مقادیر حداکثر و حداقل مربوط به متغیرهای تحت بررسی (در سالهای ۱۳۴۶ تا ۱۳۹۰) در

جدول نشان داده شده است. روش‌گاه علوم انسانی و مطالعات فرهنگی پس از مرحله نرمال‌سازی، تصادفی نمودن<sup>۴</sup> داده‌ها انجام می‌شود. نتیجه انجام این مرحله، داشتن مجموعه‌ای از ورودی و خروجی‌ها است که در آن، دسته‌های ورودی-خروجی دارای نظام خاص نیستند. پس از پایان تصادفی نمودن داده‌ها، میزان اطلاعاتی که باید در فرایند

<sup>۱</sup> داده‌های جمعیت سالهای ۱۳۸۸، ۱۳۸۹ و ۱۳۹۰ از سالنامه‌های آماری مرکز آمار ایران استخراج شده است.

<sup>۲</sup> Kuan and White

<sup>۳</sup> به منظور نرمال‌سازی از تابع mapminmax در نرم افزار متلب استفاده می‌شود.

<sup>۴</sup> Randomizing

آموزش شبکه استفاده شود مشخص می‌شود (فرجام‌نیا و همکاران، ۱۳۸۶). بر این اساس بخشی از داده‌ها برای آموزش و بخشی دیگر برای آزمون شبکه در نظر گرفته می‌شود.<sup>۱</sup>

جدول (۲): مقادیر حداکثر و حداقل متغیرهای تحت بررسی در سالهای ۱۳۴۶ تا ۱۳۹۰

متغیر	$x_{\min}$ (سال)	$x_{\max}$ (سال)
مصرف انرژی (میلیون بشکه معادل نفت خام)	۴۹/۵۸۷۲ (۱۳۴۶)	۰۶۸/۴۰۰۰ (۱۳۹۰)
تولید ناخالص داخلی (میلیارد ریال)	۸۸۲۵۸/۳۵۱۵ (۱۳۴۶)	۵۵۸۶۳۰/۰۰۰ (۱۳۹۰)
جمعیت (میلیون نفر)	۲۶/۴۴۸۲ (۱۳۴۶)	۷۵/۱۴۹۷ (۱۳۹۰)
نرخ شهرنشینی (سهم)	۳۸/۷۴۰۰ (۱۳۴۶)	۷۱/۴۰۰۰ (۱۳۹۰)
ساختار اقتصادی (سهم)	۸/۹۴۰۶ (۱۳۴۶)	۲۷/۷۸۴۵ (۱۳۹۰)
ساختار انرژی (سهم)	۱/۴۶۰۲ (۱۳۴۶)	۵۳/۴۴۰۰ (۱۳۸۹)

منبع: وزارت نیرو، ترازنامه انرژی؛ بانک مرکزی، حساب‌های ملی؛ مرکز آمار ایران، سال‌نامه آماری

اکثر محققین نمونه‌های آموزش و تصدیق را با یکی از قاعده‌های ۹۰ درصد در برابر ۱۰ درصد، ۸۰ درصد در برابر ۲۰ درصد و یا ۷۰ درصد در برابر ۳۰ درصد، انتخاب نموده‌اند. البته انتخاب هر قاعده بستگی به نوع مسئله و محدودیت داده‌ها دارد. اما تحقیقات مختلف نشان داده است که هرچه تعداد نمونه‌های آموزشی افزایش یابد، عملکرد شبکه در زمینه پیش‌بینی، بهبود می‌یابد (ژانگ و همکاران<sup>۲</sup>، ۱۹۹۸). در این مطالعه نیز با توجه به محدودیت داده‌ها از ۸۰ درصد مشاهدات (۳۵ مشاهده) برای آموزش و ۲۰ درصد آن (۹ مشاهده) برای تصدیق استفاده شده است. تعداد نرون‌های لایه پنهان نیز به پیشنهاد هکت-نیلسن (۱۹۸۷)<sup>۳</sup>  $2n + 1$  در نظر گرفته شده است که در آن  $n$  تعداد گره‌ها در لایه ورودی می‌باشد. همچنین در لایه پنهان از توابع فعال‌سازی تانژانت‌هذلولی<sup>۴</sup> و زیگموئید<sup>۵</sup> استفاده شده است. پس از تعیین ساختار شبکه و مجموعه ورودی‌های آن، شبکه برای آموزش آماده

<sup>۱</sup> به منظور ایجاد شاخص‌های تصادفی جداسازی داده‌های آموزش و آزمون از تابع dividerand در نرم افزار متلب استفاده می‌شود.

<sup>۲</sup> Zhang et al.

<sup>۳</sup> Hecht-Nielsen

<sup>۴</sup> Hyperbolic Tangent (Tanh) :  $f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$

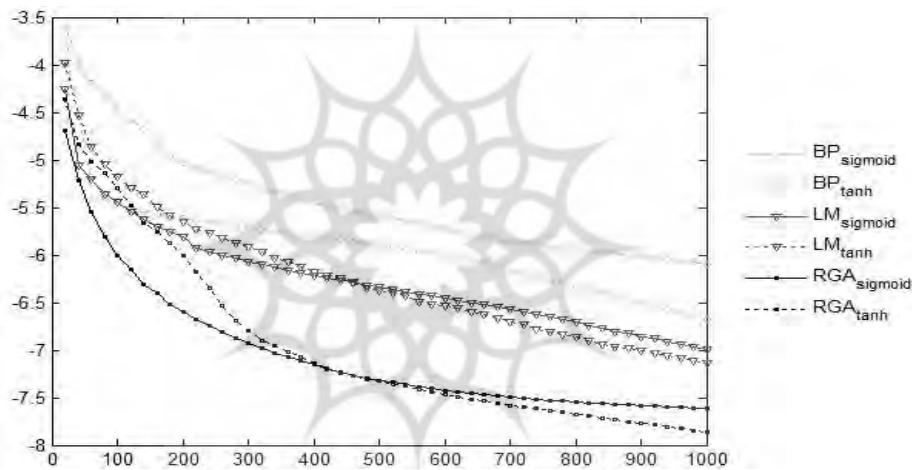
<sup>۵</sup> Sigmoid:  $f(x) = \frac{1}{1 + e^{-x}}$

می‌شود.<sup>۱</sup> پارامترهای الگوریتم ژنتیک و نیز تعداد جمعیت و حداکثر تکرار فرایند یادگیری به صورت جدول تعیین شد:

جدول (۳): تنظیم پارامترهای الگوریتم

تعداد جمعیت	نرخ جهش	نرخ تقاطع	حداکثر تکرار فرایند یادگیری
۳۰	۰/۰۵	۰/۸	۱۰۰۰

در فرایند آموزش شبکه به منظور بهینه‌سازی اوزان ارتباطی میان نرون‌ها از داده‌های آموزش و معیار میانگین مربع خطا<sup>۲</sup> (MSE) استفاده شده و سپس به منظور انتخاب بهترین شبکه از معیار حداقل خطا در داده‌های آزمون استفاده شد. نمودار و نمودار به ترتیب فرایند یادگیری شبکه بر اساس داده‌های آموزشی و داده‌های آزمون را برای کلیه شبکه‌ها نشان می‌دهند.<sup>۳</sup>




نمودار (۱): روند یادگیری شبکه با استفاده از الگوریتم‌های مختلف بر اساس داده‌های آموزشی

منبع: یافته‌های تحقیق

<sup>۱</sup> کلیه مراحل طراحی و آموزش شبکه‌های عصبی در محیط نرم افزار متلب انجام شده است.

<sup>۲</sup> Mean Squared Error:  $(MSE) = \frac{\sum_1^n (Y_i - \hat{Y}_i)^2}{n}$

<sup>۳</sup> در این نمودارها جهت رویت و مقایسه بهتر نتایج از تبدیل لگاریتمی استفاده شده است.



نمودار (۲): روند یادگیری شبکه با استفاده از الگوریتم‌های مختلف بر اساس داده‌های آزمون

منبع: یافته‌های تحقیق

همانگونه که نتایج نمودار نشان می‌دهد روند یادگیری شبکه براساس الگوریتم ژنتیک بسیار بهتر از الگوریتم‌های BP و LM بوده و در انتهای فرایند یادگیری خطای کمتری داشته است. از سوی دیگر نمودار که روند یادگیری بر اساس داده‌های آزمون را نشان می‌دهد نیز ضمن تأیید نتایج نمودار نشان می‌دهد که الگوریتم ژنتیک در یافتن نقاط حداقل خطای مربوط به داده‌های آزمون (نقطه توقف و اوزان ایده‌آل شبکه)، این خطا را بسیار کمتر از الگوریتم‌های BP و LM ارائه می‌کنند. مقایسه میان این دو الگوریتم نیز سرعت بیشتر، خطای کمتر و عملکرد بهتر الگوریتم LM را نشان می‌دهد و همچنین مقایسه روند یادگیری بر اساس توابع فعال‌سازی در هر الگوریتم، نشان دهنده عملکرد بهتر شبکه با تابع فعال‌سازی تانژانت هذلولی در مقایسه با تابع سیگموئید در لایه پنهان می‌باشد. پس از طراحی، آموزش و انتخاب بهترین شبکه عصبی بر اساس حداقل خطا در داده‌های آزمون، اکنون به بررسی کارایی و مقایسه آنها جهت انتخاب بهترین شبکه به منظور پیش‌بینی تقاضای انرژی می‌پردازیم. بدین منظور ابتدا لازم است تا همانگونه که در شکل نشان داده شده است عملیات پس‌پردازش<sup>۱</sup> بر روی خروجی هر شبکه اعمال شود تا خروجی آنها به داده‌هایی با مقیاس حقیقی برای مقایسه با مقادیر مصرف واقعی انرژی تبدیل شود. برای این منظور از رابطه (۱۱) استفاده شده است.

<sup>۱</sup> Post-processing



$$x_r = (x_n + 1) \times (x_{\max} - x_{\min}) / 2 + x_{\min} \quad (11)$$

به منظور بررسی عملکرد پیش‌بینی روش‌های گوناگون، تکنیک‌های مختلفی وجود دارد که متداول‌ترین آنها، میانگین مربع خطا، مجذور میانگین مربع خطا<sup>۱</sup> (RMSE)، میانگین قدرمطلق درصد خطا<sup>۲</sup> (MAPE) می‌باشند. به دلیل اینکه هر یک از معیارهای مذکور جنبه‌های خاصی از عملکرد مدل را نشان می‌دهند (صادقی و همکاران، ۱۳۹۱) در این مطالعه از کلیه معیارها برای ارزیابی قدرت پیش‌بینی هر تکنیک استفاده شده است. جدول ۴ و جدول ۵ نتیجه مقایسه کارایی بر اساس داده‌های آموزش و آزمون را نشان می‌دهد. نتایج این جداول بصورت ملموس‌تر و دقیق‌تری نمودار و نمودار را تشریح می‌کند. با دقت در نتایج این جداول به نظر می‌رسد بهبود نتایج کلیه الگوریتم‌های یادگیری هم بر اساس داده‌های آموزش و هم بر اساس داده‌های آزمون با استفاده از تابع فعال‌سازی تانزانت هذلولی در مقایسه با تابع فعال‌سازی سیگموئید قابل تأیید است.

جدول (۴): مقایسه کارایی شبکه‌های عصبی پیش‌بینی کننده تقاضای انرژی

تابع فعال‌سازی sigmoid			تابع فعال‌سازی tanh			شبکه عصبی
MSE	RMSE	MAPE	MSE	RMSE	MAPE	
۷۱۱/۶۸۸۱	۲۶/۶۷۷۵	۰/۰۲۲۶	۴۹۹/۸۶۴۴	۲۲/۳۵۷۶	۰/۰۱۸۱	BP-NN
۳۱۸/۶۵۱۶	۱۵/۳۷۵۵	۰/۰۱۴۴	۲۲۵/۸۹۱۲	۱۲/۷۸۹۶	۰/۰۱۲۰	LM-NN
۵۰/۲۷۷۸	۷/۰۹۰۷	۰/۰۰۵۸	۴۶/۱۵۸۴	۶/۷۹۴۰	۰/۰۰۵۲	RGA-NN

منبع: یافته‌های تحقیق

جدول (۵): مقایسه کارایی شبکه‌های عصبی پیش‌بینی کننده تقاضای انرژی

تابع فعال‌سازی sigmoid			تابع فعال‌سازی tanh			شبکه عصبی
MSE	RMSE	MAPE	MSE	RMSE	MAPE	
۹۹۷/۳۷۳۴	۳۱/۵۹۷۰	۰/۰۲۹۶	۶۲۸/۱۰۳۲	۲۵/۰۶۲۰	۰/۰۲۳۵	BP-NN
۳۲۴/۴۴۳۴	۸/۰۱۲۳	۰/۰۱۶۰	۱۵۱/۱۱۱۱	۱۲/۲۹۲۷	۰/۰۱۱۲	LM-NN
۴۶/۸۱۷۸	۶/۸۴۲۴	۰/۰۰۵۹	۴۳/۷۹۷۹	۶/۶۱۸۰	۰/۰۰۵۶	GA-NN


منبع: یافته‌های تحقیق

$$^1 \text{ Root Mean Square Error: } (RMSE) = \sqrt{\frac{\sum_1^n (\hat{Y}_t - Y_t)^2}{n}}$$

$$^2 \text{ Mean Absolute Percentage Error: } (MAPE) = \frac{\sum_1^n \left| \frac{\hat{Y}_t - Y_t}{Y_t} \right|}{n}$$

از سوی دیگر این نتایج ضمن تأیید عملکرد بهتر LM-NN در مقایسه با BP-NN، نشان-دهنده قدرت پیش‌بینی بالاتر شبکه‌های عصبی مبتنی بر الگوریتم ژنتیک در مقایسه با الگوریتم‌های پسانتشار خطا و لونیگ-مارکوارت می‌باشد. این نتایج نشان می‌دهد؛ حداقل خطای پیش‌بینی در داده‌های آموزش و آزمون به ترتیب برابر با ۰/۵۲ و ۰/۵۶ درصد در RGA-NN با تابع فعال‌سازی تانژانت هذلولی می‌باشد.

نمودار مقادیر واقعی و پیش‌بینی شده تقاضای انرژی بر اساس RGA-NN را نشان می‌دهد. همانگونه که مشاهده می‌شود در این نمودار نقاط پیش‌بینی تقریباً منطبق بر نقاط واقعی می‌باشد که این امر قدرت بسیار بالای الگوریتم پیشنهادی در پیش‌بینی‌های بلند مدت و در شرایط محدودیت داده‌های را نشان می‌دهد.



نمودار (۳): پیش‌بینی تقاضای انرژی بر اساس RGA-NN

منبع: یافته‌های تحقیق

## ۶- نتیجه‌گیری

استفاده از تکنیک‌های غیرخطی در مدل‌سازی و پیش‌بینی تقاضای انرژی با توجه به روند غیرخطی و پرنوسان آن و متغیرهای موثر بر آن اجتناب‌ناپذیر است. اخیراً الگوریتم ژنتیک و شبکه‌های عصبی به عنوان مهمترین تکنیک‌ها در مدل‌سازی فرایندهای غیرخطی و پیچیده مورد توجه محققین قرار گرفته است. این تکنیک‌ها علیرغم مزایای فراوان دارای نقاط ضعف نیز می‌باشند؛ تحمیل فرم تبعی خاص از سوی محقق در تکنیک الگوریتم ژنتیک و توقف یادگیری شبکه‌های عصبی در نقطه بهینه محلی از مهمترین نقاط ضعف این تکنیک‌ها بوده و در عوض جستجوی نقطه بهینه سراسری و عدم تحمیل فرم تبعی خاص به ترتیب از نقاط

قوت تکنیک‌های الگوریتم ژنتیک و شبکه‌های عصبی می‌باشد. از این رو در این مطالعه به منظور پیش‌بینی هرچه دقیق‌تر تقاضای انرژی الگوریتم ترکیبی این دو روش پرکاربرد معرفی و مورد استفاده قرار گرفته و نتایج آن با تکنیک‌های رایج مقایسه شده است. یافته‌ها ضمن تأیید نتایج مطلوب‌تر در صورت استفاده از تابع فعالسازی تانژانت هذلولی در لایه پنهان در کلیه شبکه‌های عصبی، نشان می‌دهد که تکنیک ترکیبی پیشنهادی نتایج بسیار بهتری داشته است. همچنین این نتایج قدرت پیش‌بینی بیشتر شبکه عصبی مبتنی بر الگوریتم لونیبرگ-مارکوارت (LM-NN) در مقایسه با شبکه عصبی مبتنی بر الگوریتم پس انتشار خطا (BP-NN) را تأیید کرده و نشان می‌دهند که شبکه عصبی مبتنی بر الگوریتم ژنتیک با کدینگ حقیقی (RGA-NN)، با حداقل خطای پیش‌بینی در داده‌های آموزش و آزمون - به ترتیب برابر با ۰/۵۲ و ۰/۵۶ درصد- مناسب‌ترین تکنیک جهت پیش‌بینی تقاضای بلند مدت انرژی در شرایط محدودیت داده‌ها می‌باشد. با توجه به تأیید قدرت توضیح دهنده‌گی متغیرهای توضیحی بکار رفته در این مطالعه و توصیف بهتر شرایط موثر بر تقاضای انرژی در ایران، استفاده از این متغیرها در مطالعات آتی جهت پیش‌بینی مطلوب‌تر تقاضای انرژی پیشنهاد می‌شود. با توجه به دقت پیش‌بینی بالاتر الگوریتم پیشنهادی این مطالعه، استفاده از این تکنیک در پیش‌بینی سایر متغیرهای اقتصادی بخصوص در شرایط محدودیت داده‌ها پیشنهاد دیگر این مطالعه است.

## فهرست منابع

۱. زاهدی‌وفا محمد هادی و توحید فیروزان سرنقی (۱۳۸۷)، بررسی اثر تجارت خارجی بر اشتغال و دستمزد نیروی کار بخش صنعت در ایران، پژوهشنامه اقتصادی، شماره ۳۱، صص ۶۹-۹۴.
۲. سهرابی‌وفا، حسین (۱۳۹۱)، پیش‌بینی تقاضای انرژی در ایران با استفاده از تکنیک‌های محاسبات نرم، پایان‌نامه کارشناسی ارشد، تهران، دانشگاه صنعت آب و برق (شهیدعباسپور).
۳. سهرابی‌وفا، حسین؛ صادقی، حسین؛ علی‌اکبر، افضلیان و حقانی، محمود (۱۳۹۱)، مقایسه کارایی الگوی ARIMA و شبکه عصبی GMDH در پیش‌بینی تقاضای بلندمدت برق، بیست‌وهفتمین کنفرانس بین‌المللی برق، ۲۲ تا ۲۴ آبان، تهران، پژوهشگاه نیرو.
۴. صادقی، حسین؛ افضلیان، علی‌اکبر؛ حقانی، محمود و سهرابی‌وفا، حسین (۱۳۹۱)، پیش‌بینی تقاضای بلندمدت انرژی الکتریکی با استفاده از الگوریتم ترکیبی عصبی فازی و انبوه ذرات، فصلنامه تحقیقات مدل‌سازی اقتصادی، ۱۰، ۲۱ تا ۵۶.
۵. صادقی، حسین؛ ذوالفقاری، مهدی؛ سهرابی‌وفا، حسین و سلمان‌ی، یونس (۱۳۹۱)، کاربرد الگوریتم انبوه ذرات و الگوریتم ژنتیک در شبیه‌سازی و پیش‌بینی تقاضای انرژی، نشریه انرژی ایران، ۱۵، ۴۵ تا ۶۰.
۶. فرجام‌نیا، ایمان؛ ناصری، محسن و احمدی، سیدمحمد مهدی (۱۳۸۶)، پیش‌بینی قیمت نفت با دو روش ARIMA و شبکه‌های عصبی مصنوعی، فصلنامه پژوهش‌های اقتصادی ایران، ۳۲، ۱۶۱ تا ۱۸۳.
۷. فضل‌زاده، علیرضا و تجویدی، مینا (۱۳۸۷)، مدیریت انرژی در صنایع ایران: مطالعه موردی: رابطه علی بین مقدار برق مصرفی و ارزش افزوده صنایع کوچک (۴۹-۱۰ نفر کارکن)، فصلنامه مطالعات اقتصاد انرژی، ۱۹، ۱۴۷ تا ۱۶۲.
۸. کرامت‌فر، مهدی (۱۳۹۱)، بررسی اثر افزایش قیمت حامل‌های انرژی بر عرضه صادرات صنعتی ایران، پایان‌نامه کارشناسی ارشد، تهران، دانشگاه صنعت آب و برق (شهیدعباسپور).
۹. منهای، محمد باقر (۱۳۸۴)، مبانی شبکه‌های عصبی، دانشگاه صنعتی امیرکبیر، تهران.

۱۰. مهناج، محمدباقر؛ کاظمی، عالییه؛ شکوری گنجوی، حامد؛ مهرگان، محمدرضا و تقی-زاده، محمد (۱۳۸۹)، پیش بینی تقاضای انرژی بخش حمل و نقل با استفاده از شبکه عصبی: مطالعه موردی در ایران، پژوهش‌های مدیریت در ایران، ۲، ۲۰۳-۲۲۰.

1. Amarawickrama, H. A. and L.C. Hunt (2007), Electricity Demand for Sri Lanka: A Time Series Analysis, Surrey Energy Economics Centre (SEEC), School of Economics Discussion Papers (SEEDS) 118.
2. Andonie R. (2010), Extreme Data Mining: Inference from Small Datasets, International Journal of Computers Communications & Control, 5: 280-291.
3. Ang, B.W. (1988), Electricity-output Relation and Sectoral Electricity Use, The case of East and South East Asian Developing Countries, Energy Policy, 16: 115-121.
4. ASSAREH, E., M. A. BEHRANG, M. R. ASSARI, and A. GHANBARZADEH (2010), Application of Pso (Particle Swarm Optimization) and Ga (Genetic Algorithm) Techniques on Demand Estimation of Oil in Iran, Energy, 35, 5223-5229.
5. Azadeh A, Saberi M, Gitiforouz A, and Z. Saberi (2009), A Hybrid Simulation-Adaptive Network Based Fuzzy Inference System for Improvement of Electricity Consumption Estimation, Expert Syst Appl, 36:11108-11117.
6. Azadeh, A., Ghaderi, S.F., and Sohrabkhani, S. (2007), Forecasting Electrical Consumption by Integration of Neural Network, Time Series and ANOVA, Applied Mathematics and Computation, 186: 1753-1761.
7. Barnes, D. and W. M. Floor (1996), Rural Energy in Developing Countries: A Challenge for Economic Development, Annual Review of Energy and Environment, 21: 497-530.
8. Bhattacharyya, S. C. and G.R. Timilsina (2009), Energy Demand Models for Policy Formulation, Policy ReseaRch WoRking, paper: 4866.
9. Bianco, V., Manca, O. and S. Nardini (2009), Electricity Consumption Forecasting in Italy Using Linear Regression Models, Energy, 34: 1413-1421.
10. Canyurt, O., Ceylan, H., Ozturk, H. and A. Hepbasli (2004), Energy Demand Estimation Based on Two-Different Genetic Algorithm Approaches, Energy Sources 26, 1313-1320.
11. Deb, K., and H.G, Beyer (2001), Self-adaptive Genetic Algorithms with Simulated Binary Crossover, Evol Comput, 9: 197-221.

12. Dilaver, Z. and Hunt, L. C. (2011), Turkish Aggregate Electricity Demand: An Outlook to 2020, Surrey Energy Economics Centre (SEEC), School of Economics Discussion Papers (SEEDS) 132.
13. Dunkerley, J., W. Ramsay, L. Gordon and E. Cecelski (1981), Energy Strategies for Developing Countries, Washington, DC: Resources for the Future.
14. Ferguson, R., Wilkinson, W. and R. Hill (2000), Electricity Use and Economic Development, *Energy Policy*, 28: 923–934.
15. Forouzanfar, M., Doustmohammadi, A., Hasanzadeh, S., and G.H. Shakouri (2012), Transport Energy Demand Forecast Using Multi-Level Genetic Programming, *Applied Energy*, 91: 496-503.
16. Geem, Z.W. (2011), Transport Energy Demand Modeling of South Korea Using Artificial Neural Network, *Energy Policy*, 39: 4644-4650.
17. Haldenbilen S, and H. Ceylan (2005), Genetic Algorithm Approach to Estimate Transport Energy Demand in Turkey, *Energy Policy*, 33: 89–98.
18. Haykin, S. (1999), *Neural Networks: A Comprehensive Foundation*, Prentice-Hall Inc., NJ.
19. Hecht-Nielsen, R. (1987), Kolmogorov's Mapping Neural Network Existence Theorem, In *IEEE First Annual International Conference on Neural Networks*, 3, pp. 11–13.
20. Hopfield, J.J. (1982), Neural Networks and Physical Systems with Emergent Collective Computational Abilities, In *Proceedings of the National Academy of Sciences*, pp. 2554-2558. National Academy of Sciences.
21. Hornik, K. (1991), Approximation Capabilities of Multilayer Feedforward Networks, *Neural Networks*, 4: 251-257.
22. Huang, C., and C. Moraga (2004), A Diffusion-Neural-Network for Learning from Small Samples, *International Journal of Approximate Reasoning*, 35: 137-161.
23. Kialashaki, A., and J.R Reisel (2013), Modeling of the Energy Demand of the residential sector in the United States using regression models and Artificial Neural Networks, *Applied Energy*, 108: 271-280
24. Kuan, C.M., and H. White (1994), Artificial Neural Networks: An Econometric Perspective, *Econometric Reviews*, 13: 1-91.
25. Li, D.C., C.W. Liu (2009), A Neural Network Weight Determination Model Designed Uniquely for Small Data Set Learning, *Expert Systems with Applications*, 36: 9853-9858.

26. Lin, B. Q. (2003), Electricity Demand in the People's Republic of China, ERD Working Paper Series, No.37, Economics and Research Department.
27. Massarrat, M. (2004), Iran's Energy Policy Current Dilemmas and Perspective for a Sustainable Energy Policy, International Journal of Environmental Science & Technology, 1: 233-245.
28. McClelland, J.L., Rumelhart, D.E., and G.E. Hinton (1986), The Appeal of Parallel Distributed Processing, in Parallel Distributed Processing: Explorations in the Microstructure of Cognition - Foundations, 1, MIT Press, Cambridge, pp.3-44.
29. McCulloch WS and W. Pitts (1943), A Logic Calculus of the Ideas Immanent in Nervous Activity, Bull of Math Biophys, 5: 115-133.
30. Mohamed, Z. and P. Bodger (2005), Forecasting Electricity Consumption in New Zealand Using Economic and Demographic Variables, Energy, 30: 1833-1843.
31. Murat, Y.S., and H. Ceylan (2006), Use of Artificial Neural Networks for Transport Energy Demand Modeling, Energy Policy, 34: 3165-3172.
32. Pao, H.T. (2009), Forecasting Energy Consumption in Taiwan Using Hybrid Nonlinear Models, Energy, 34: 1438-1446.
33. Rechenberg I (1965), Cybernetic Solution Paths of an Experimental Problem, Technical Report, Royal Aircraft Establishment, Farnborough, Library Translation 1122.
34. Rongfu Mao Haichao, Z., Linke, Z., and C. Aizhi (2006), A New Method to Assist Small Data Set Neural Network Learning, In: Intelligent Systems Design and Applications, ISDA. Sixth International Conference on, pp. 17-22.
35. Rosenberg, N. (1998), The Role of Electricity in Industrial Development, The Energy Journal, 19: 7-24.
36. Rosenblatt, F. (1958), The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain, Psychological Review, 65: 386-408.
37. SOZEN, A., and E. Arcakoglu (2007), Prospects for Future Projections of the Basic Energy Sources in Turkey, Energy Sources, Part B: Economics, Planning, and Policy, 2, 183-201.
38. Stender, J. (1993), Parallel Genetic Algorithms. Ios Press Inc.
39. Tsai, T.I. and D.C. Li (2008), Approximate Modeling for High Order Non-Linear Functions Using Small Sample Sets, Expert Systems with Applications, 34: 564-569.

40. Yu, S., Wei, Y.M., and K. Wang (2012a), A PSO-GA Optimal Model to Estimate Primary Energy Demand of China, Energy Policy, 42: 329-340.
41. Yu, S., Zhu, K., and X. Zhang (2012b), Energy Demand Projection of China Using a Path-Coefficient Analysis and PSO-GA Approach, Energy Conversion and Management, 53: 142-153.
42. Zhang, G., Patuwo, B.E., and M.Y. Hu (1998), Forecasting with Artificial Neural Network: The State of Art, International Journal of Forecasting, 14: 35-62.

