

ترکیب شبکه‌های عصبی و الگوریتم‌های تکاملی در پیش‌بینی تقاضای انرژی

حسین صادقی^۱
حسین سهرابی‌وفا^۲
فاطمه نوری^۳

چکیده

پیش‌بینی روند تقاضای انرژی جهت اتخاذ سیاست‌های مقتضی و مناسب اهمیت فراوانی دارد. به دلیل روند پرنوسان و غیر خطی تقاضای انرژی و متغیرهای موثر بر آن قابلیت روش‌های هوشمند و غیر خطی به خصوص شبکه‌های عصبی و الگوریتم‌های تکاملی به منظور پیش‌بینی تقاضای انرژی در مطالعات مختلف به اثبات رسیده است. با وجود نقاط قوت فراوان، این تکنیک‌ها با مسائل مهمی همچون تحمیل فرم تبعی خاص - در الگوریتم‌های تکاملی - یا نیاز به نمونه‌های آموزشی فراوان - در شبکه‌های عصبی - مواجه هستند. هدف این مطالعه ارائه یک الگوریتم ترکیبی جهت پیش‌بینی هرچه دقیق‌تر تقاضای انرژی می‌باشد تا ضمن رفع معایب تکنیک‌های فردی از مزایای آنان به صورت همزمان استفاده شود. بدین منظور کارایی تکنیک‌های مختلف در پیش‌بینی تقاضای انرژی طی دوره ۱۳۴۶ تا ۱۳۹۰ مورد بررسی قرار گرفته است. یافته‌های پژوهش نشان می‌دهد استفاده از الگوریتم‌های تکاملی در آموزش شبکه‌های عصبی در شرایط محدودیت داده‌ها، نتایج مطلوبی داشته و در این بین شبکه عصبی پیشنهادی مبتنی بر ترکیب الگوریتم ژنتیک و انبوه ذرات نتایج بسیار مناسبی ارائه می‌کند. به گونه‌ای که مقایسه نتایج با سایر مطالعات در این حوزه علاوه بر تأیید قدرت توضیح دهنده‌گی متغیرهای بکار رفته، توانایی بالاتر الگوریتم پیشنهادی را نشان می‌دهد. همچنین نتایج پیش‌بینی روند آتی تقاضای انرژی نشان می‌دهد که میزان مصرف انرژی در سال ۱۴۰۴ بر اساس سه سناریو مختلف معادل ۱۸۱۷، ۱۶۴۳ و ۱۴۵۷ میلیون بشکه نفت خام خواهد بود.

واژگان کلیدی: شبکه‌های عصبی، الگوریتم ژنتیک، الگوریتم انبوه‌ذرات، پیش‌بینی، تقاضای انرژی.

Keywords: Neural Networks, Genetic Algorithm, Particle Swarm Algorithm, prediction, Energy Demand.

JEL Classification: Q41, Q40, C69, C53, C45, C22.

^۱ عضو هیأت علمی دانشکده مدیریت و اقتصاد دانشگاه تربیت مدرس

^۲ کارشناس ارشد اقتصاد انرژی پردیس فنی مهندسی شهیدعباسپور (نویسنده مسئول)

^۳ کارشناس ارشد اقتصاد نظری دانشگاه مفید

۱- مقدمه

انرژی شالوده اساسی توسعه جوامع بوده و به عنوان یک عامل محیطی مهم، نقش اساسی در حیات و توسعه زندگی بشر داشته است (یو و همکاران^۱، ۲۰۱۲ a). در دهه هفتاد میلادی تکانه‌های نفتی همراه با رکود اقتصادی در غرب سبب شد تا نقش انرژی در تحولات اقتصادی جایگاه ویژه‌ای پیدا کرده و پس از آن بررسی کمی عوامل موثر بر تغییرات مصرف آن، به منظور آگاهی از روند گذشته و پیش‌بینی مصرف آتی آن در جهت برنامه‌ریزی و سیاست‌گذاری‌های اقتصادی در کانون توجه محققین و تحلیل‌گران اقتصادی قرار گیرد. به دلیل روند غیر خطی و پرنوسان تقاضای انرژی و متغیرهای اثرگذار بر آن، توابع ریاضی غیر خطی می‌تواند تقاضای انرژی را بهتر برآورد کنند که این امر منجر به جستجوی راه‌حلی‌هایی با رویکرد هوشمند مانند الگوریتم‌های تکاملی^۲ (EA) و شبکه‌های عصبی مصنوعی^۳ (ANN) شده است که البته هر یک دارای مزایا و معایب خاص خود می‌باشند. در استفاده از الگوریتم‌های تکاملی به دلیل تحمیل فرم تبعی خاص به صورت خطی، درجه دوم، نمایی^۴ و یا هر فرم تبعی دیگر، امکان عدم شناسایی روابط پیچیده‌ی غیر خطی وجود دارد (آزاده و همکاران^۵، ۲۰۰۹). از سوی دیگر شبکه‌های عصبی مصنوعی ضمن عدم نیاز به تعیین فرم تبعی خاص، خود دارای معایب دیگری می‌باشند، عدم وجود یک روش استقرایی جامع در انتخاب الگوریتم یادگیری شبکه، توقف الگوریتم در مینیمم محلی^۶ و همچنین نیاز به منبع غنی داده‌ها برای یادگیری شبکه از نقایص این تکنیک به شمار می‌رود.

از نظر ذخایر قابل استحصال انرژی، ایران با داشتن ۱۵۶/۵۳ میلیارد بشکه نفت خام و میعانات گازی متعارف، پس از ونزوئلا، عربستان و کانادا در رتبه چهارم جهان قرار داشته و تقریباً ۹ درصد ذخایر نفت جهان را دارا می‌باشد. با این وجود مصرف انرژی در ایران نیز بسیار بالا بوده و از استانداردهای جهانی و حتی مصرف کشورهای هم‌نوع خود (اعضای اوپک) بیشتر است.^۷ بررسی روند تحولات انرژی در کشور نشان می‌دهد که به دنبال تغییرات ساختاری اقتصاد ایران خصوصاً پس از دهه ۴۰ شمسی رشد و توسعه صنایع و به کارگیری تجهیزات مصرف‌کننده نو و همچنین

1. Yu et al. (2012a)

2. Evolutionary Algorithm (EA)

3. Artificial Neural Network (ANN)

4. Linear, Quadratic, Exponential

5. Azadeh et al. (2009)

6. Local Minimum

۷. ارقام ارائه شده بر اساس داده‌های ترازنامه انرژی سال ۱۳۹۰ می‌باشد.

رشد شهرنشینی، مصرف انواع حامل‌های انرژی رو به افزایش گذاشته است. مصرف نهایی انرژی در سال ۱۳۴۶ برابر با ۵۳/۴ میلیون بشکه معادل نفت خام بوده که در سال ۱۳۵۶ به ۲۰۶/۹ میلیون بشکه افزایش یافته و به‌طور متوسط، سالانه معادل ۱۴/۶ درصد رشد داشته است. پس از پیروزی انقلاب و تحولات سیاسی-اقتصادی و به‌خصوص جنگ تحمیلی، مصرف انرژی همچنان به روند افزایشی خود ادامه داده و از ۱۹۹/۷ میلیون بشکه در سال ۱۳۵۷ به ۳۳۱/۴ میلیون بشکه در سال ۱۳۶۷ افزایش یافته است. پس از آزادسازی مصرف انرژی در سال ۱۳۶۸ مصرف انرژی شتاب بیشتری داشته و طی سال‌های ۱۳۶۸ تا ۱۳۷۲ (طی برنامه اول) از رشدی معادل ۵/۸۸ درصد برخوردار بوده است. اما این روند طی سال‌های ۱۳۷۳ تا ۱۳۸۰ با اندکی کاهش به ۳/۱ درصد رسیده است. مروری بر روند تحولات مصرف انرژی در کشور به‌ویژه عدم تغییر الگوی مصرف علیرغم محدودیت‌های شدید که افزایش مصرف انرژی پس از آزادسازی نشان‌دهنده آن است، این فرضیه را که احتمالاً افزایش قیمت انرژی در سطوح محدود و کوتاه مدت اثری بر تغییر الگوی مصرف نخواهد داشت قوت می‌بخشد (ملکی، ۱۳۸۳). نگاهی به تحولات مصرف انرژی و آلودگی‌های ناشی از سوخت‌های فسیلی اهمیت برنامه‌ریزی و مدیریت تقاضای انرژی و به تبع مدل‌سازی و پیش‌بینی تقاضای انرژی جهت اتخاذ سیاست‌های مناسب را نشان می‌دهد.

در این مطالعه با توجه به نیاز سیاست‌گذاران، برنامه‌ریزان و محققین درگیر با مسائل انرژی و علاقه‌مند به پیش‌بینی تقاضای انرژی و با توجه به محدودیت تعداد داده‌ها و پیروی آن‌ها از روند غیر خطی، تکنیک ترکیبی الگوریتم‌های تکاملی و شبکه‌ی عصبی چند لایه پرسپترون (MLP)^۱ جهت پیش‌بینی تقاضای کل انرژی ارائه شده است.

دوره زمانی این مطالعه نیز، سال‌های ۱۳۴۶ تا ۱۳۹۰ می‌باشد. جنبه‌های نوآوری این مطالعه علاوه بر معرفی یک تکنیک ترکیبی فراابتکاری 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. در بخش سوم تکنیک ترکیبی مورد استفاده ارائه می‌شود. در بخش چهارم متغیرهای توضیحی معرفی و در بخش پنجم تقاضای انرژی با استفاده از تکنیک‌های متنوع پیش‌بینی شده و با استفاده از معیارهای مختلف ارزیابی خطا، کارایی این

^۱. Multi-Layer Perceptron (MLP)

تکنیک‌ها بررسی می‌شود و پس از انتخاب بهترین تکنیک، در بخش ششم به کمک سناریوسازی روند آتی تقاضای انرژی پیش‌بینی می‌شود و در نهایت در بخش هفتم نتایج مطالعه ارائه می‌شود.

۲- پیشینه تحقیق

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، به‌طور وسیعی افزایش یافت (پیندیک^۱، ۱۹۷۹). از آن زمان بحث پویا و زنده‌ی میان مهندسين و اقتصاددانان فعال در زمینه انرژی منجر به تحولات مهم در روش‌هایی به جهت غنی‌تر شدن فرایند تصمیم‌گیری انرژی به عنوان یک مجموعه‌ی کل گردید و طیف گسترده‌ای از مدل‌ها برای تحلیل و پیش‌بینی تقاضای انرژی ابداع و در دسترس محققین قرار گرفت (ویرل و سزیراکسک^۲، ۱۹۹۰). پیش‌بینی تقاضای انرژی برای برنامه‌ریزی انرژی، تنظیم استراتژی و تعریف و توصیه‌ی 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 مولفه‌ی اساسی به شمار می‌رود (بهاتاچاریا و تیملسینا^۳، ۲۰۰۹). بنابراین مدل‌سازی و پیش‌بینی تقاضای انرژی برای سیاست‌گذاران و فعالان در بخش انرژی بسیار با اهمیت است. در سال‌های اخیر مطالعات فراوانی در زمینه پیش‌بینی تقاضای انرژی با استفاده از تکنیک‌های نوین محاسباتی در جهت غلبه بر مسائل مرتبط با روند غیر خطی و پرنوسان تقاضای انرژی و متغیرهای توضیحی آن انجام شده که در ادامه و در جداول (۱) و (۲) به ترتیب خلاصه‌ای از مطالعات خارجی و داخلی انجام شده در این زمینه مرور شده است.

به‌طور کلی از نتایج مطالعات مرور شده می‌توان دریافت، الگوهایی که بر پایه مدل‌های غیرخطی و بخصوص شبکه‌های عصبی (NN) بنا شده‌اند نتایج مطلوب‌تری نسبت به الگوهای خطی داشته‌اند. از سوی دیگر انتخاب الگوریتم یادگیری و توقف الگوریتم در نقطه بهینه محلی و همچنین نیاز به نمونه‌های آموزشی فراوان از جمله محدودیت‌های پیش روی شبکه‌های عصبی می‌باشد. از این‌رو در این مطالعه برای نخستین بار در ادبیات مربوط به پیش‌بینی تقاضای انرژی از تکنیک ترکیبی

1. Pindyck (1979)

2. Wirl and Szirucsek (1990)

3. Bhattacharyya and Timilsina (2009)

شبکه عصبی و الگوریتم‌های تکاملی استفاده شده است. چراکه در این تکنیک نقاط ضعف هر یک از تکنیک‌های شبکه‌های عصبی و الگوریتم‌های تکاملی پوشش داده می‌شود. عدم نیاز به فرم تبعی خاص شبکه‌های عصبی و جستجوی نقاط بهینه سراسری الگوریتم‌های تکاملی در یادگیری شبکه با داده‌های محدود از مهم‌ترین نقاط قوت این تکنیک خواهد بود.

جدول ۱: مطالعات خارجی 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 ^۱ (۲۰۰۴)
درآمد ملی، جمعیت، تعداد خودروها	انرژی حمل و نقل (ترکیه)	الگوریتم ژنتیک	هالدنبیلن و جیلان ^۲ (۲۰۰۵)
درآمد ملی، جمعیت، تعداد خودروها	انرژی حمل و نقل (ترکیه)	شبکه عصبی	مرات و جیلان ^۳ (۲۰۰۶)
سری زمانی	انرژی الکتریکی (ایران)	شبکه عصبی	آزاده و همکاران ^۴ (۲۰۰۷)
درآمد ملی، جمعیت، صادرات، واردات	انرژی (ترکیه)	الگوریتم انبوه ذرات	آنلر ^۵ (۲۰۰۸)
سری زمانی	انرژی (تایوان)	شبکه عصبی	پاو ^۶ (۲۰۰۹)
تولید ناخالص داخلی، جمعیت صادرات، واردات	فراورده‌های نفتی (ایران)	الگوریتم ژنتیک و الگوریتم انبوه ذرات	عصاره و همکاران ^۷ (۲۰۱۰)
متغیرهای تولید ناخالص داخلی، جمعیت، قیمت سوخت، تعداد خودروها، میزان حمل و نقل	انرژی بخش حمل و نقل (کره جنوبی)	رگرسیون معمولی، شبکه عصبی	جیم ^۸ (۲۰۱۱)
تولید ناخالص داخلی، جمعیت، تعداد خودروها	انرژی بخش حمل و نقل (کره جنوبی)	برنامه‌ریزی ژنتیک	فروزان‌فر و همکاران ^۹ (۲۰۱۲)
اندازه خانه، تعداد ساکنین، بهره‌وری از تجهیزات گرمایشی، شدت انرژی	انرژی بخش خانگی (امریکا)	رگرسیون معمولی، شبکه عصبی	کیالاشکی و ریسل ^{۱۰} (۲۰۱۳)

منبع: سهرابی‌وفا (۱۳۹۱)

1. Canyurt et al. (2004)
2. Haldenbilen and Ceylan (2005)
3. Murat and Ceylan (2006)
4. Azadeh et al. (2007)
5. Ünler (2008)
6. Pao (2009)
7. Assareh et al. (2010)
8. Geem (2011)
9. Forouzanfar et al. (2012)
10. Kialashaki and Reisel (2013)

جدول ۲: مطالعات داخلی انجام شده در زمینه پیش‌بینی تقاضای انرژی

نویسنده (سال)	تکنیک	متغیر هدف (کشور)	متغیر توضیحی
خانکشی‌زاده (۱۳۸۳)	شبکه‌های عصبی	انرژی الکتریکی (ایران)	تولید ناخالص داخلی، قیمت، جمعیت، تعداد مشترکین
حیدری (۱۳۸۴)	تجزیه	انرژی بخش‌های صنعت، کشاورزی، خدمات، حمل و نقل (ایران)	نرخ رشد، سهم تولید از تولید ناخالص داخلی و شدت مصرف انرژی هر بخش
قبری، خضری و اعظمی (۱۳۸۷)	الگوریتم ژنتیک	انرژی بخش حمل و نقل زمینی (ایران)	تولید ناخالص داخلی، جمعیت، تعداد خودروها، مسافت طی شده
صادقی، ذولفقاری و حیدرزاده (۱۳۸۸)	الگوریتم ژنتیک	بنزین بخش حمل و نقل (ایران)	تولید ناخالص داخلی، قیمت بنزین، جمعیت، تعداد خودروهای بنزین سوز، عمر متوسط خودرو، راندمان مصرف
موسوی و همکاران (۱۳۸۹)	ARCH ^۱ و ARIMA ^۲	حامل‌های انرژی بخش کشاورزی (ایران)	سری زمانی
ابراهیمی و آل‌مراد جیدرفی (۱۳۹۰)	ARIMA	انرژی بخش‌های صنعت، خانگی، کشاورزی، خدمات، حمل و نقل (ایران)	سری زمانی
سهرابی‌وفا و همکاران (۱۳۹۱)	شبکه عصبی GMDH ^۳ و ARIMA	انرژی الکتریکی (ایران)	سری زمانی
صادقی و همکاران (۱۳۹۱)	الگوریتم ترکیبی عصبی فازی و انبوه ذرات	انرژی الکتریکی (ایران)	تولید ناخالص داخلی، جمعیت

منبع: سهرابی‌وفا (۱۳۹۱)

با توجه به مطالب فوق از نظر مدلسازی تمایز و نوآوری مطالعه حاضر با مطالعات صورت گرفته در زمینه تقاضای انرژی، استفاده از تکنیک ترکیبی هوشمند شبکه عصبی و الگوریتم‌های تکاملی در پیش‌بینی تقاضای انرژی می‌باشد. الگوریتم پیشنهادی به صورت هوشمند پس از آموزش و مقایسه شبکه‌های عصبی مختلف به وسیله الگوریتم‌های تکاملی بر اساس بهترین شبکه مصرف انرژی را پیش‌بینی می‌کند. همچنین استفاده از متغیرهایی متفاوت با سایر مطالعات در جهت بهبود قدرت پیش‌بینی مدل، وجه تمایز دیگر این مطالعه خواهد بود.

۳- مبانی نظری تکنیک پیشنهادی

الگوریتم ژنتیک (GA)^۴ و الگوریتم انبوه ذرات (PSO)^۱ هر دو از الگوریتم‌های جمعیت مبنای می- باشند که قدرت آن‌ها در حل مسائل بهینه‌یابی بسیار دشوار به اثبات رسیده است (کندی و

1. Autoregressive Integrated Moving Average

2. Autoregressive Conditional Heteroskedasticity

3. Group Method of Data Handling

4. Genetic Algorithm

ابرهارت، ۱۹۹۵)^۳. با این وجود هر دو مدل دارای نقاط ضعف و قوت خاص خود می‌باشد. الگوریتم انبوه ذرات از نظر مفهومی بسیار ساده و از نظر پیاده‌سازی تنها در چند خط قابل کد شدن می‌باشد. الگوریتم انبوه ذرات همچنین برخلاف الگوریتم ژنتیک دارای حافظه می‌باشد در حالی که در الگوریتم ژنتیک چنانچه یک ذره برای نسل بعد انتخاب نشود خاطرات آن کاملاً محو خواهد شد. در الگوریتم انبوه ذرات فعل و انفعالات مشترک و همکاری گروه موجب بهبود جستجو برای یافتن پاسخ بهینه می‌باشد، در حالی که الگوریتم ژنتیک در یافتن پاسخ دقیق با مشکل مواجه است ولی در یافتن بهینه سراسری عملکرد مناسبی دارد (عبدالقادر^۴، ۲۰۱۱). با این وجود بدون عملگر انتخاب الگوریتم انبوه ذرات ممکن است منابع محاسباتی را بر روی ذراتی که از نظر پاسخ مسئله ضعیف ارزیابی می‌شوند و در ناحیه نامناسبی قرار دارند به هدر دهد. مقایسه میان هر دو الگوریتم ژنتیک و انبوه ذرات توسط ابرهارت و شی^۵ (۱۹۹۸) و همچنین انجلین^۶ (۱۹۹۸) انجام شده و در نهایت هر دو مطالعه پیشنهاد کرده‌اند که ترکیبی از الگوریتم ژنتیک و انبوه ذرات استاندارد منجر به استراتژی جستجوی کارآمدتری خواهد شد. الگوریتم انبوه ذرات استاندارد ممکن است انعطاف کافی برای مسائل کاربردی را نداشته باشد، به خصوص زمانی که این مسائل پیچیده، ناسازگار و چند هدفه^۷ باشند. روش‌های مختلفی جهت ترکیب این دو الگوریتم وجود دارد. یک رویکرد استفاده از تنها یک الگوریتم در مرحله انتخاب و سپس استفاده از عملگرهای الگوریتم دیگر جهت ایجاد پاسخ‌های بهینه می‌باشد. مطالعه محمدی و جزایری^۸ (۲۰۰۷) و همچنین رایبسون و همکاران^۹ (۲۰۰۲) چنین رویکردی داشته است. رویکرد دیگر در ترکیب این دو الگوریتم می‌تواند تقسیم جمعیت به دو دسته باشد که در آن برای هر دسته تنها عملگرهای یک الگوریتم اعمال می‌شود. مطالعه گریمالدی و همکاران^{۱۰} (۲۰۰۴) و همچنین کاو و زهرا^{۱۱} (۲۰۰۸) دارای چنین رویکردی بوده‌اند. در این مطالعه رویکرد نوینی در ترکیب این دو الگوریتم ارائه شده

^۱. Particle Swarm Optimization

^۲. Population Based Algorithm

^۳. جهت رعایت اختصار از بحث درباره جزئیات هر یک از الگوریتم‌ها خودداری شده است. خوانندگان علاقه‌مند می‌توانند جهت آشنایی بیشتر به مطالعه انجام شده توسط صادقی و همکاران (۱۳۹۱) مراجعه کنند.

^۴. Abdel-Kader (2011)

^۵. Eberhart and Shi (1998)

^۶. Angeline (1998)

^۷. Complicated, Conflicting and Multitasking

^۸. Mohammadi and Jazaeri (2007)

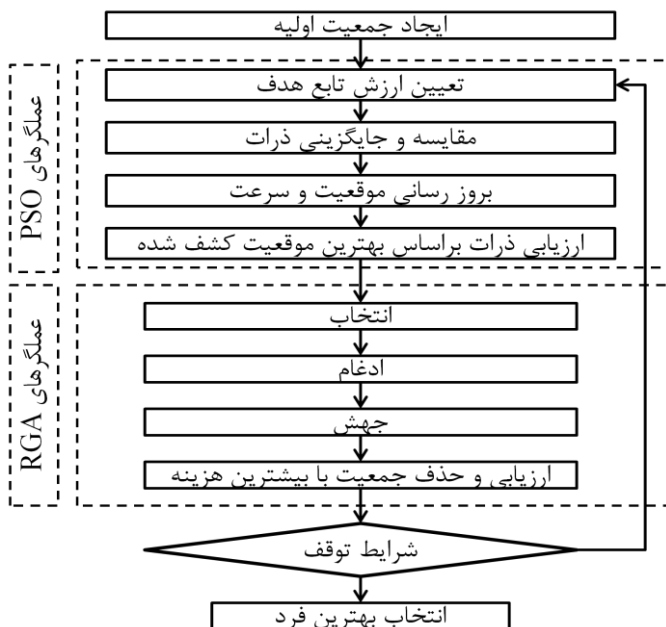
^۹. Robinson et al. (2002)

^{۱۰}. Grimaldi et al. (2004)

^{۱۱}. Kao and Zahara (2008)

است به گونه‌ای که در آن کلیه عملگرهای هر دو الگوریتم همزمان بر روی جمعیت اعمال می‌شود.

شکل ۱ مراحل اجرای الگوریتم ترکیبی ارائه شده در این مطالعه را نشان می‌دهد.



شکل ۱: فلوچارت ترکیب الگوریتم انبوه ذرات و ژنتیک

همان گونه که در شکل ۱ مشاهده می‌شود، در این تکنیک پس از ایجاد جمعیت اولیه به ترتیب عملگرهای الگوریتم انبوه ذرات و الگوریتم ژنتیک^۱ بر روی کلیه افراد اعمال می‌شود که فرآیند مربوط به هر یک پیش تر بحث شد. شرط توقف در این الگوریتم معیار حداکثر تعداد تکرار^۲ می‌باشد.

شبکه‌های عصبی در بسیاری از زمینه‌های مختلف مورد استفاده قرار گرفته‌اند با این وجود، دستیابی به نتایج مطلوب تنها زمانی ممکن بوده است که منبع غنی داده‌ها با مشاهدات فراوان در اختیار

^۱ در این مطالعه از نسخه بهبود یافته الگوریتم ژنتیک با نام الگوریتم ژنتیک با کدگذاری حقیقی (Real Coded GA) استفاده شده است.

^۲ Iteration

باشد و زمانی که با داده‌های اندک برای آموزش شبکه مواجه بوده‌ایم کارایی بالایی نداشته است که این نقص کاربردهای شبکه‌ی عصبی را به شدت محدود می‌کند (اندونی^۱، ۲۰۱۰). تکنیک‌های هوشمند متنوعی جهت فائق آمدن بر مسئله‌ی محدودیت داده‌های آموزش ارائه شده است؛ ایجاد نمونه‌های آموزشی هوشمند^۲، انتخاب ویژگی^۳، تنظیم مناسب پارامترهای مدل استنباطی^۴ و دسته‌بندی گروهی داده‌ها^۵ از جمله تکنیک‌های پیشنهادی در این زمینه بوده است که مطالعات مختلف از جمله مطالعات انجام شده توسط رانگفو و همکاران^۶ (۲۰۰۶)، لی و لیو^۷ (۲۰۰۹)، هوانگ و مورگا^۸ (۲۰۰۴)، تسای و لی^۹ (۲۰۰۸)، سهرابی و وفا و همکاران (۱۳۹۱) به زعم خود 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 غیر خطی از جمله مسائل پیش‌روی این تکنیک‌ها بوده است. از این‌رو در این مطالعه به منظور غلبه بر مسائل فوق، به کمک الگوریتم‌های تکاملی به آموزش شبکه‌های 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 در شکل ۲ نشان داده شده است.

در شکل ۲ نمادهای LM-NN، BP-NN، PSO-RGA-NN، PSO-NN، RGA-NN به ترتیب نشان دهنده شبکه‌های عصبی مبتنی بر الگوریتم ژنتیک، الگوریتم انبوه ذرات، الگوریتم ترکیبی انبوه ذرات و ژنتیک، الگوریتم پس‌انتشار خطا و الگوریتم لونبرگ مارکوارت می‌باشد.

1. Andonie (2010)

2. Generate Artificial Training Samples

3. Feature Selection

4. Parameter Fine-Tuning of the Inferred Model

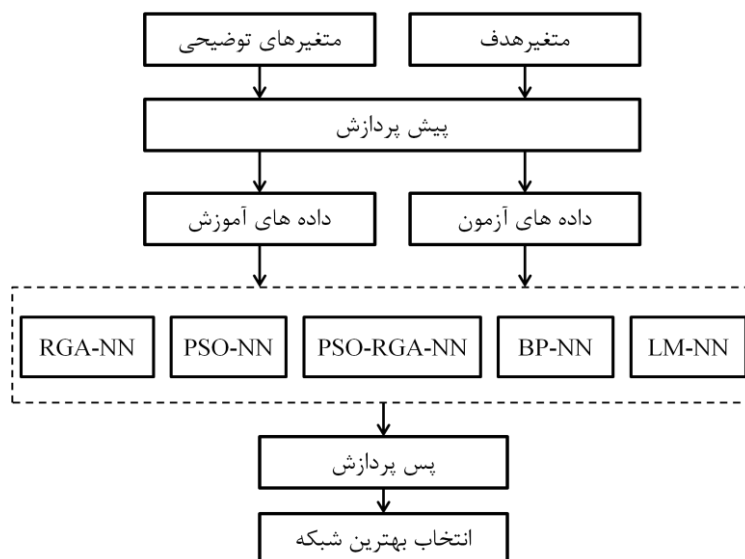
5. Group Method of Data Handling

6. Rongfu et al. (2006)

7. Li and Liu (2009)

8. Huang and Moraga (2004)

9. Tsai and Li (2009)



شکل ۲: فلوچارت الگوریتم ترکیبی پیش‌بینی کننده تقاضای انرژی

۴- بررسی مدل

مروری بر مبانی نظری نشان می‌دهد که مدلسازی تقاضای انرژی بر اساس رویکردهای مختلف به طرق گوناگونی انجام می‌شود که می‌توان آن‌ها را در سه دسته کلی؛ روش‌های آماری (بدون تصریح روابط علی و ساختاری)، اقتصادسنجی و شبیه‌سازی دسته‌بندی کرد. شبکه‌های عصبی و سیستم‌های خبره از روش‌های پرکاربرد و موفق مبتنی بر شبیه‌سازی می‌باشند که تقاضای بلندمدت انرژی را با استفاده از متغیرهای کلان اقتصادی و اجتماعی پیش‌بینی می‌کنند (سوگانتی و سامونل^۱، ۲۰۱۲).

پیش‌بینی تقاضای انرژی در دو افق کوتاه مدت (ساعتی، هفتگی، ماهانه) و بلندمدت (سالانه و چندساله) انجام می‌شود. اطلاعات حاصل از پیش‌بینی‌های بلندمدت به منظور گسترش ظرفیت تولید، تصمیمات سرمایه‌گذاری، تحلیل سود و بودجه‌ریزی حیاتی می‌باشد (کوچوکنیز^۲، ۲۰۱۰). این اطلاعات همچنین جهت سیاست‌گذاری و مدیریت تقاضا و برنامه‌ریزی جهت کاهش آلاینده‌های زیست محیطی ضروری می‌باشد.

¹. Suganthia and Samuel (2012)

². Kucukdeniz (2010)

بررسی ادبیات تجربی در زمینه پیش‌بینی بلندمدت تقاضای انرژی نشان می‌دهد که این مطالعات در اغلب موارد از متغیرهای تولید ناخالص داخلی، جمعیت، صادرات و واردات به عنوان عوامل مؤثر بر تقاضای کل انرژی استفاده کرده و سایر عواملی را که در تقاضای انرژی مؤثر هستند نادیده گرفته‌اند. اما تقاضای انرژی از عوامل دیگری همچون؛ قیمت انرژی، ساختار اقتصادی، ساختار انرژی و نیز نرخ شهرنشینی تأثیر می‌پذیرد. همچنین در مدل‌سازی‌های بلندمدت به دلیل حضور متغیر تولید ناخالص داخلی استفاده از متغیرهای زیرمجموعه آن همچون صادرات و واردات ضروری به نظر نمی‌رسد. از سوی دیگر متغیرهای جوی همچون دما و رطوبت به طور سالانه تغییر محسوسی نداشته و همچنین تنوع آب و هوایی کشور نیز مزید بر علت عدم استفاده از متغیرهای جوی در مدل‌سازی‌های کلان در بلندمدت خواهد بود (صادقی و همکاران، ۱۳۹۱). در ادامه به تشریح متغیرهای مؤثر بر تقاضای بلندمدت کل انرژی بر اساس ادبیات تجربی پرداخته می‌شود.

۴-۱- تولید ناخالص داخلی

بر اساس تئوری‌های اقتصادی افزایش درآمد منجر به افزایش قدرت خرید مصرف‌کنندگان شده و افزایش قدرت خرید منجر به افزایش مصرف کالاهای ضروری خواهد شد. روزنبرگ^۱ (۱۹۹۸) بیان می‌کند که شواهدی قوی برای اثرگذاری فرایند توسعه اقتصادی بر مصرف انرژی مشاهده می‌شود. فرگوسن و همکاران^۲ (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 (کرامت‌فر، ۱۳۹۱). همچنین یک باور عمومی و توافق کلی در زمینه ارتباط میان سطح فعالیت اقتصادی و مصرف انرژی وجود دارد که مطالعات فروانی با استفاده از تکنیک‌های علیت^۳ روابط میان این دو متغیر را به خوبی نشان داده‌اند. با در نظر گرفتن مطالعه انجام شده توسط مهرآرا^۴ (۲۰۰۷) یک رابطه یک طرفه از تولید ناخالص داخلی به مصرف انرژی در کشورهای صادرکننده نفت وجود دارد. بر این اساس می‌توان بیان داشت که در این کشورها افزایش تولید منجر به افزایش مصرف انرژی می‌گردد و ایران نیز به عنوان یکی از کشورهای صادرکننده نفت از این اصل مستثنی

^۱. Rosenberg (1998)

^۲. Ferguson et al. (2000)

^۳. Causality

^۴. Mehrara (2007)

نخواهد بود (صادقی و همکاران، ۱۳۹۱). چرا که روند تاریخی اقتصاد ایران نشان می‌دهد، قیمت پایین انرژی باعث وابستگی شدید تولیدات این کشور به مصرف انرژی بوده است (مهرگان و همکاران، ۱۳۹۱). بنابراین افزایش سطح تولید منجر به افزایش مصرف انرژی می‌شود (بهبودی و همکاران، ۱۳۸۷). 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 آنگک^۱ (۱۹۸۸)، لین^۲ (۲۰۰۳)، آماراویکراما و هانت^۳ (۲۰۰۷) و دیلاور و هانت^۴ (۲۰۱۱) اشاره نمود.

۴-۲- جمعیت

جمعیت کل نه تنها بر مقدار مصرف انرژی تأثیرگذار 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^۵، ۲۰۱۲). از این رو متغیر جمعیت را می‌توان به عنوان یکی از مهم‌ترین عوامل مؤثر بر تقاضای انرژی در نظر گرفت (شورا و همکاران^۶، ۲۰۱۱). 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^۷ (۲۰۰۵)، بیانکو و همکاران^۸ (۲۰۰۹)، آزاده و همکاران (۲۰۱۰) و همچنین عصاره و همکاران^۹ (۲۰۱۰) اشاره کرد.

۴-۳- نرخ شهرنشینی

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 حامل‌های انرژی می‌باشند. ولی مناطق روستایی در این زمینه‌ها دارای مزیت کمتری هستند. در مناطق روستایی نحوه دسترسی به سوخت و الگوی مصرفی متفاوت است. از این رو رشد شهرنشینی نیز عامل دیگری

1. Ang (1988)

2. Lin (2003)

3. Amarawickrama and Hunt (2007)

4. Dilaver and Hunt (2011)

5. Yu et al (2012b)

6. Shuvra (2011)

7. Mohamed and Bodger (2005)

8. Bianco et al (2009)


9. Assareh et al (2010)

است که باعث تشدید تقاضای انرژی خواهد شد (یو و همکاران، ۲۰۱۲). لذا نرخ شهرنشینی (سهم جمعیت شهری از کل جمعیت) نیز می‌تواند به عنوان یک عامل تأثیرگذار بر رشد مصرف انرژی در نظر گرفته شود.

۴-۴- ساختار اقتصاد

ساختار اقتصاد نیز یکی از عوامل مؤثر بر مصرف انرژی می‌باشد. در ایران به دلیل فراوانی نسبی منابع انرژی، شدت انرژی (میزان انرژی مصرفی برای تولید مقدار معینی از کالا و خدمات) در مقایسه با سایر کشورها بالاتر است (آرمن و زارع، ۱۳۸۴). 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 به خصوص صنایع این کشور شده و لذا بخش صنعت ایران کارآیی 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 (فضل‌زاده و تجویدی، ۱۳۸۷).

نمودار ۱ نشان دهنده افزایش شدت انرژی^۱ همراه با افزایش سهم بخش صنعت در اقتصاد می‌باشد که این امر بر اثر برنامه‌های توسعه اقتصادی و برخورداری از رانت انرژی در این کشور بوده است. از این رو سهم ارزش افزوده‌ی بخش صنعت در تولید ناخالص داخلی به عنوان معیاری برای تأثیر ساختار اقتصادی بر مصرف انرژی در این مطالعه استفاده شده است.^۲



نمودار ۱: پراکنش متقابل شدت انرژی و سهم بخش صنعت در اقتصاد

منبع: یافته‌های تحقیق


^۱ نسبت مصرف کل انرژی (معادل ده هزار بشکه نفت خام) به تولید ناخالص داخلی (میلیارد ریال به قیمت ثابت ۱۳۷۶).
^۲ داده‌های مورد نظر از بانک مرکزی و ترازنامه‌های انرژی استخراج شده است.

۴-۵- ساختار انرژی

کشور ایران دارای منابع عظیم نفتی در جهان بوده و یکی از اعضای مهم کشورهای تولید کننده 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 پیش رو دارد؛ تغییر الگوی مصرف انرژی یا جایگزینی سوخت‌های 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^۱، ۲۰۰۴). گاز طبیعی هم آسیب کمتری برای محیط زیست داشته و هم دارای قیمت ارزانی می‌باشد، همچنین گاز طبیعی در مقایسه با سوخت‌های فسیلی با در نظر گرفتن میزان آلودگی، یک سوخت پاک محسوب می‌شود. گاز طبیعی مزیت مهم دیگری نیز در مقایسه با سایر سوخت‌های فسیلی (از نظر محیط زیست و تکنیکی) دارد؛ این سوخت دارای ذرات معلق اندکی می‌باشد. این نقش زمانی برجسته‌تر خواهد بود که به مواد بسیار خطرناک یعنی ذرات آلوده ثانویه که در اثر سوخت‌های فسیلی ایجاد می‌شود توجه شود (پاسکویل و همکاران^۲، ۲۰۰۱). بنابراین در ایران نیز تولید گاز طبیعی با نرخ بالایی رشد یافته که هدف از آن ابتدا جایگزینی سوخت در بخش خانگی، تجاری و سپس بخش صنعتی و در نهایت تولید برق با استفاده از گاز طبیعی می‌باشد. از این رو سهم مصرف گاز طبیعی در سوخت‌های اولیه ایران از ۱۴٪ در سال ۱۳۵۵ به ۴۰٪ در سال ۱۳۷۷ افزایش یافت و تا جایی که در سال ۱۳۷۹ مصرف گاز طبیعی برای نخستین بار در تاریخ ایران بیشتر از فرآورده‌های نفتی شده است (مسرت، ۲۰۰۴). نمودار ۲ روند مصرف گاز طبیعی و فرآورده‌های نفتی را نشان می‌دهد. 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. با توجه به آنچه ذکر شد، سهم گاز طبیعی از کل مصرف انرژی به عنوان منعکس کننده ساختار انرژی نیز بر روند مصرف انرژی مؤثر خواهد بود.

^۱ Massarrat (2004)

^۲ Pascoli et al. (2001)



نمودار ۲: مقایسه روند مصرف فرآورده‌های نفتی و گاز طبیعی

منبع: (<http://nioc.ir>)

۴-۶- قیمت انرژی

با توجه به تئوری‌های اقتصادی، قیمت به عنوان یک عامل اولیه در تقاضا لحاظ شده و بر رفتار مصرف کننده تأثیرگذار است. همچنین به کمک قیمت اثر درآمدی و جانشینی استخراج می‌شود (یو و همکاران، ۲۰۱۲). یافتن شاخص قیمتی واحد برای یک حامل انرژی به دلایلی همچون تبعیض قیمتی امری ممکن ولی دشوار و همراه با تورش و ساده‌سازی می‌باشد. چنین مسائلی برای تقاضای کل انرژی یک کشور که در آن حامل‌های انرژی در بخش‌های مختلف اقتصادی به قیمت‌های متفاوتی به فروش می‌رسند بسیار عمیق‌تر خواهد بود. علاوه بر مسائل فوق دریافت کلی یارانه انرژی توسط مصرف کننده و تعیین دستوری قیمت انرژی از سوی دولت، یافتن شاخصی مناسب برای اندازه‌گیری قیمت کل انرژی که انعکاسی واقعی از موقعیت عرضه و تقاضا باشد را عملاً غیر ممکن می‌سازد. از سوی دیگر مطالعات مختلف در ایران نشان می‌دهد که کشش قیمتی تقاضای حامل‌های مختلف انرژی در کشور اندک و بعضاً بی‌معنی است (پژویان ۱۳۷۹)، مهرگان و همکاران (۱۳۸۸)، چگینی‌آشتیانی (۱۳۹۱)). با توجه به آنچه بیان شد و همان‌گونه که بررسی ادبیات تجربی نشان می‌دهد، در پیش‌بینی تقاضای بلندمدت کل انرژی کشور متغیر قیمت در مدلسازی لحاظ نمی‌شود.

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 (۱) در نظر گرفته می‌شود:

$$E = f(Gdp, Pop, Urb, ECstr, ENstr) \quad (1)$$

در معادله فوق، E نشان‌دهنده‌ی تقاضای سالانه انرژی معادل میلیون بشکه نفت خام بوده که از ترازنامه‌های انرژی استخراج شده است و Gdp ، Pop ، Urb ، $ECstr$ و $ENstr$ به ترتیب نشان‌دهنده 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 از ترازنامه انرژی و اطلاعات سری زمانی بانک مرکزی^۱ استخراج شده‌اند.

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 غیر خطی بوده و به 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 غیر خطی است که در سال‌های اخیر به موازات پیشرفت‌های ابزار محاسبات و پردازش اطلاعات، از جایگاه پر اهمیتی 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 می‌توان ثابت کرد شبکه‌های عصبی پیشخور با یک لایه پنهان، تابع فعال‌سازی مناسب در لایه پنهان، تابع فعال‌سازی خطی در لایه خروجی و تعداد نرون‌های کافی در لایه پنهان، قادرند هر تابعی را با دقت دلخواه تقریب بزنند (کوان و وایت^۲، ۱۹۹۴). به همین علت به این نوع شبکه عصبی با چنین ساختاری، تقریب زننده جامع^۳ گفته می‌شود. بدین معنی که با تعداد کافی از نرون در لایه پنهان، شبکه تقریباً می‌تواند هر تابع خطی یا غیرخطی را با یک سطح دلخواه از دقت، تقریب بزند. 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

^۱. آمار جمعیت و نرخ شهرنشینی از داده‌های بانک جهانی استخراج شده است.

^۲. Kuan and White (1994)

^۳. Universal Approximator

(داده‌ها) با استفاده از تکنیک *Min-Max* استاندارد شده و به داده‌های نرمال در بازه $[-1, +1]$ تبدیل می‌شوند^۱ (نرمال‌سازی^۲).

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

در رابطه (۲)، 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.

پس از مرحله نرمال‌سازی، تصادفی نمودن^۳ 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 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^۴. تحقیقات مختلف نشان داده است که هر چه تعداد نمونه‌های آموزشی افزایش یابد، عملکرد شبکه در زمینه پیش‌بینی، بهبود می‌یابد (ژانگ و همکاران^۵، ۱۹۹۸).

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

^۱. به منظور نرمال‌سازی از تابع *mapminmax* در نرم افزار متلب استفاده می‌شود.

^۲. Normalizing

^۳. Randomizing

^۴. به منظور ایجاد شاخص‌های تصادفی جداسازی داده‌های آموزش و آزمون از تابع *dividerand* در نرم افزار متلب استفاده می‌شود.

^۵. Zhang et al. (1998)

در این مطالعه با توجه به محدودیت داده‌ها از ۸۰ درصد مشاهدات (۳۵ مشاهده) برای آموزش و ۲۰ درصد آن (۹ مشاهده) برای آزمون استفاده شده است. تعداد لایه‌های پنهان در کل مدل‌های ساخته شده در این مطالعه یک در نظر گرفته شده است که علت آن نیز گریز از اشکال بیش-آموزشی خطا است (فرجام‌نیا و همکاران، ۱۳۸۶). تعداد نرون‌های لایه پنهان نیز به پیشنهاد هکت نیلسن (۱۹۸۷)^۱ $2n + 1$ در نظر گرفته شده است که در آن n تعداد گره‌ها در لایه ورودی می‌باشد. همچنین در لایه پنهان از توابع فعال‌سازی تانژانت‌هذلولی^۲ و زیگموئید^۳ استفاده شده است. پس از تعیین ساختار شبکه و مجموعه ورودی‌های آن، شبکه برای آموزش آماده می‌شود. همان گونه که پیش‌تر اشاره شد در این مطالعه به منظور آموزش شبکه‌های عصبی با در نظر گرفتن محدودیت مشاهدات علاوه بر الگوریتم‌های رایج (LM , BP) از الگوریتم‌های تکاملی (PSO , RGA و $PSO-RGA$) نیز استفاده شده است.^۴

پارامترهای شناختی (C_1)، اجتماعی (C_2) و ضریب اینرسی (ω) در الگوریتم انبوه ذرات به کمک قواعد ارائه شده توسط کندی و ابرهارت (۱۹۹۵) تنظیم شده است:

$$\omega = \frac{2}{\left| 2 - \varphi - \sqrt{\varphi^2 - 4\varphi} \right|} \quad (۳)$$

$$\varphi = \varphi_1 + \varphi_2 > 4 \quad (۴)$$

$$c_1 = \omega \varphi_1 \quad (۵)$$

$$c_2 = \omega \varphi_2 \quad (۶)$$

که در این روابط پارامترهای φ_1 و φ_2 برابر با ۲/۰۵ می‌باشد. همچنین پارامترهای الگوریتم ژنتیک و نیز تعداد جمعیت و حداکثر تکرار فرایند یادگیری پس از تحلیل حساسیت به صورت جدول ۴ تعیین شد:

^۱. Hecht-Nielsen (1987)

^۲. Hyperbolic Tangent (Tanh) : $f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$


^۳. Sigmoid: $f(x) = \frac{1}{1 + e^{-x}}$

^۴. کلیه مراحل طراحی و آموزش شبکه‌های عصبی در محیط نرم افزار متلب انجام شده است.

جدول ۴: تنظیم پارامترهای الگوریتم

$pop^{GA} = 30$, $pop^{PSO} = 40$, $pop^{PSO-GA} = 30$	تعداد جمعیت
$p_m = 0/05$, $p_c = 0/8$	نرخ جهش و ادغام
1000	حداکثر تکرار فرایند یادگیری

در فرایند آموزش شبکه به منظور بهینه‌سازی اوزان ارتباطی میان نرون‌ها از داده‌های آموزش و معیار میانگین مربع خطا (MSE)^۱ استفاده شده و سپس به منظور انتخاب بهترین شبکه از معیار حداقل خطا در داده‌های آزمون استفاده شد. نمودار ۳ و نمودار ۴ هر یک به ترتیب فرآیند یادگیری شبکه بر اساس داده‌های آموزشی و داده‌های آزمون را برای کلیه شبکه‌ها نشان می‌دهد.^۲




نمودار ۳: روند یادگیری شبکه با استفاده از الگوریتم‌های مختلف بر اساس داده‌های آموزشی

منبع: یافته‌های تحقیق

^۱. Mean Squared Error: $(MSE) = \frac{\sum_1^n (\hat{Y}_t - Y_t)^2}{n}$

^۲. در این نمودارها جهت رویت و مقایسه بهتر نتایج از تبدیل لگاریتمی استفاده شده است.



نمودار ۴: روند یادگیری شبکه با استفاده از الگوریتم‌های مختلف بر اساس داده‌های آزمون

منبع: یافته‌های تحقیق

همان‌گونه که نتایج نمودار ۳ نشان می‌دهد روند یادگیری شبکه بر اساس الگوریتم‌های تکاملی بسیار بهتر از الگوریتم‌های BP و LM بوده و در انتهای فرآیند یادگیری خطای کمتری داشته‌اند. در این بین روند یادگیری الگوریتم ژنتیک با کدینگ حقیقی (RGA) بهتر از الگوریتم انبوه ذرات و روند یادگیری ترکیب این دو الگوریتم یعنی الگوریتم $PSO-RGA$ بهتر از روش‌های فردی می‌باشد. همچنین استفاده از نوع تابع فعال‌سازی - تانزانت هذلولی یا زیگموئید - تأثیری در این نتایج نداشته و کلیه نتایج بحث شده فارغ از نوع تابع فعال‌سازی تأیید می‌شود.

از سوی دیگر نمودار ۴ که روند یادگیری بر اساس داده‌های آزمون را نشان می‌دهد نیز ضمن تأیید نتایج نمودار ۳ نشان می‌دهد که الگوریتم‌های تکاملی با وجود کندی 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. نتایج این نمودار همچنین همانند نمودار ۳ نشان می‌دهد که در میان الگوریتم‌های تکاملی الگوریتم ژنتیک با کدینگ حقیقی عملکرد بهتری از الگوریتم انبوه ذرات داشته و از سوی دیگر الگوریتم ترکیبی ارائه شده ($PSO-RGA-NN$) خطای کمتری از کلیه روش‌ها دارد. همچنین مقایسه روند یادگیری بر اساس توابع فعال‌سازی در هر الگوریتم، نشان دهنده عملکرد بهتر شبکه با تابع فعال‌سازی تانزانت هذلولی در مقایسه با تابع سیگموئید می‌باشد.

۵-۱- ارزیابی کارایی پیش‌بینی

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^۱ بر روی خروجی هر شبکه اعمال شود تا خروجی آنان به داده‌هایی با مقیاس حقیقی برای قیاس با مقادیر مصرف واقعی انرژی تبدیل شود. برای این منظور از تابع (۷) استفاده شده است.

$$x_r = (x_n + 1) \times (x_{\max} - x_{\min}) / 2 + x_{\min} \quad (7)$$

به منظور بررسی عملکرد پیش‌بینی روش‌های گوناگون، تکنیک‌های مختلفی وجود دارد که متداول‌ترین آنان، میانگین مربع خطا (MSE)، مجذور میانگین مربع خطا ($RMSE$)^۲، میانگین قدرمطلق درصد خطا ($MAPE$)^۳ می‌باشند. به دلیل این که 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 ۵ و جدول ۶ نتیجه مقایسه کارایی بر اساس داده‌های آموزش و آزمون را نشان می‌دهد. نتایج این جداول به صورت ملموس‌تر و دقیق‌تری نمودار ۳ و نمودار ۴ را تشریح می‌کند. با دقت در 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.

از سوی دیگر این نتایج ضمن تأیید عملکرد بهتر $LM-NN$ در مقایسه با $BP-NN$ ، نشان‌دهنده‌ی قدرت پیش‌بینی بالاتر شبکه‌های عصبی مبتنی بر الگوریتم‌های تکاملی در مقایسه با الگوریتم‌های

1. Post-processing

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

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

پس انتشار خطا و لونبرگ - مارکوارت می‌باشد. همچنین مقایسه میان شبکه‌های عصبی مبتنی بر الگوریتم‌های تکاملی ضمن تأیید عملکرد بهتر *RGA-NN* در مقایسه با *PSO-NN*، بهبود قابل توجه نتایج پیش‌بینی در ترکیب این دو الگوریتم را نشان می‌دهد.

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

تابع فعال سازی <i>sigmoid</i>			تابع فعال سازی <i>tanh</i>			شبکه عصبی
<i>MSE</i>	<i>RMSE</i>	<i>MAPE</i>	<i>MSE</i>	<i>RMSE</i>	<i>MAPE</i>	
۷۱۱/۶۸۸۱	۲۶/۶۷۷۵	۰/۰۲۲۶	۴۹۹/۸۶۴۴	۲۲/۳۵۷۶	۰/۰۱۸۱	<i>BP-NN</i>
۳۱۸/۶۵۱۶	۱۵/۳۷۵۵	۰/۰۱۴۴	۲۲۵/۸۹۱۲	۱۲/۷۸۹۶	۰/۰۱۲۰	<i>LM-NN</i>
۶۰/۴۰۴۹	۷/۷۷۲۱	۰/۰۰۶۶	۵۸/۵۹۱۸	۶/۶۷۸۰	۰/۰۰۶۳	<i>PSO-NN</i>
۵۰/۲۷۷۸	۷/۰۹۰۷	۰/۰۰۵۸	۴۶/۱۵۸۴	۶/۷۹۴۰	۰/۰۰۵۲	<i>RGA-NN</i>
۲۱/۴۲۱۲	۴/۶۲۸۳	۰/۰۰۳۴	۱۶/۰۰۱۲	۴/۰۰۰۱	۰/۰۰۲۳	<i>PSO-RGA-NN</i>

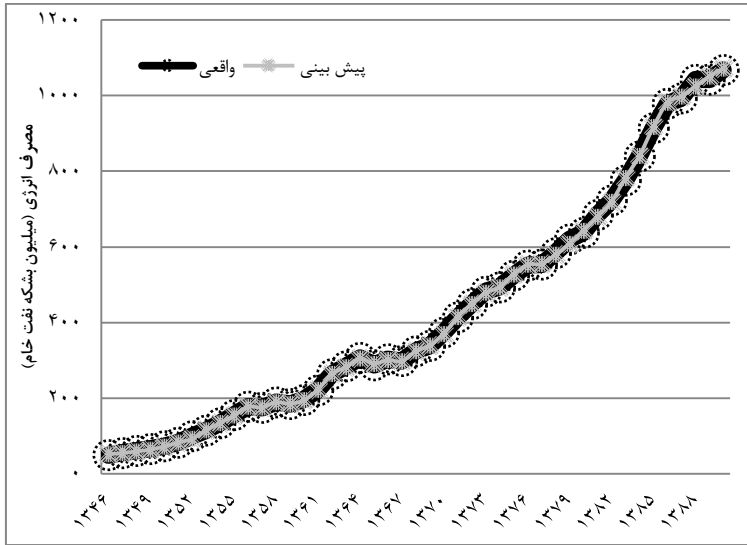
منبع: یافته‌های تحقیق

جدول ۶: مقایسه کارایی شبکه‌های عصبی پیش‌بینی کننده تقاضای انرژی (بر اساس داده‌های آزمون)

تابع فعال سازی <i>sigmoid</i>			تابع فعال سازی <i>tanh</i>			شبکه عصبی
<i>MSE</i>	<i>RMSE</i>	<i>MAPE</i>	<i>MSE</i>	<i>RMSE</i>	<i>MAPE</i>	
۹۹۷/۳۷۳۴	۳۱/۵۹۷۰	۰/۰۲۹۶	۶۲۸/۱۰۳۲	۲۵/۰۶۲۰	۰/۰۲۳۵	<i>BP-NN</i>
۳۲۴/۴۴۳۴	۸/۰۱۲۳	۰/۰۱۶۰	۱۵۱/۱۱۱۱	۱۲/۲۹۲۷	۰/۰۱۱۲	<i>LM-NN</i>
۶۰/۴۲۴۸	۷/۷۷۳۳	۰/۰۰۶۹	۵۳/۸۳۷۱	۷/۳۳۷۴	۰/۰۰۶۴	<i>PSO-NN</i>
۴۶/۸۱۷۸	۶/۸۴۲۴	۰/۰۰۵۹	۴۳/۷۹۷۹	۶/۶۱۸۰	۰/۰۰۵۶	<i>RGA-NN</i>
۳۱/۱۸۰۱	۵/۵۸۳۹	۰/۰۰۴۲	۲۵/۵۱۶۵	۵/۰۵۱۴	۰/۰۰۳۷	<i>PSO-RGA-NN</i>

منبع: یافته‌های تحقیق

همچنین نتایج فوق نشان می‌دهد؛ حداقل خطای پیش‌بینی در داده‌های آموزش و آزمون به ترتیب برابر با ۰/۲۳ و ۰/۳۷ درصد در *PSO-RGA-NN* با تابع فعال‌سازی تاثرات هذلولی می‌باشد. نمودار ۵ مقادیر واقعی و پیش‌بینی شده تقاضای انرژی بر اساس *PSO-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 بلندمدت و در شرایط محدودیت داده‌ها را نشان می‌دهد.



نمودار ۵: پیش‌بینی تقاضای انرژی بر اساس PSO-RGA-NN

منبع: یافته‌های تحقیق

در ادامه به منظور روشن تر شدن هرچه بهتر قدرت الگوریتم پیشنهادی این مطالعه با سایر روش‌ها، به مقایسه نتایج آنان با مطالعات دیگر در زمینه پیش‌بینی تقاضای انرژی پرداخته می‌شود. از آنجا که معیار میانگین قدر مطلق درصد خطا ($MAPE$) متأثر از واحد اندازه‌گیری نبوده و در این رویکرد بزرگ و کوچک بودن واحد اندازه‌گیری متغیرها بر نتیجه ارزیابی تأثیر ندارد (سوری، ۱۳۸۹)، از این معیار به منظور مقایسه نتایج مطالعات مختلف استفاده شده است (جدول ۷).

همان‌گونه که در جدول ۷ مشاهده می‌شود، بهترین کارایی پیش‌بینی مربوط به مطالعه یو و همکاران (۲۰۱۲) می‌باشد که حداقل معیار خطا در آن برابر با ۰/۵۴ درصد است. لذا مقایسه نتایج مطالعه حاضر با جدول ۷ برتری تکنیک پیشنهادی ترکیبی $PSO-RGA-NN$ با استفاده از هر دو تابع فعال‌سازی تانژانت هلالی و سیگموئید با خطای ۰/۳۷ و ۰/۴۲ درصد را تأیید می‌نماید. همچنین این نتایج نشان دهنده‌ی توضیح دهنده‌ی بالایی متغیرهای بکار رفته در مطالعات یو و همکاران و مطالعه حاضر در پیش‌بینی تقاضای انرژی می‌باشد.

جدول ۷: مقایسه نتایج مطالعات مختلف در حوزه پیش‌بینی تقاضای انرژی بر اساس داده‌های آزمون

معیار خطا (MAPE)	متغیر هدف (کشور)	روش	نویسنده (سال)
۰/۰۲۳۰	رگرسیون حداقل مربعات جزئی ^۱	انرژی بخش حمل‌ونقل (چین)	ژانگ و همکاران ^۱ (۲۰۰۹)
۰/۰۷۵	رگرسیون حداقل مربعات معمولی	انرژی بخش صنعت (ایران)	آزاده و همکاران ^۳ (۲۰۰۸)
۰/۰۰۹۹	شبکه‌های عصبی مصنوعی		
۰/۰۵۵۶	الگوریتم ژنتیک - مدل خطی	انرژی (ترکیه)	جیلان و اوزتورک ^۴ (۲۰۰۴)
۰/۰۶۱۶	الگوریتم ژنتیک - مدل نمایی		
۰/۰۸۳۷	الگوریتم ژنتیک - مدل خطی	انرژی بخش حمل‌ونقل (ترکیه)	هالدنبیلین و جیلان ^۵ (۲۰۰۵)
۰/۱۱۵۰	الگوریتم ژنتیک - مدل نمایی		
۰/۲۷۰۴	الگوریتم ژنتیک - مدل درجه دوم		
۰/۰۲۱۰	الگوریتم ژنتیک - مدل غیرخطی	نفت (ترکیه)	جانپورت و اوزتورک ^۶ (۲۰۰۸)
۰/۰۳۲۲		گاز طبیعی (ترکیه)	
۰/۰۲۹۷		زغال‌سنگ (ترکیه)	
۰/۰۱۳۶	الگوریتم ژنتیک - مدل خطی	انرژی الکتریکی (ایران)	امجدی و همکاران ^۷ (۲۰۱۰)
۰/۰۳۲۹	الگوریتم ژنتیک - مدل غیرخطی		
۰/۰۱۵۱	الگوریتم پرنگان - مدل خطی		
۰/۰۰۹۸	الگوریتم پرنگان - مدل غیرخطی		
۰/۰۱۰۷	الگوریتم کلونی مورچگان	انرژی (ترکیه)	توکساری ^۸ (۲۰۰۷)
۰/۰۰۸۳	الگوریتم پرنگان	انرژی (ترکیه)	آنلر ^۹ (۲۰۰۸)
۰/۲۰۲۳	برنامه نویسی ژنتیک	انرژی (چین)	لی و تانگ ^{۱۰} (۲۰۱۱)
۰/۲۷۷۶	رگرسیون خطی		
۰/۰۱۲۰	شبکه‌های عصبی	انرژی الکتریکی (ایران)	آزاده و همکاران ^{۱۱} (۲۰۰۸)
۰/۰۱۴۰	الگوریتم ژنتیک	انرژی الکتریکی (ایران)	آزاده و همکاران ^{۱۲} (۲۰۱۰)
۰/۰۱۵۶	شبکه‌های عصبی		
۰/۰۰۸۲	الگوریتم رگرسیون فازی		
۰/۰۰۹۳	الگوریتم پرنگان - ژنتیک - مدل خطی	انرژی (چین)	یو و همکاران ^{۱۳} (۲۰۱۲)
۰/۰۰۵۶	الگوریتم پرنگان - ژنتیک - مدل نمایی		
۰/۰۰۵۴	الگوریتم پرنگان - ژنتیک - مدل درجه دوم		

منبع: یو و همکاران (۲۰۱۲)

1. Zhang et al. (2009)
2. Partial least square regression
3. Azadeh et al. (2008a)
4. Ceylan and Ozturk (2004)
5. Haldenbilen and Ceylan (2005)
6. Canyurt and Ozturk (2008)
7. Amjadi et al. (2010)
8. Toksari (2007)
9. Unler (2008)
10. Lee and Tong (2011)
11. Azadeh et al. (2008a)
12. Azadeh et al. (2008b)
13. Yu et al. (2012b)

۶- سناریوسازی و پیش‌بینی روند آتی تقاضای انرژی

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 روی متخصصان آینده‌نگری، انتخاب محتمل‌ترین تصویر آینده را چندان درست نمی‌دانند، چرا که باید سناریوهای مختلفی را برای برنامه‌ریزی به کار برد (صادقی و همکاران، ۱۳۹۱). سناریوسازی ابزاری قدرتمند جهت توانمندسازی برنامه‌ریزان و مدیران در بررسی حالت‌های امکان‌پذیر آینده به‌شمار می‌رود (دای^۱، ۲۰۰۲). این تکنیک یکی از روش‌های کیفی آینده‌نگری است که بر طبق آن به ترسیم و تصوّر آینده ممکن پرداخته می‌شود. در حیطه انرژی شرکت نفتی شل از نخستین شرکت‌هایی است که با پیش‌بینی فروپاشی اتحاد جماهیر شوروی استفاده موفق و قابل ملاحظه‌ای از سناریوسازی داشته است. پیش‌بینی تقاضا نیز یکی از ضروریات مهم جهت تصمیم‌گیری و سیاست‌گذاری در حوزه انرژی محسوب می‌شود. از این رو در این مطالعه با استفاده از *PSO-RGA-NN* و بر اساس سناریو سازی تقاضای کل انرژی کشور تا سال ۱۴۰۴ (افق سند چشم‌انداز) پیش‌بینی می‌شود. بدین منظور ابتدا متغیرهای مستقل بر اساس سناریوسازی پیش‌بینی شده و سپس با جایگذاری آنان در شبکه عصبی آموزش دیده مقادیر آتی تقاضای انرژی پیش‌بینی می‌شود. در پیش‌بینی متغیرهای مستقل سناریوهای مختلفی را می‌توان در نظر گرفت، با این وجود جهت پرهیز از پیچیدگی در روند تصمیم‌گیری تنها به سه سناریو محتمل در جدول ۱۸ اکتفا شده است. سناریو B با نگاه به روند گذشته متغیرها ارائه شده و سناریو A با یک نگاه خوش‌بینانه و سناریو C با یک نگاه بدبینانه ارائه شده است.


جدول ۸: 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: فرضیات تحقیق

^۱. Dye (2002)

پس از پیش‌بینی روند آتی متغیرهای مستقل بر اساس سناریوهای فوق و جایگذاری آنان در شبکه نهایی، روند آتی تقاضای انرژی تا سال ۱۴۰۴ پیش‌بینی و در نمودار ۶ ارائه شده است. همان‌گونه که در نمودار ۶ ملاحظه می‌شود، سناریو A به صورت یک سناریو خوشبینانه در مورد روند رشد شاخص‌های اقتصادی - اجتماعی میزان تقاضای انرژی در سال ۱۴۰۴ را معادل ۱۸۱۷/۹۸ میلیون بشکه نفت خام پیش‌بینی می‌کند و سناریو C به صورت یک سناریو بدبینانه در مورد روند رشد شاخص‌های اقتصادی - اجتماعی میزان تقاضای انرژی در این سال را معادل ۱۴۵۷/۲۳ میلیون بشکه نفت خام پیش‌بینی می‌کند. سناریو B که به صورت یک سناریو بینابین و با نگاه به روند گذشته متغیرهای مستقل ارائه شده است، روند آتی تقاضای انرژی را بین دو سناریو A و B پیش‌بینی کرده و میزان تقاضای انرژی در سال ۱۴۰۴ را معادل ۱۶۴۳/۳۴ میلیون بشکه نفت خام نشان می‌دهد.



نمودار ۶: پیش‌بینی روند آتی تقاضای انرژی تا سال ۱۴۰۴

منبع: یافته‌های تحقیق

۷- نتیجه‌گیری

اهمیت مسائل انرژی به خصوص در بعد تقاضا بر کسی پوشیده نیست. امروزه مدیریت تقاضا از جمله تقاضای انرژی نقش مهمی در برنامه‌ریزی کشورها دارد و از سوی دیگر انرژی در تأمین امنیت اقتصادی نقش اساسی داشته و به عنوان یکی از عوامل اساسی در کلیه بخش‌های اقتصادی به صورت مستقیم یا غیر مستقیم در فرآیند تولید نقش دارد. همچنین با اجرای برنامه‌های توسعه و

روند صنعتی شدن کشور و ازدیاد جمعیت و متعاقب آن‌ها افزایش نیاز به حامل‌های انرژی پررنگ‌تر شده است. لذا هر گونه سیاست‌گذاری و تصمیم‌گیری در حوزه‌ی انرژی مستلزم بررسی روند تقاضای انرژی و عوامل موثر بر آن است. بنابراین مدل‌سازی تقاضای انرژی کشور و پیش‌بینی روند آتی آن در کنار دیگر سیاست‌های حاکم بر تقاضای انرژی می‌تواند نقش مؤثری در فرآیند تصمیم‌گیری‌های اقتصادی داشته باشد.

باتوجه به روند غیر خطی و پرنوسان تقاضای انرژی و متغیرهای اثرگذار بر آن، استفاده از تکنیک‌های غیر خطی در برآورد تقاضای انرژی ضروری به نظر می‌رسد. همین امر نیز منجر به استفاده از راه‌حلهایی هوشمند، همچون الگوریتم‌های تکاملی و شبکه‌های عصبی مصنوعی شده است که هر یک دارای مزایا و معایب خاص خود می‌باشند.

شبکه‌های عصبی از ابزارهای کارآمد در زمینه پیش‌بینی محسوب می‌شود که توانایی آن در یافتن روابط غیر خطی و پیچیده همواره در مطالعات مختلف مورد تأیید قرار گرفته است. علیرغم توجه و تأکید محققین به تکنیک‌های خطی و سستی که در آن با ساده‌سازی ارتباط پیچیده میان پدیده‌ها، به صورت خطی برآورد و تحلیل می‌شود و همچنین برخی کاستی‌های تکنیک‌های هوشمند در تصریح ضرایب و برآورد روابط علی و معلولی که مطلوب این محققین است، استفاده از تکنیک‌های هوشمند روز به روز مورد اقبال محققین در شاخه‌های مختلف علوم از جمله اقتصاد می‌باشد. تا جایی که ارائه پیش‌بینی دقیق‌تر تکنیک‌های هوشمند در مقایسه با روش‌های سستی در کنار علاقه محققین به پیش‌بینی حوادث آینده، موجب استفاده روزافزون از آن‌ها در مسائل اقتصادی و کاربردی همچون پیش‌بینی تقاضای انرژی شده است.

در این مطالعه به منظور مدل‌سازی و پیش‌بینی هرچه دقیق‌تر تقاضای انرژی در شرایط محدودیت داده‌ها از ترکیب این تکنیک‌ها استفاده شده است. رفع معایب تکنیک‌های فردی و استفاده از مزایای آنان در پیش‌بینی تقاضای انرژی نقطه قوت الگوریتم پیشنهادی این مطالعه می‌باشد. نتایج مطالعه نشان می‌دهد شبکه‌های عصبی مبتنی بر الگوریتم‌های تکاملی قدرت پیش‌بینی بالاتری از شبکه‌های عصبی مبتنی بر روش‌های کلاسیک یادگیری داشته است. مقایسه میان روش‌های کلاسیک یادگیری نیز نشان دهنده قدرت بالاتر الگوریتم لوبرگ-مارکوارت می‌باشد. در میان شبکه‌های عصبی مبتنی بر الگوریتم‌های تکاملی نیز شبکه عصبی مبتنی بر الگوریتم ترکیبی پیشنهادی (PSO-RGA-NN) دارای کمترین خطای پیش‌بینی در داده‌های آموزش و آزمون بوده و همچنین خطای پیش‌بینی شبکه عصبی مبتنی بر الگوریتم ژنتیک با کدینگ حقیقی (RGA-NN)

کمتر از شبکه عصبی مبتنی بر الگوریتم انبوه ذرات (*PSO-NN*) می‌باشد. افزایش دقت پیش‌بینی در استفاده از تابع فعال‌سازی تانژانت هذلولی دیگر یافته این پژوهش است. همچنین مقایسه یافته‌ها با نتایج سایر مطالعات ضمن تأیید قدرت توضیح دهنده‌گی بالای متغیرهای؛ تولید ناخالص داخلی، جمعیت، نرخ شهرنشینی، ساختار اقتصادی و ساختار انرژی، نشان دهنده قدرت پیش‌بینی بالاتر الگوریتم پیشنهادی در این مطالعه است.

با توجه به اهمیت پیش‌بینی صحیح تقاضای بلندمدت انرژی برای سیاست‌گذاری و مدیریت این حوزه، پس از اطمینان از قدرت الگوریتم پیشنهادی، تقاضای آتی انرژی تا افق سند چشم‌انداز ۲۰ ساله کشور بر اساس سناریوسازی پیش‌بینی شد که نتایج سناریو بینابین و محتمل میزان مصرف انرژی در سال ۱۴۰۴ را معادل ۱۶۴۳/۳۴ میلیون بشکه نفت خام نشان می‌دهد.

با توجه به نتایج تحقیق، استفاده از الگوریتم پیشنهادی به منظور پیش‌بینی دقیق‌تر تقاضای انرژی و توسعه سیاست‌های مختلف در بخش انرژی کشور پیشنهاد می‌گردد. همچنین پیشنهاد می‌شود از این تکنیک در مطالعات آتی به منظور پیش‌بینی حامل‌های انرژی در بخش‌های مختلف اقتصادی استفاده شود. با توجه به قدرت بالای پیش‌بینی تکنیک پیشنهادی، مقایسه این تکنیک با دیگر روش‌ها در پیش‌بینی سایر متغیرهای اقتصادی در مطالعات آتی نیز دست کم می‌تواند شاهدهی بر کارآمدی آن باشد.

منابع و مأخذ

الف) منابع و مأخذ فارسی

۱. ابراهیمی، محسن. و آل‌مراد جبدرفقی، 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، موسسه همایش صنعت.
۲. آرمن، سید عزیز. و زارع، روح‌الله (۱۳۸۴). "بررسی رابطه علیت گرنجری بین مصرف انرژی و رشد اقتصادی در ایران طی سال‌های ۱۳۴۶-۱۳۸۱". فصلنامه پژوهش‌های اقتصادی ایران ۲۴: ۱۱۷-۱۴۳.
۳. بغزیان، آلبرت. و نصرآبادی، ابراهیم (۱۳۸۵). "پیش‌بینی مصرف فرآورده‌های نفتی: مقایسه سیستم معادلات اقتصاد سنجی و شبکه‌های عصبی". فصل‌نامه مطالعات اقتصاد انرژی ۱۰: ۴۷-۶۷.
۴. بهبودی، داود. اصغرپور، حسین. و قزوینیان، محمدحسن (۱۳۸۷). "بررسی رابطه‌ی مصرف کل برق و رشد اقتصادی ایران (۱۳۸۵-۱۳۴۶)". فصلنامه‌ی مطالعات اقتصاد انرژی ۱۷: ۷۲-۵۷.
۵. پژویان، جمشید. و محمدی، تیمور (۱۳۷۹). "قیمت‌گذاری بهینه رمزی برای صنعت برق ایران". پژوهش‌های اقتصادی ایران ۶: ۳۹-۶۱.
۶. چگینی‌آشتیانی، علی. و جولوی، مهدی (۱۳۹۱). "برآورد تابع تقاضای برق و پیش‌بینی آن برای افق چشم‌انداز ۱۴۰۴ ایران و نقش آن در توسعه کشور با توجه به هدفمند شدن یارانه‌های انرژی". پژوهش‌های رشد و توسعه اقتصادی ۲(۷): ۱۹۱-۱۶۹.
۷. حیدری، ابراهیم (۱۳۸۴). "پیش‌بینی تقاضای انرژی در اقتصاد ایران بر اساس روش تجزیه". مجله تحقیقات اقتصادی ۶۹: ۵۶-۲۷.
۸. خانکشی‌زاده، محرم (۱۳۸۳). "پیش‌بینی بلند مدت تقاضای انرژی الکتریکی در منطقه آذربایجان با استفاده از شبکه عصبی". نوزدهمین کنفرانس بین‌المللی برق، ۲ تا ۴ آذر، تهران، شرکت توانیر.
۹. سهرابی‌وفا، حسین (۱۳۹۱). "پیش‌بینی تقاضای انرژی در ایران با استفاده از تکنیک‌های محاسبات نرم، پایان‌نامه کارشناسی ارشد، تهران، دانشگاه صنعت آب و برق (شهید عباسپور)".
۱۰. سهرابی‌وفا، حسین. صادقی، حسین. افضلیان، علی‌اکبر. و حقانی، محمود (۱۳۹۱). "مقایسه کارایی الگوی ARIMA و شبکه عصبی GMDH در پیش‌بینی تقاضای بلندمدت برق". بیست و هفتمین کنفرانس بین‌المللی برق، ۲۲ تا ۲۴ آبان، تهران، پژوهشگاه نیرو.
۱۱. سوری، علی (۱۳۸۹). "اقتصاد سنجی همراه با کاربرد نرم افزار Eviews7، تهران، نشر فرهنگ شناسی".
۱۲. صادقی حسین. ذوالفقاری، مهدی. و الهام‌نژاد، مجتبی (۱۳۹۰). "مقایسه عملکرد شبکه‌های عصبی و مدل ARIMA در مدلسازی و پیش‌بینی کوتاه مدت قیمت سبده نفت خام اوپک (با تاکید بر انتظارات تطبیقی)". فصل‌نامه‌ی مطالعات اقتصاد انرژی ۲۸: ۲۵-۴۷.

۱۳. 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 - ۵۶.
۱۴. صادقی، حسین. ذوالفقاری، مهدی. و حیدرزاده، محمد (۱۳۸۸). "نخمن تابع تقاضای بنزین در بخش حمل و نقل با استفاده از الگوریتم ژنتیک". فصلنامه مطالعات اقتصاد انرژی ۲۱: ۱-۲۷.
۱۵. 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: ۴۵-۶۰.
۱۶. فرجام‌نیا، ایمان. ناصری، محسن. و احمدی، سید محمد مهدی (۱۳۸۶). "پیش‌بینی قیمت نفت با دو روش ARIMA و شبکه‌های عصبی مصنوعی". فصلنامه پژوهش‌های اقتصادی ایران ۳۲: ۱۶۱-۱۸۳.
۱۷. 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: ۱۴۷-۱۶۲.
۱۸. قبری، علی. خضری، محسن. و اعظمی، آرش (۱۳۸۷). "شبیه‌سازی تابع تقاضای بنزین و نفت گاز در حمل و نقل زمینی ایران، با استفاده از روش الگوریتم ژنتیک". فصلنامه اقتصاد مقداری ۱۹: ۱۵۷-۱۷۷.
۱۹. ملکی، رضا (۱۳۸۳). "بررسی رابطه علیت بین مصرف انرژی و تولید داخلی در ایران". مجله برنامه و بودجه ۸۹: ۸۱-۱۲۱.
۲۰. مهرگان، نادر. حقانی، محمود. و کرامت‌فر، مهدی (۱۳۹۱). "آیا افزایش قیمت انرژی تهدید جدی برای صادرات صنعتی در ایران محسوب می‌شود". فصلنامه پژوهش‌ها و سیاست‌های اقتصادی ۶۲: ۷۲-۹۴.
۲۱. مهرگان، نادر. محمدی، سارا. و حقانی، محمود (۱۳۸۸). "تجزیه و تحلیل تغییرات مصرف برق در بخش کشاورزی". ششمین کنفرانس اقتصاد کشاورزی ایران، ۱۴ تا ۱۵ بهمن، کرج، پردیس کشاورزی و منابع طبیعی دانشگاه تهران.
۲۲. مهناج، محمد باقر (۱۳۸۴). مبانی شبکه‌های عصبی (هوش محاسباتی)، دانشگاه صنعتی امیرکبیر، تهران.
۲۳. مهناج، محمدباقر. کاظمی، عالیه. شکوری گنجوی، حامد. مهرگان، محمدرضا. و تقی‌زاده، محمد (۱۳۸۹). "پیش‌بینی تقاضای انرژی بخش حمل و نقل با استفاده از شبکه عصبی: مطالعه موردی در ایران". پژوهش‌های مدیریت در ایران ۲: ۲۰۳-۲۲۰.
۲۴. موسوی، سید نعمت‌اله. مختاری، زینب. و فرج‌زاده، ذکریا (۱۳۸۹). "پیش‌بینی مصرف حامل‌های انرژی در بخش کشاورزی ایران با الگوهای ARCH و ARIMA". فصل‌نامه‌ی مطالعات اقتصاد انرژی ۲۷: ۱۸۱-۱۹۵.

(ب) منابع و مآخذ لاتین

1. Abdel-Kader, R.F. (2011). "Hybrid Discrete PSO with GA Operators for Efficient QoS-multicast Routing". Ain Shams Engineering Journal 2: 21-31.
2. 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 University of Surrey.
3. Amjadi MH, Nezamabadi-pour H, and MM. Farsangi (2010). "Estimation of Electricity Demand of Iran Using two Heuristic Algorithms". Energy Convers Manage 51: 493-7.
4. Andonie R. (2010). "Extreme Data Mining: Inference from Small Datasets". International Journal of Computers Communications & Control 5: 280-291.
5. 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.
6. Angeline, P. (1998). "Evolutionary Optimization Versus Particle Swarm Optimization". Philosophy And Performance Differences: 601-610.
7. Assareh, E., Behrang, M.A., Assari, M.R., 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.
8. Azadeh A, Ghaderi SF, and S. Sohrabkhani (2008a). "Annual Electricity Consumption Forecasting by Neural Network in High Energy Consuming Industrial Sectors". Energy Convers Manage 49: 2272-8.
9. Azadeh A, Ghaderi SF, and S. Sohrabkhani (2008b). "A Simulated-based Neural Network Algorithm for Forecasting Electrical Energy Consumption in Iran". Energy Policy 36: 2637-2644.
10. 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.
11. Azadeh A, Saberio M, and O Seraj (2010). "An Integrated Fuzzy Regression Algorithm for Energy Consumption Estimation with Non-stationary Data: a Case Study of Iran". Energy 35: 2351-2366.
12. 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.
13. Azadeh, A., Saberi, M., Nadimi, I. and V.M.A Behrooznia (2010). "An Integrated Intelligent Neuro-Fuzzy Algorithm for Long-Term Electricity

Consumption: Cases of Selected EU Countries". Acta Polytechnica Hungarica 7: 71-90.

14. 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.

15. Bhattacharyya, S. C. and G.R. Timilsina (2009). "Energy Demand Models for Policy Formulation". Policy ReseaRch WoRking, paper: 4866.

16. Bianco, V., Manca, O. and S. Nardini (2009). "Electricity Consumption Forecasting in Italy Using Linear Regression Models". Energy 34: 1413-1421.

17. Canyurt O. and H.K. Ozturk (2008). "Application of Genetic Algorithm (GA) Technique on Demand Estimation of Fossil Fuels in Turkey". Energy Policy 36: 2562-9.

18. 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.

19. Ceylan H, and H.K.Ozturk (2004). "Estimating Energy Demand of Turkey Based on Economic Indicators Using Genetic Algorithm Approach". Energy Convers Manage 45: 2525-37.

20. 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, University of Surrey.

21. Dye, L. D. (2002). "Using Scenario Planning as an Aid in Project Portfolio Management". Proceedings of the Project Management Institute Annual Seminars & Symposium, October 3-10, San Antonio, Texas, USA.

22. Eberhart, R., and Y. Shi (1998). "Comparison between genetic algorithms and particle swarm optimization". In: *Porto VW*, Saravanan N, Waagen D & Eiben AE (eds.)

23. Ferguson, R., Wilkinson, W. and R. Hill (2000). "Electricity Use and Economic Development". Energy Policy 28: 923-934.

24. 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.

25. Geem, Z.W. (2011). "Transport energy demand modeling of South Korea using artificial neural network". Energy Policy 39: 4644-4650.

26. Grimaldi, E.A., Grimacia, F., Mussetta, M., Pirinoli, P. and R.E. Zich (2004). "A New Hybrid Genetical—Swarm Algorithm for Electromagnetic Optimization". in *Proceedings of International Conference on Computational Electromagnetics and its Applications*: 157-160.

27. Haldenbilen, S. and H. Ceylan (2005). "Genetic Algorithm Approach to Estimate Transport Energy Demand in Turkey". Energy Policy 33: 89-98.

28. HECHT-NIELSEN, R. (1987). "Kolmogorov's Mapping Neural Network Existence Theorem". In *IEEE First Annual International Conference on Neural Networks*, **3**: 11–13.
29. Hourri Jafari, H., and A. Baratimalayeri (2008). "The Crisis of Gasoline Consumption in the Iran's Transportation Sector". *Energy Policy* **36**: 2536-2543.
30. Huang, C., and C. Moraga (2004). "A Diffusion-Neural-Network for Learning from Small Samples". *International Journal of Approximate Reasoning* **35**: 137-161.
31. Katsunari S. and I. Yusuke (2009). "Effect of Number of Hidden Neurons on Learning in Large-Scale Layered Neural Networks". *ICCAS-SICE* 18-21 Aug 2009, Fukuoka, 5008 – 5013.
32. Kennedy, J., and R. Eberhart (1995). "Particle Swarm Optimization. In: Neural Networks". *IEEE International Conference on Proceedings*: **4**: 1942-1948
33. 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.
34. Kuan, C.M., and H. White (1994). "Artificial Neural Networks: An Econometric Perspective". *Econometric Reviews* **13**: 1-91.
35. Lee YS, and LL. Tong (2011). "Forecasting Energy Consumption Using a Grey Model Improved by Incorporating Genetic Programming". *Energy Convers Manage* **52**:147–152.
36. 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.
37. Lin, B. Q. (2003). "Electricity Demand in the People's Republic of China". *ERD Working Paper Series* No.37. Economics and Research Department.
38. 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.
39. Mehrara, M. (2007). "Energy Consumption and Economic Growth: The Case of Oil Exporting Countries". *Energy Policy* **35**: 2939-2945.
40. Mohamed, Z. and P. Bodger (2005). "Forecasting Electricity Consumption in New Zealand using Economic and Demographic Variables". *Energy* **30**: 1833-1843.
41. Mohammadi, A and M. Jazaeri (2007). "A Hybrid Particle Swarm Optimization-Genetic Algorithm for Optimal Location of SVC Devices in Power System Planning". In *Proceedings of 42nd International Universities Power Engineering Conference* pp: 1175–1181.
42. Murat, Y.S., and H. Ceylan (2006). "Use of Artificial Neural Networks for Transport Energy Demand Modeling". *Energy Policy* **34**: 3165-3172.

43. 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.
44. Pao, H.T. (2009). "Forecasting Energy Consumption in Taiwan using Hybrid Nonlinear Models". Energy 34: 1438-1446.
45. Pascoli, S.D., Femia, A., Luzzati, T. (2001). "Natural Gas, Cars and the Environment. A (Relatively) 'Clean' and Cheap Fuel Looking for Users". Ecological Economics 38: 179-189.
46. Pindyck, R.S. (1979). *The structure of world energy demand*, The MIT Press Cambridge, Massachusetts.
47. Robinson, J., Sinton, S., and Y.R. Samii (2002). "Particle Swarm, Genetic Algorithm, and Their Hybrids: Optimization of a Profiled Corrugated Horn Antenna". in Proceedings of the IEEE International Symposium in Antennas and Propagation Society pp: 314-317.
48. 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.
49. Rosenberg, N. (1998). "The Role of Electricity in Industrial Development". The Energy Journal 19: 7-24.
50. Shuvra, M. A., Mostafijur R., Arshad A. and I.K. Shahidul (2011). "Modeling and Forecasting Demand for Electricity in Bangladesh Econometrics Model". International Conference on Economics, Trade and Development ipedr.7, iacsit press.
51. 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.
52. Suganthia, L., Samuel and Anand A (2012). "Energy Models for Demand Forecasting—A Review". Renewable and Sustainable Energy Reviews 16: 1223-1240.
53. Toksar MD. (2007). "Ant Colony Optimization Approach to Estimate Energy Demand of Turkey". Energy Policy 35: 3984-90.
54. 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.
55. Ünler, A. (2008). "Improvement of Energy Demand Forecasts using Swarm Intelligence: The Case of Turkey with Projections to 2025". Energy Policy 36: 1937-1944.
56. Wirl, F. and E. Szirucsek (1990). "Energy Modelling – a Survey of Related Topics". OPEC Review Autumn: 361-78.
57. Kao, Y.T. and Zahara, E.E. (2008). "A Hybrid Genetic Algorithm and Particle Swarm Optimization for Multimodal Functions". Applied Soft Computing 8: 849-857.

58. 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.
59. 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.
60. Zhang M, Mu H, Li G, and Y. Ning (2009). "Forecasting the Transport Energy Demand Based on PLSR Method in China". Energy 34:1396–400.
61. 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.