

# پیش‌بینی تقاضای انرژی با استفاده از شبکه عصبی مبتنی بر الگوریتم انبوه ذرات

حسین سهرابی وفا<sup>۱</sup>، فاطمه نوری<sup>۲</sup>، مرتضی عبادی<sup>۳</sup>

تاریخ دریافت مقاله:

۱۳۹۲/۰۳/۱۹

تاریخ پذیرش مقاله:

۱۳۹۲/۰۶/۰۳

چکیده:

انرژی نقش اساسی در فرایند تولید و رفاه اجتماعی داشته و پیش‌بینی تقاضای آن به منظور تنظیم بازار و عرضه مطمئن آن امری ضروری می‌باشد. با توجه به روند پرنوسان و غیرخطی تقاضای انرژی و متغیرهای موثر بر آن، مدل‌های غیرخطی بخصوص شبکه‌های عصبی و الگوریتم انبوه ذرات در این امر توفیق بیشتری داشته‌اند. با توجه به اینکه در کنار نقاط قوت فراوان، این تکنیک‌ها دارای نقاط ضعفی مانند نیاز به تعیین فرم تبعی خاص، نیاز به داده‌های آموزشی فراوان و ضعف در یافتن نقطه بهینه سراسری نیز می‌باشند، در این مطالعه با ادغام آنان به صورت یک الگوریتم ترکیبی این نقایص مرتفع شده است. پس از بکارگیری و مقایسه این تکنیک ترکیبی با سایر روش‌ها در پیش‌بینی تقاضای انرژی طی سال‌های ۱۳۴۶ تا ۱۳۹۰، نتایج مطالعه قدرت پیش‌بینی بالاتر تکنیک ترکیبی در کنار قدرت توضیح‌دهندگی متغیرهای توضیحی بکار رفته را تائید می‌کند.

کلمات کلیدی:

الگوریتم انبوه‌ذرات، پیش‌بینی، تقاضای انرژی، شبکه عصبی

SohrabiVafa@gmail.com  
Nfatemeh67@yahoo.com  
Morteza.Ebadi@ut.ac.ir

۱) کارشناس ارشد اقتصاد انرژی دانشگاه صنعت آب و برق (نویسنده مسئول)  
۲) کارشناس ارشد اقتصاد دانشگاه مفید قم  
۳) کارشناس ارشد اقتصاد دانشگاه تهران

## مقدمه

در مطالعات متعددی رابطه شاخص مصرف انرژی سطح فعالیت‌های اقتصادی به اثبات رسیده است. از سوی دیگر، انرژی به عنوان یک کالای مصرفی نیز در بخش‌های مختلف اقتصادی از جمله بخش خانگی استفاده شده و ارتباط مستقیمی با رفاه اجتماعی دارد. از این رو، مدل‌سازی و پیش‌بینی تقاضای انرژی جهت اتخاذ سیاست‌های اقتصادی مناسب و برنامه‌ریزی صحیح تولید و بهره‌برداری انرژی امری ضروری می‌باشد. در این خصوص، برنامه‌ریزی انرژی بدون دانش کافی از روند گذشته، کنونی و همچنین روند آتی مصرف انرژی غیرممکن است [56]. بنابراین، بهتر است که تخمین‌های انرژی با دقت مطلوب و قابلیت اعتماد بالایی انجام تا از اشتباهات هزینه‌بر اجتناب شود. تخمین تقاضای انرژی بر اساس شاخص‌های اقتصادی - اجتماعی ممکن است به شکل الگوهای ریاضی مختلفی انجام گیرد که می‌توانند به صورت خطی یا غیرخطی باشند [50]. به دلیل روند غیرخطی و پرنوسان تقاضای انرژی و متغیرهای اثرگذار بر آن، توابع ریاضی غیرخطی می‌توانند تقاضای انرژی را بهتر برآورد کنند که این امر منجر به جستجوی راه‌حلی با رویکردهای هوشمند مانند الگوریتم بهینه‌یابی انبوه ذرات (PSO) و شبکه‌های عصبی مصنوعی (ANN) شده است که البته هر یک دارای مزایا و معایب خاص خود می‌باشند. در استفاده از الگوریتم انبوه ذرات به دلیل تحمیل فرم تبعی خاص به صورت خطی، درجه دوم، نمایی<sup>۳</sup> و یا هر فرم تبعی دیگر، امکان عدم شناسایی روابط پیچیده غیرخطی وجود دارد [24]. شبکه‌های عصبی مصنوعی نیز ضمن عدم نیاز به تعیین فرم تبعی خاص، خود دارای معایب دیگری می‌باشند. نبود یک روش استقرایی جامع در انتخاب الگوریتم یادگیری شبکه، توقف الگوریتم در حداقل محلی<sup>۴</sup> و همچنین نیاز به منبع غنی داده‌ها برای یادگیری شبکه از نقایص این تکنیک‌ها به شمار می‌رود. در این مطالعه، با توجه به روند غیرخطی و محدودیت داده‌ها، برای نخستین بار تکنیک ترکیبی الگوریتم انبوه ذرات و شبکه عصبی چندلایه پرسپترون (MLP)<sup>۵</sup> جهت پیش‌بینی تقاضای بلند مدت انرژی ارائه شده است. دوره زمانی این مطالعه، سال‌های ۱۳۴۶ تا ۱۳۹۰ می‌باشد. جنبه‌های نوآوری این مطالعه علاوه بر معرفی یک الگوریتم ترکیبی به منظور پیش‌بینی هرچه دقیق‌تر تقاضای انرژی در شرایط محدودیت داده‌ها، استفاده از متغیرهای توضیحی متفاوت نیز می‌باشد. متغیرهای توضیحی استفاده شده در این مطالعه، تولید ناخالص داخلی، جمعیت، نرخ شهرنشینی، ساختار اقتصادی و ساختار انرژی در ایران است که علت استفاده هر یک در ادامه بحث می‌شود.

بخش دوم این مقاله به پیشینه تحقیق می‌پردازد. مبانی نظری الگوریتم انبوه ذرات 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، نتایج مطالعه در بخش هفتم ارائه می‌شود.

- 1) Particle Swarm Optimization (PSO)
- 2) Artificial Neural Network(ANN)
- 3) Linear, Quadratic, Exponential
- 4) Local minimum
- 5) Multi-Layer Perceptron (MLP)

## پیشینه تحقیق

حامل‌های مختلف انرژی به عنوان نیروی محرکه فعالیت‌های گوناگون اقتصادی نقش مهمی در فرایند رشد و توسعه اقتصادی و تامین رفاه اجتماعی در کشورهای توسعه یافته و در حال توسعه داشته‌اند [57]. همچنین نرخ رشد مصرف انرژی یکی از شاخص‌های توسعه تلقی شده و از سوی دیگر، در نظریات رشد اقتصادی اخیر انرژی نیز به عنوان یکی از عوامل تولیدی مهم و موثر بر رشد محسوب می‌شود و در کشورهای در حال توسعه از جایگاه ویژه‌ای برخوردار است [31]. از سال ۱۹۷۰ که انرژی توجه سیاستگذاران را در اثر اولین بحران نفتی به خود جلب کرد، مطالعه و تحقیق بر روی تقاضای انرژی به منظور غلبه بر دانش محدود درباره طبیعت تقاضای انرژی و واکنش آن در مواجهه با شوک‌های خارجی، به طور وسیعی افزایش یافت [52]. از آن زمان، بحث پویا و زنده میان مهندسی و اقتصاددانان فعال در زمینه انرژی منجر به تحولات مهمی در روش‌هایی برای غنی‌تر شدن فرایند تصمیم‌گیری انرژی به عنوان یک مجموعه کل گردید و طیف گسترده‌ای از مدل‌ها برای تحلیل و پیش‌بینی تقاضای انرژی ابداع و در دسترس محققین قرار گرفت [60]. پیش‌بینی تقاضای انرژی برای برنامه‌ریزی انرژی، تنظیم راهبرد و تعریف و توصیه سیاست‌های انرژی نه تنها برای کشورهای در حال توسعه (که با چالش داده‌های مورد نیاز و نهادهای لازم و مدل‌های مقتضی روبرو هستند) ضروری است، بلکه برای کشورهای توسعه یافته (که این محدودیت‌ها در آنها کمتر است) نیز یک مولفه اساسی به شمار می‌رود [27]. لذا در سال‌های اخیر، مطالعات فراوانی در زمینه پیش‌بینی تقاضای انرژی با استفاده از تکنیک‌های نوین محاسباتی در جهت غلبه بر مسائل مرتبط با روند غیرخطی و پرنوسان تقاضای انرژی و متغیرهای توضیحی آن انجام شده که در ادامه و در جداول (۱) و (۲) به ترتیب خلاصه‌ای از مطالعات داخلی و خارجی در این زمینه مرور شده است.

جدول (۱) مطالعات داخلی در زمینه پیش‌بینی تقاضای انرژی

متغیر هدف (کشور)	متغیر توضیحی	تکنیک	[مرجع] (سال)
انرژی الکتریکی	تولید ناخالص داخلی، قیمت، جمعیت، تعداد مشترکین	شبکه‌های عصبی	[۶] (۱۳۸۳)
انرژی بخش‌های صنعت، کشاورزی، خدمات، حمل و نقل	نرخ رشد، سهم تولید از تولید ناخالص داخلی و شدت مصرف انرژی هر بخش	تجزیه	[۵] (۱۳۸۴)
انرژی بخش حمل و نقل زمینی	تولید ناخالص داخلی، جمعیت، تعداد خودروها، مسافت طی شده	الگوریتم ژنتیک	[۱۴] (۱۳۸۷)
بنزین بخش حمل و نقل	تولید ناخالص داخلی، قیمت بنزین، جمعیت، تعداد خودروهای بنزین سوز، عمر متوسط خودرو، راندمان مصرف	الگوریتم ژنتیک	[۱۰] (۱۳۸۸)
حامل‌های انرژی بخش کشاورزی	سری زمانی	ARIMA <sup>۱</sup> و ARCH <sup>۱</sup>	[۱۸] (۱۳۸۹)
انرژی بخش‌های صنعت، خانگی، کشاورزی، خدمات، حمل و نقل	سری زمانی	ARIMA	[۱] (۱۳۹۰)
انرژی الکتریکی	سری زمانی	شبکه عصبی GMDH <sup>۳</sup> و ARIMA	[۹] (۱۳۹۱)

[ ]:

- 1) Autoregressive Integrated Moving Average
- 2) Autoregressive Conditional Heteroskedasticity
- 3) Group Method of Data Handling

جدول ۲) مطالعات خارجی در زمینه پیش‌بینی تقاضای انرژی

نویسنده (سال)	تکنیک	متغیر هدف (کشور)	متغیر توضیحی
[29] (۲۰۰۴)	الگوریتم ژنتیک	انرژی (ترکیه)	درآمد ملی، جمعیت، صادرات، واردات
[35] (۲۰۰۵)	الگوریتم ژنتیک	انرژی حمل و نقل (ترکیه)	درآمد ملی، جمعیت، تعداد خودروها
[49] (۲۰۰۶)	شبکه عصبی	انرژی حمل و نقل (ترکیه)	درآمد ملی، جمعیت، تعداد خودروها
[25] (۲۰۰۷)	شبکه عصبی	انرژی الکتریکی (ایران)	سری زمانی
[59] (۲۰۰۸)	الگوریتم انبوه ذرات	انرژی (ترکیه)	درآمد ملی، جمعیت، صادرات، واردات
[51] (۲۰۰۹)	شبکه عصبی	انرژی (تایوان)	سری زمانی
[23] (۲۰۱۰)	الگوریتم ژنتیک و الگوریتم انبوه ذرات	فراورده‌های نفتی (ایران)	تولید ناخالص داخلی، جمعیت، صادرات، واردات
[34] (۲۰۱۱)	رگرسیون معمولی، شبکه عصبی	انرژی بخش حمل و نقل (کره جنوبی)	متغیرهای تولید ناخالص داخلی، جمعیت، قیمت سوخت، تعداد خودروها، میزان حمل و نقل
[33] (۲۰۱۲)	برنامه‌ریزی ژنتیک	انرژی بخش حمل و نقل (کره جنوبی)	تولید ناخالص داخلی، جمعیت، تعداد خودروها
[41] (۲۰۱۳)	رگرسیون معمولی، شبکه عصبی	انرژی بخش خانگی (امریکا)	اندازه خانه، تعداد ساکنین، بهره‌وری از تجهیزات گرمایشی، شدت انرژی


منبع: [۸]

به طور کلی، از نتایج مطالعات مورد بررسی می‌توان دریافت که الگوهایی که بر پایه مدل‌های غیرخطی و بخصوص شبکه‌های عصبی (NN) بنا شده‌اند، نتایج مطلوب‌تری نسبت به الگوهای خطی داشته‌اند. همچنین بررسی مطالعات انجام شده توانایی الگوریتم‌های هوشمند و شبکه‌های عصبی در پیش‌بینی تقاضای بلندمدت انرژی را نیز تأیید می‌نماید که در مطالعات داخلی می‌توان به مراجع [۶، ۹، ۱۰، ۱۴] و در مطالعات خارجی به مراجع [23, 29, 33, 34, 35, 41, 49, 59] اشاره کرد.

از سوی دیگر، انتخاب الگوریتم یادگیری و توقف الگوریتم در نقطه بهینه محلی و همچنین نیاز به نمونه‌های آموزشی فراوان از جمله محدودیت‌های پیش‌روی شبکه‌های عصبی می‌باشد. از این رو، در این مطالعه برای نخستین بار در ادبیات مربوط به پیش‌بینی تقاضای انرژی از تکنیک ترکیبی شبکه عصبی و الگوریتم انبوه ذرات استفاده شده است. عدم نیاز به فرم تبعی خاص شبکه‌های عصبی و جستجوی نقاط بهینه سراسری الگوریتم انبوه ذرات در یادگیری شبکه با داده‌های محدود، از مهمترین نقاط قوت این تکنیک خواهد بود. تمایز و نوآوری مطالعه حاضر با مطالعات صورت گرفته در زمینه تقاضای انرژی، استفاده از تکنیک ترکیبی شبکه عصبی و الگوریتم انبوه ذرات در پیش‌بینی تقاضای انرژی و همچنین استفاده از متغیرهایی متفاوت با سایر مطالعات و سازگار با شرایط کشور در جهت بهبود قدرت پیش‌بینی مدل، وجه تمایز این مطالعه خواهد بود.

## مبانی نظری شبکه‌های عصبی و الگوریتم انبوه ذرات

پس از شناخت توانایی سلول‌های عصبی در مغز انسان، مفهوم شبکه‌های عصبی مصنوعی در سال ۱۹۴۳ توسط مک‌کلاک (عصب‌شناس) و پیت<sup>۱</sup> (ریاضیدان) مطرح شد [47] و بعدها به طور گسترده‌ای مورد اقبال عمومی پژوهشگران در مدل‌سازی تجربی فرایندهای غیرخطی قرار گرفت [36]. اولین شبکه عصبی مصنوعی را روزنبلات<sup>۲</sup> در سال ۱۹۵۸ به نام پرسپترون<sup>۳</sup> طراحی و به کار گرفت [55]. پس از آنکه در سال ۱۹۸۲ هاپفیلد<sup>۴</sup> با طراحی شبکه عصبی به همین نام (هاپفیلد) توانست یکی از پیچیده‌ترین مسائل بهینه‌سازی موسوم به فروشنده دوره‌گرد ( $TSP^5$ ) را حل کند، قدرت شبکه‌های عصبی در مدل‌سازی مسائل غیرخطی مورد توجه قرار گرفت [37] و بعدها راملهارت و مک‌کلند<sup>۶</sup> در سال ۱۹۸۶ با ارائه الگوریتم پس انتشار خطا ( $BP^7$ ) منجر به توسعه هرچه بیشتر شبکه‌های عصبی چند لایه پیشخور<sup>۸</sup> با نام پرسپترون چندلایه ( $MLP$ ) شدند [46]. یک شبکه عصبی پیشخور سه لایه که در شکل ۱ نشان داده شده است، به عنوان ساختار پایه برای شبکه عصبی مورد استفاده در این مطالعه در نظر گرفته شده است.



شکل ۱) ساختار شبکه عصبی پیشخور سه لایه

- 1) W.S McCulloch and W. Pitts
- 2) F. Rosenblatt
- 3) Perceptron
- 4) J.J. Hopfield
- 5) Traveling Salesman Problem (TSP)
- 6) J.L McClelland and D.E. Rumelhart
- 7) Back Propagation (BP)
- 8) Feed Forward Neural Network

پیش‌تر در مطالعات مختلف اشاره شده است که چنین ساختار شبکه ساده‌ای دارای قابلیت بسیار بالایی در نگاشت میان ورودی و خروجی بوده و قادر به تخمین هر تابع پیوسته غیرخطی با دقت مطلوب در صورت استفاده از نرون‌های کافی در لایه پنهان می‌باشد [38]. 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  $k$  و  $y(k)$  متغیر هدف،  $w_j$  ضریب وزن‌دهی به نرون پنهان  $j$  ام به لایه آخر،  $w_0$  بایاس لایه خروجی،  $w_{j0}$  بایاس لایه ورودی،  $w_{ij}$  ضرایب وزن‌دهی میان نرون  $j$  ام لایه پنهان و ورودی  $i$  ام و  $f_j$  نیز تابع فعال‌سازی غیرخطی نرون  $j$  ام لایه پنهان می‌باشد. تابع هدف برای آموزش چنین شبکه‌ای به صورت 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،  $M$  تعداد مشاهدات در زمان‌های مختلف،  $y_k^{real}$  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 (BP) مهمترین و پرکاربردترین تکنیک بهینه‌یابی در آموزش شبکه‌های عصبی محسوب می‌شود. این الگوریتم در سال ۱۹۸۶ توسط راملهارت و مک‌لند مطرح شد [۱۶]. 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 (تصدیق) به منظور بررسی میزان جامعیت شبکه و انتخاب بهترین شبکه آموزش دیده استفاده می‌شود [۱۷]. الگوریتم پس‌انتشار خطا را می‌توان تعمیم یافته قانون دلتا نامید. روابط (۳) تا (۵) نحوه محاسبه وزن‌های شبکه بر اساس این قانون را نشان می‌دهد.

$$e_k = y_k^{real} - y_k^{predict} \quad (3)$$

$$\Delta w_t = \eta e_k p_{kj} \quad (4)$$

$$w_{t+1} = w_t + \Delta w_t \quad (5)$$

در روابط فوق،  $\eta$ ،  $e_k$ ،  $w$  و  $p_{kj}$  به ترتیب نشان دهنده نرخ یادگیری<sup>۱</sup>، خطای مشاهده شده و وزن مربوطه 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 [36].

پس از معرفی الگوریتم پس انتشار خطا، الگوریتم لوبنرگ-مارکواریت<sup>۳</sup> ( $LM$ ) با سرعت همگرایی بیشتر در بهینه‌یابی اوزان شبکه عصبی ارائه شد که قاعده یادگیری آن به صورت 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.

الگوریتم انبوه ذرات که در سال ۱۹۹۵ از سوی ابرهارت و کندی<sup>۵</sup> ارائه شد، یک پارادایم محاسباتی بر اساس ایده‌ای است که از رفتار مشترک و حرکت گله‌ای جمعیت بیولوژیک با الهام از رفتار اجتماعی پرندگان مهاجم یا تجمع ماهیان ارائه شده است [40]. به بیان دیگر، این تکنیک یک الگوریتم تکاملی<sup>۶</sup> جهت بهینه‌سازی توابع غیرخطی است که بر مبنای تشبیهی از فعل و انفعال اجتماعی همچون رفتار کلاغ‌ها ارائه شده است. در حرکت یک دسته از کلاغ‌ها، یک کلاغ (سرگروه) دارای بهترین موقعیت می‌باشد و بقیه کلاغ‌ها با توجه به موقعیت خود و کلاغ‌های مجاور سعی در بهتر کردن مکان و نزدیک شدن به سرگروه را دارند. در این حین، چنانچه یکی از اعضا بتواند موقعیت بهتری نسبت به سرگروه پیدا کند، او به عنوان سرگروه انتخاب می‌شود که عملکرد الگوریتم انبوه ذرات نیز به این گونه است [۱۱]. الگوریتم انبوه ذرات یک فرآیند ساده است، اجرای آن آسان است، در کنترل پارامترها قوی عمل می‌کند و از نظر محاسباتی کارایی آن در مقایسه با سایر الگوریتم‌های ابتکاری<sup>۷</sup> در مسائل بهینه‌یابی مختلف به اثبات رسیده است [1].

زمانی که الگوریتم انبوه ذرات به منظور حل یک مسئله بهینه‌یابی به کار می‌رود. جمعیتی از ذرات جهت اکتشاف فضای پاسخ مسئله به منظور دستیابی به یک پاسخ بهینه به کار گرفته می‌شوند. هر ذره یک پاسخ احتمالی فضای مسئله را ارائه می‌دهد که با مختصات معینی در فضای  $D$  بعدی شناخته می‌شود. موقعیت ذره  $i$  ام

- 1) Learning Rate
- 2) Gradient Descent
- 3) Levenberg-Marquardt
- 4) Jacobian Matrix
- 5) J. Kennedy and R. Eberhart
- 6) Evolutionary process
- 7) Heuristic

با  $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$  نشان داده می‌شود. سرعت ذره نیز توسط  $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$  نشان داده می‌شود. تابع برازندگی برای هر ذره در جمعیت اندازه‌گیری شده و با اندازه بهترین نتیجه قبلی همان ذره و بهترین ذره در میان کل جمعیت مقایسه می‌شود. پس از یافتن این دو مقدار بهینه، ذره با بروز رسانی سرعت و موقعیتش بر اساس توابع زیر حرکت می‌کند:

$$V_i^{t+1} = \omega \times V_i^t + c_1 \times rand_1 \times (p_{i\_best} - X_i^t) + c_2 \times rand_2 \times (g_{best} - X_i^t) \quad (7)$$

$$X_i^{t+1} = X_i^t + V_i^{t+1} \quad (8)$$

به صورتی  $i = (1, 2, \dots, Npop)$  که در آن  $Npop$  نشان دهنده اندازه جمعیت و  $p_{i\_best}$  نیز بهترین پاسخ یافت شده توسط ذره  $i$  ام و  $g_{best}$  نیز بهترین پاسخ در کل گروه می‌باشد.  $C_1$  و  $C_2$  نیز پارامترهای شناختی و اجتماعی<sup>۱</sup> می‌باشند که مقدار آنها در بازه  $[0, 2]$  قابل انتخاب است. توابع  $rand_1$  و  $rand_2$  نیز تولید کننده دو عدد تصادفی با احتمال یکنواخت در بازه  $[0, 1]$  می‌باشند. تغییرات  $V_i^{t+1}$  نیز در بازه  $[-V_{max}, V_{max}]$  متغیر خواهد بود که در آن حداکثر سرعت مجاز برای ذرات می‌باشد. ضریب اینترسی  $\omega$  نیز جهت کنترل تعادل جستجوی الگوریتم میان اکتشاف و استخراج<sup>۲</sup> استفاده می‌شود. در این الگوریتم، مراحل بازگشتی<sup>۳</sup> تا زمانی که شرایط توقف حاصل شود ادامه خواهد داشت.

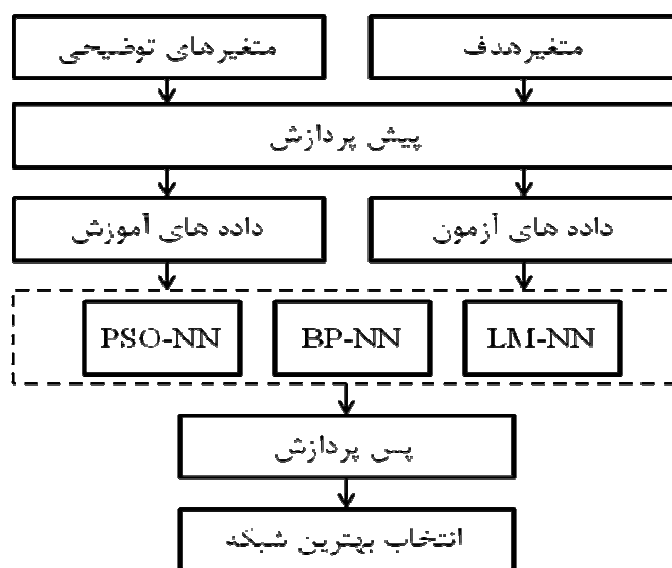
### تکنیک ترکیبی شبکه عصبی و الگوریتم انبوه ذرات

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، کارایی بالایی نداشته که این نقص کاربردهای شبکه‌ی عصبی را بشدت محدود می‌کند [21]. تکنیک‌های هوشمند متنوعی جهت فائق آمدن بر مسئله محدودیت داده‌های آموزش ارائه شده است. ایجاد نمونه‌های آموزشی هوشمند<sup>۴</sup>، انتخاب ویژگی<sup>۵</sup>، تنظیم مناسب پارامترهای مدل استنباطی<sup>۶</sup> و دسته‌بندی گروهی داده‌ها<sup>۷</sup> از جمله تکنیک‌های پیشنهادی بوده است که مطالعات مختلف از جمله مطالعات [9, 39, 43, 53] هر یک با رویکردی خاص سعی در حل مسئله محدودیت داده‌ها داشته‌اند. ولی هر یک از تکنیک‌های پیشنهادی در این زمینه دارای نقاط

- 1) Cognitive and Social Parameters
- 2) Exploration and Exploitation
- 3) Recursive
- 4) Generate Artificial Training Samples
- 5) Feature Selection
- 6) Parameter Fine-Tuning of the Inferred Model
- 7) Group Method of Data Handling



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 پیش‌روی این تکنیک‌ها بوده است. از این رو در این مطالعه به منظور غلبه بر مسائل فوق، به کمک الگوریتم انبوه ذرات به آموزش شبکه عصبی پرداخته و سپس کارایی آنان با تکنیک‌های رایج مقایسه شده و بهترین روش در پیش‌بینی تقاضای بلند مدت انرژی معرفی می‌شود. مراحل اجرای این الگوریتم ترکیبی در شکل ۲ نشان داده شده است.



شکل ۲) نمودار جریان الگوریتم ترکیبی پیش‌بینی کننده تقاضای انرژی

در شکل ۲، نمادهای  $PSO-NN$ ،  $BP-NN$  و  $LM-NN$  به ترتیب نشان دهنده شبکه‌های عصبی مبتنی بر الگوریتم انبوه ذرات، الگوریتم پس انتشار خطا و الگوریتم لونیگ مارکوارت می‌باشد.

### بررسی مدل

در ابتدا، بررسی متغیرهای موثر بر تقاضای انرژی ضروری به نظر می‌رسد. رشد بالای جمعیت محرک مصرف انرژی می‌باشد [62]. در مطالعات مختلف از جمعیت به عنوان متغیر توضیحی در مدل‌سازی تقاضای انرژی استفاده شده است که از جمله آنها می‌توان به [23, 28, 48] 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 [61, 62]. 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 نظریه‌های اقتصادی، افزایش درآمد منجر به افزایش قدرت خرید مصرف‌کنندگان شده و افزایش قدرت خرید منجر به افزایش مصرف کالاهای ضروری خواهد شد. روزنبرگ<sup>۱</sup> (۱۹۹۸) بیان می‌کند که شواهدی قوی برای اثرگذاری فرایند توسعه اقتصادی بر مصرف انرژی مشاهده می‌شود. فرگوسن و همکاران<sup>۲</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 [22, 44, 20, 30] اشاره کرد.

همچنین ساختار اقتصاد نیز یکی از عوامل موثر بر مصرف انرژی می‌باشد. منابع غنی نفت و گاز ایران و اجرای سیاست‌های عرضه سوخت ارزان به صنایع منجر به کاهش کارایی انرژی و افزایش شدت انرژی در فعالیت‌های اقتصادی بخصوص 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 است [۱۳]. زاهدی‌وفا (۱۳۸۷) در مرجع [۷] 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 [۱۵].

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 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، چرا که کشور علاوه بر دارا بودن منابع عظیم نفتی دارای رتبه دوم ذخایر گازی در جهان نیز هست [45]. 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

1) N. Rosenberg [54]

2) R. Ferguson *et al* [32]

نخستین بار در تاریخ ایران بیشتر از فرآورده‌های نفتی شده است [45]. با توجه به آنچه ذکر شد، سهم گاز طبیعی از کل مصرف انرژی به عنوان منعکس کننده ساختار انرژی نیز بر روند مصرف انرژی موثر خواهد بود.

با توجه به مطالب فوق و مطالعات تجربی در این مطالعه، 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،  $ENstr$  و  $ECstr, Urb, Pop, Gdp$  به ترتیب نشان دهنده تولید ناخالص داخلی به قیمت ثابت سال ۱۳۷۶ (هزار میلیارد 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) می‌باشند که اطلاعات آنان از ترازنامه انرژی [۴] و اطلاعات سری زمانی بانک مرکزی [۲] استخراج شده است.

### 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 شدت در نوسان می‌باشند، لذا استفاده از الگوهای هوشمند غیرخطی در مدل‌سازی تقاضای انرژی اجتناب‌ناپذیر است. شبکه‌های عصبی 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 [42]. 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>۲</sup>

(۱) داده‌های جمعیت سال‌های ۱۳۸۸، ۱۳۸۹ و ۱۳۹۰ از سالنامه‌های آماری مرکز آمار ایران استخراج شده است [۳].  
(۲) به منظور نرمال‌سازی از تابع  $mapminmax$  در نرم افزار متلب استفاده می‌شود.

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

در رابطه (۱۰)،  $x_r$ ،  $x_n$ ،  $x_{\max}$  و  $x_{\min}$  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 ۳ نشان داده شده است.

جدول ۳) 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)	۱۰۶۸/۴۰۰۰ (۱۳۹۰)
تولید ناخالص داخلی (میلیارد ریال)	۸۸۲۵۸/۳۵۱۵ (۱۳۴۶)	۵۵۸۶۳۰/۰۰۰۰ (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: یافته‌های تحقیق

پس از مرحله نرمال‌سازی، تصادفی نمودن<sup>۱</sup> داده‌ها انجام می‌شود. نتیجه انجام این مرحله، داشتن مجموعه‌ای از ورودی و خروجی‌هاست که در آن، دسته‌های ورودی - خروجی دارای نظام خاص نیستند. پس از پایان تصادفی نمودن داده‌ها، میزان اطلاعاتی که باید در فرایند آموزش شبکه استفاده شود، مشخص می‌شود [۱۲]. بر این اساس، بخشی از داده‌ها برای آموزش و بخشی دیگر برای آزمون شبکه در نظر گرفته می‌شود<sup>۲</sup>.

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 [63]. 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. به منظور تعیین تعداد نرون‌های مورد نیاز در لایه پنهان نیز از ترکیبی از روش‌های موجود استفاده شده است. به این ترتیب، با استفاده از معادله (۱۱) تعداد نرون‌ها تعیین می‌شود:

#### 1) Randomizing

(۲) به منظور ایجاد شاخص‌های تصادفی جداسازی داده‌های آموزش و آزمون از تابع dividerand در نرم افزار متلب استفاده می‌شود.

$$N^h = \frac{1}{2}(N^i + N^o) + \sqrt{m} \quad , \quad 10 \square \frac{1}{2}(5+1) + \sqrt{45} \quad (11)$$

در تابع (۱۱)،  $N^i$ ،  $N^h$ ،  $N^o$  و  $m$  به ترتیب برابر با تعداد نرون‌ها در لایه پنهان، ورودی، خروجی و تعداد مشاهدات می‌باشد. همچنین در لایه پنهان از توابع فعال‌سازی تانژانت‌هذلولی<sup>۱</sup> و زیگموئید<sup>۲</sup> استفاده شده است. پس از تعیین ساختار شبکه و مجموعه ورودی‌های آن، شبکه برای آموزش آماده می‌شود. پارامترهای شناختی ( $C_1$ )، اجتماعی ( $C_2$ ) و ضریب اینترسی ( $\omega$ ) در الگوریتم انبوه ذرات به کمک قواعد ارائه شده توسط کندی و ابرهارت (۱۹۹۵) تنظیم شده است:

$$\omega = \frac{2}{\left|2 - \varphi - \sqrt{\varphi^2 - 4\varphi}\right|} \quad , \quad \varphi = \varphi_1 + \varphi_2 > 4 \quad , \quad c_1 = \omega\varphi_1 \quad , \quad c_2 = \omega\varphi_2 \quad (12)$$


که در این رابطه، پارامترهای  $\varphi_1$  و  $\varphi_2$  برابر با ۲/۰۵ می‌باشد. همچنین در این الگوریتم تعداد جمعیت و تکرار به ترتیب برابر با ۳۰ و ۱۰۰۰ در نظر گرفته شده است. در فرایند آموزش شبکه به منظور بهینه‌سازی اوزان ارتباطی میان نرون‌ها از داده‌های آموزش و معیار میانگین مربع خطا ( $MSE^f$ ) استفاده شده و سپس به منظور انتخاب بهترین شبکه از معیار حداقل خطا در داده‌های آزمون استفاده شد. نمودار و (۲) هر یک به ترتیب فرایند یادگیری شبکه بر اساس داده‌های آموزشی و داده‌های آزمون را برای کلیه شبکه‌ها نشان می‌دهد.<sup>۵</sup>

$$1) \text{ Hyperbolic Tangent (Tanh) : } f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

$$2) \text{ Sigmoid: } f(x) = \frac{1}{1 + e^{-x}}$$


$$4) \text{ Mean Squared Error: } (MSE) = \frac{\sum_1^n (\hat{Y}_t - Y_t)^2}{n}$$

(۵) در این نمودارها جهت رویت و مقایسه بهتر نتایج از تبدیل لگاریتمی استفاده شده است.



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

منبع: یافته‌های تحقیق



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

منبع: یافته‌های تحقیق

همانگونه که نتایج نمودار (۱) نشان می‌دهد، روند یادگیری شبکه براساس *PSO* بسیار بهتر از *BP* و *LM* بوده و در انتهای فرایند یادگیری خطای کمتری داشته است. از سوی دیگر، نمودار (۲) که روند یادگیری بر اساس داده‌های آزمون را نشان می‌دهد نیز ضمن تأیید نتایج نمودار (۱) نشان می‌دهد که *PSO* در یافتن نقاط حداقل خطای مربوط به داده‌های آزمون (نقطه توقف و اوزان ایده‌آل شبکه)، این خطا را بسیار کمتر از *BP* و *LM* ارائه می‌کند. مقایسه بین این دو الگوریتم نیز

سرعت بیشتر، خطای کمتر و عملکرد بهتر  $LM$  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 ۲) 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 (۱۳) استفاده شده است.

$$x_r = (x_n + 1) \times (x_{\max} - x_{\min}) / 2 + x_{\min} \quad (13)$$

به منظور بررسی عملکرد پیش‌بینی روش‌های گوناگون، تکنیک‌های مختلفی وجود دارد که متداول‌ترین آنان، میانگین مربع خطا، مجذور میانگین مربع خطا،  $(RMSE)$ ، میانگین قدرمطلق درصد خطا  $(MAPE)$  می‌باشند. به دلیل اینکه هر یک از معیارهای مذکور جنبه‌های خاصی از عملکرد مدل را نشان می‌دهند [11]، در این مطالعه از کلیه معیارها برای ارزیابی قدرت پیش‌بینی هر تکنیک استفاده شده است. جدول ۱) و (جدول ۲) نتیجه مقایسه کارایی بر اساس داده‌های آموزش و آزمون را نشان می‌دهد. نتایج این جداول به صورت ملموس‌تر و دقیق‌تری 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 تانژانت هذلولی در مقایسه با تابع فعال‌سازی سیگموئید قابل تأیید است.

جدول ۴) مقایسه کارایی شبکه‌های عصبی پیش‌بینی کننده تقاضای انرژی (بر اساس داده‌های آموزش)

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	<b>BP-NN</b>
۳۱۸/۶۵۱۶	۱۵/۳۷۵۵	۰/۰۱۴۴	۲۲۵/۸۹۱۲	۱۲/۷۸۹۶	۰/۰۱۲۰	<b>LM-NN</b>
۶۰/۴۰۴۹	۷/۷۷۲۱	۰/۰۰۶۶	۵۸/۵۹۱۸	۶/۶۷۸۰	۰/۰۰۶۳	<b>PSO-NN</b>

منبع: یافته‌های تحقیق

1) Post-processing

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


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

جدول ۵) مقایسه کارایی شبکه‌های عصبی پیش‌بینی کننده تقاضای انرژی (بر اساس داده‌های آزمون)

تابع فعال سازی sigmoid			تابع فعال سازی 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
۶۰/۴۲۴۸	۷/۷۷۳۳	۰/۰۰۶۹	۵۳/۸۳۷۱	۷/۳۳۷۴	۰/۰۰۶۴	PSO-NN

منبع: یافته‌های تحقیق

از سوی دیگر، این نتایج ضمن تأیید عملکرد بهتر LM-NN در مقایسه با BP-NN نشان‌دهنده قدرت پیش‌بینی بالاتر شبکه‌های عصبی مبتنی بر PSO در مقایسه با BP و LM می‌باشد. این نتایج نشان می‌دهد که حداقل خطای پیش‌بینی در داده‌های آموزش و آزمون به ترتیب برابر با ۰/۶۳ و ۰/۶۴ درصد در PSO-NN با تابع فعال‌سازی تانژانت هذلولی می‌باشد. نمودار (۳) مقادیر واقعی و پیش‌بینی شده تقاضای انرژی بر اساس PSO-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 بلندمدت و در شرایط محدودیت داده‌ها را نشان می‌دهد.



نمودار (۱) پیش‌بینی تقاضای انرژی بر اساس PSO-NN

منبع: یافته‌های تحقیق

### پیش‌بینی تقاضای آتی انرژی

به منظور پیش‌بینی تقاضای آتی انرژی، ابتدا باید متغیرهای مستقل مدل پیش‌بینی شوند. از این رو، در ادامه پس از پیش‌بینی متغیرهای مستقل بر اساس سناریوسازی، تقاضای انرژی تا افق سندچشم‌انداز ۱۴۰۴ پیش‌بینی می‌شود. روش سناریو سازی یکی از روشهای کیفی آینده نگری است که بر طبق آن به ترسیم و تصور آینده با طراحی سناریوهای




فرضی می‌پردازیم. سناریوها تصویر روشنی از آینده‌اند که برنامه‌ریزی به کمک آنها می‌تواند مسائل، چالش‌ها و فرصت‌های محیط را بروشنی ببیند و بشناسد. سناریو ابزاری برای تحلیل سیاست‌ها و شناخت شرایط، تهدیدات، فرصت‌ها، نیازها و ارزش‌های برتر آینده است. به سبب گوناگونی عوامل و نیروهای سازنده آینده و پیچیدگی و تعامل میان آنها، هرگز نمی‌توان آینده را به طور دقیق پیش‌بینی کرد. از این رو، متخصصان آینده‌نگری، انتخاب محتمل‌ترین تصویر آینده را چندان درست نمی‌دانند، چرا که باید سناریوهای مختلفی را برای برنامه‌ریزی به کار برد [۱۱]. از این رو، در این مطالعه به منظور پیش‌بینی روند آتی تقاضای بلندمدت انرژی، سه سناریو احتمالی برای رشد متغیرهای مستقل در نظر گرفته و سپس براساس آنها مقادیر آتی تقاضای بلندمدت انرژی پیش‌بینی می‌گردد. سناریوهای محتمل در جدول (۶) ارائه شده است.

جدول ۴) رشد سالانه متغیرهای مستقل بر اساس سناریوسازی

متغیر	سناریو A	سناریو B	سناریو C
تولید ناخالص داخلی	۶٪	۴٪	۲٪
جمعیت	۲٪	۱/۵٪	۱٪
نرخ شهرنشینی	۱/۵٪	۱/۲۵٪	۱٪
ساختار اقتصادی	۴٪	۳٪	۲٪
ساختار انرژی	۳٪	۲٪	۱/۵٪

منبع: یافته‌های تحقیق

پس از پیش‌بینی روند متغیرهای مستقل بر اساس سناریوسازی، با جایگذاری آنها در  $PSO-NN$  می‌توان روند آتی تقاضای انرژی را پیش‌بینی کرد. نمودار ۲) نشان‌دهنده پیش‌بینی روند آتی تقاضای انرژی تا سال ۱۴۰۴ می‌باشد.



نمودار ۲) پیش‌بینی روند آتی تقاضای انرژی تا سال ۱۴۰۴

منبع: یافته‌های تحقیق

بر اساس روند پیش‌بینی شده در نمودار ۲)، می‌توان مشاهده کرد که سناریو A به صورت یک سناریو خوش‌بینانه

مقادیر آتی تقاضای انرژی را با یک تخمین بیش از حد<sup>۱</sup> پیش‌بینی کرده و مصرف انرژی در سال ۱۴۰۴ (افق سند چشم‌انداز ۲۰ ساله کشور) را ۱۸۱۸ میلیون بشکه نفت‌خام پیش‌بینی می‌کند. سناریو C نیز به صورت یک سناریو بدبینانه مقادیر آتی تقاضای انرژی را با یک تخمین کمتر از حد<sup>۲</sup> نشان داده و میزان مصرف انرژی در سال ۱۴۰۴ را ۱۴۵۷ میلیون بشکه نفت‌خام پیش‌بینی می‌کند. در نهایت، سناریو B که به صورت یک سناریو بینابین و بر اساس متوسط رشد روند گذشته متغیرهای مستقل ارائه شده است، میزان مصرف انرژی در افق سند چشم‌انداز ۲۰ ساله کشور را ۱۶۴۳ میلیون بشکه نفت‌خام پیش‌بینی می‌کند.

### 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 انبوه ذرات (PSO) و شبکه‌های عصبی (NN) 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 (PSO) 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 (PSO) و (NN) 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 لونبرگ-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 انبوه ذرات (PSO-NN)، با حداقل خطای پیش‌بینی در داده‌های آموزش و آزمون - به ترتیب برابر با ۰/۶۳ و ۰/۶۴ درصد - مناسب‌ترین تکنیک جهت پیش‌بینی تقاضای بلند مدت انرژی در شرایط محدودیت داده‌ها می‌باشد. با توجه به اهمیت پیش‌بینی صحیح تقاضای بلند مدت انرژی برای سیاست‌گذاری و مدیریت این حوزه، پس از اطمینان از قدرت الگوریتم طراحی شده، تقاضای آتی انرژی تا افق سند چشم‌انداز ۲۰ ساله کشور بر اساس سناریوسازی پیش‌بینی شد که نتایج سناریو بینابین میزان مصرف انرژی در سال ۱۴۰۴ را ۱۶۴۳ میلیون بشکه نفت خام نشان می‌دهد.

1) Overestimation  
2) Underestimation

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.

## منابع

- [۱] ابراهیمی، محسن و آل‌مرادجیدرقی، محمود (۱۳۹۰)؛ «پیش‌بینی تقاضای انرژی برای بخش‌های اقتصاد ایران در افق زمانی ۱۴۰۴ با استفاده از مدل ARIMA»؛ دومین کنفرانس مدیریت و بهینه‌سازی مصرف انرژی، ۲۰ تا ۲۱ شهریور، تهران.
- [۲] اطلاعات سری زمانی بانک مرکزی جمهوری اسلامی ایران (<http://tsd.cbi.ir>)
- [۳] اطلاعات سری زمانی مرکز آمار ایران، معاونت برنامه‌ریزی و نظارت راهبردی ریاست جمهوری (<http://amar.org.ir>).
- [۴] ترانزنامه‌های انرژی، وزارت نیرو، دفتر برنامه‌ریزی کلان برق و انرژی.
- [۵] حیدری، ابراهیم (۱۳۸۴)؛ «پیش‌بینی تقاضای انرژی در اقتصاد ایران براساس تجزیه»؛ مجله تحقیقات اقتصادی، ۶۹، ۵۶ تا ۲۷.
- [۶] خانکشی‌زاده، محرم (۱۳۸۳)؛ «پیش‌بینی بلندمدت تقاضای انرژی الکتریکی در منطقه آذربایجان با استفاده از شبکه عصبی»؛ نوزدهمین کنفرانس بین‌المللی برق، ۲ تا ۴ آذر، تهران، شرکت توانیر.
- [۷] زاهدی‌وفا، محمد هادی و فیروزان سرنقی، توحید (۱۳۸۷)؛ «بررسی اثر تجارت خارجی بر اشتغال و دستمزد نیروی کار بخش صنعت در ایران»؛ پژوهشنامه اقتصادی، شماره ۳۱، صص ۶۹ تا ۹۴.
- [۸] سهرابی‌وفا، حسین (۱۳۹۱)؛ «پیش‌بینی تقاضای انرژی در ایران با استفاده از تکنیک‌های محاسبات نرم»؛ پایان‌نامه کارشناسی ارشد، تهران، دانشگاه صنعت آب و برق (شهیدعباسپور).
- [۹] سهرابی‌وفا، حسین؛ صادقی، حسین؛ علی‌اکبر، افضلیان و حقانی، محمود (۱۳۹۱)؛ «مقایسه الگوی ARIMA و شبکه عصبی GMDH در پیش‌بینی تقاضای بلندمدت برق»؛ بیست‌وهفتمین کنفرانس بین‌المللی برق، ۲۲ تا ۲۴ آبان، تهران، پژوهشگاه نیرو.
- [۱۰] صادقی، حسین؛ ذوالفقاری، مهدی و حیدرزاده، محمد (۱۳۸۸)؛ «تخمین تابع تقاضای بنزین در بخش حمل و نقل با استفاده از الگوریتم ژنتیک»؛ فصلنامه مطالعات اقتصاد انرژی، ۲۱، ۲۷ تا ۲۱.
- [۱۱] 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.
- [۱۲] 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.
- [۱۳] 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.

- [۱۴] قنبری، علی؛ خضری، محسن و اعظمی، آرش (۱۳۸۷): « شبیه سازی تابع تقاضای بنزین و نفت گاز در حمل و نقل زمینی ایران، با استفاده از روش الگوریتم ژنتیک»؛ فصلنامه اقتصاد مقدراری، ۱۹، ۱۵۷ تا ۱۷۷.
- [۱۵] کرامت‌فر، مهدی (۱۳۹۱): «بررسی اثر افزایش قیمت حامل‌های انرژی بر عرضه صادرات صنعتی ایران»؛ پایان‌نامه کارشناسی ارشد، تهران، دانشگاه صنعت آب و برق (شهید عباسپور).
- [۱۶] منهج، محمد باقر (۱۳۸۴): «مبانی شبکه‌های عصبی»؛ دانشگاه صنعتی امیرکبیر، تهران.
- [۱۷] منهج، محمدباقر؛ کاظمی، عالیه؛ شکوری گنجوی، حامد؛ مهرگان، محمدرضا و تقی‌زاده، 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 تا ۲۲۰.
- [۱۸] موسوی، سیدنعمت‌اله؛ مختاری، زینب و فرج‌زاده ذکریا (۱۳۸۹): «پیش‌بینی مصرف حامل‌های انرژی در بخش کشاورزی ایران با الگوهای ARCH و ARIMA»؛ فصلنامه مطالعات اقتصاد انرژی، ۲۷، ۱۸۱ تا ۱۹۵.
- [19] Abdel-Kader, R.F. (2011); "Hybrid discrete PSO with GA operators for efficient QoS-multicast routing"; *Ain Shams Engineering Journal*, 2: 21-31.
- [20] 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, Surrey Energy Economics Centre (SEEC), School of Economics, University of Surrey.
- [21] Andonie R. (2010) "Extreme Data Mining: Inference from Small Datasets"; *International Journal of Computers Communications & Control*, 5: 280-291.
- [22] 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.
- [23] 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.
- [24] 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.
- [25] 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.
- [26] 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.
- [27] Bhattacharyya, S. C. and G.R. Timilsina (2009); "Energy Demand Models for Policy Formulation"; *Policy Research Working*, paper: 4866.
- [28] Bianco, V., Manca, O. and S. Nardini (2009); "Electricity consumption forecasting in Italy using linear regression models"; *Energy*, 34: 1413-1421.
- [29] 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.
- [30] 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, Surrey Energy Economics Centre (SEEC), School of Economics, University of Surrey.
- [31] Dunkerley, J., W. Ramsay, L. Gordon and E. Cecelski (1981); "Energy Strategies for Developing Countries"; Washington, DC: Resources for the Future.
- [32] Ferguson, R., Wilkinson, W. and R. Hill (2000); "Electricity Use and Economic Development"; *Energy Policy*, 28: 923-934.
- [33] 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.

- [34] Geem, Z.W. (2011); "Transport energy demand modeling of South Korea using artificial neural network" *Energy Policy*, 39: 4644-4650.
- [35] Haldenbilen, S. and H. Ceylan (2005); "Genetic algorithm approach to estimate transport energy demand in Turkey"; *Energy Policy*, 33: 89-98.
- [36] Haykin, S. (1999); "Neural Networks: A Comprehensive Foundation" Prentice-Hall Inc., NJ.
- [37] 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.
- [38] Hornik, K. (1991); "Approximation Capabilities of Multilayer Feedforward Networks"; *Neural Networks*, 4: 251-257.
- [39] Huang, C., and C. Moraga (2004); "A diffusion-neural-network for learning from small samples"; *International Journal of Approximate Reasoning*, 35: 137-161.
- [40] Kennedy, J., and R. Eberhart (1995); "Particle swarm optimization. In: Neural Networks"; *IEEE International Conference on Proceedings*, pp. 1942-1948 vol.4.
- [41] 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
- [42] Kuan, C.M., and H. White (1994); "Artificial neural networks: An econometric perspective"; *Econometric Reviews*, 13: 1-91.
- [43] 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.
- [44] Lin, B. Q. (2003); "Electricity Demand in the People's Republic of China", *ERD Working Paper* series, No.37, Economics and Research Department.
- [45] 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.
- [46] 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.
- [47] McCulloch WS and W. Pitts (1943); "A logic calculus of the ideas immanent in nervous activity"; *Bull of Math Biophys*, 5: 115-133.
- [48] Mohamed, Z. and P. Bodger (2005); "Forecasting electricity consumption in New Zealand using economic and demographic variables"; *Energy*, 30: 1833-1843.
- [49] Murat, Y.S., and H. Ceylan (2006); "Use of artificial neural networks for transport energy demand modeling"; *Energy Policy*, 34: 3165-3172.
- [50] OZTURK, H. K., CEYLAN, H., CANYURT, O. E., and A. HEPBASLI (2005); "Electricity Estimation Using Genetic Algorithm Approach: A Case Study of Turkey"; *Energy*, 30, 1003-1012.
- [51] Pao, H.T. (2009) "Forecasting energy consumption in Taiwan using hybrid nonlinear models"; *Energy*, 34: 1438-1446.
- [52] Pindyck, R.S.(1979); "The structure of world energy demand"; The MIT Press Cambridge, Massachusetts.
- [53] 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.
- [54] Rosenberg, N. (1998). "The role of electricity in industrial development", *The Energy Journal*, 19: 7-24.
- [55] Rosenblatt, F. (1958); "The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain"; *Psychological Review*, 65: 386-408. Reprinted in *Anderson and Rosenfeld*, 1988, pp 92-114.
- [56] SÖZEN, A., and E. ARCAKLIOĞLU (2007); "Prospects for Future Projections of the Basic Energy Sources in Turkey"; *Energy Sources, Part B: Economics, Planning, and Policy*, 2, 183-201.
- [57] Suganthi L., and A.A. Samuel (2012); "Energy models for demand forecasting—A review"; *Renewable and Sustainable Energy Reviews*, 16:1223– 1240.

- [58] 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.
- [59] Ünler, A. (2008) ; "Improvement of energy demand forecasts using swarm intelligence: The case of Turkey with projections to 2025"; *Energy Policy*, 36: 1937-1944.
- [60] Wirl, F. and E. Szirucsek (1990); "Energy modelling – a survey of related topics"; *OPEC Review*, Autumn: 361-78.
- [61] 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.
- [62] 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.
- [63] 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.