

بررسی کارایی مدل‌های نروفازی، شبکه عصبی و رگرسیون چندمتغیره در پیش‌بینی صرف انرژی کشور

حمید بابایی میبدی^{*}، محمدحسین طخاری مهرجردی^{**} و روح الله تقی‌زاده مهرجردی^{***}

تاریخ پذیرش: ۱۳۹۰/۱۲/۶

تاریخ دریافت: ۱۳۹۰/۴/۲۸

انرژی در کنار سایر عوامل تولید، عامل مؤثری در رشد و توسعه اقتصادی تلقی می‌شود و در عملکرد بخش‌های مختلف اقتصادی نقش چشمگیری ایفا می‌کند. از این‌رو، مسؤولان کشور باید تلاش کنند تا با پیش‌بینی دقیق‌تر مصرف انرژی و برنامه‌ریزی صحیح در هدایت مصرف، پارامترهای عرضه و تقاضای انرژی را به نحوی مطلوب کنترل کنند. هدف از این مقاله، بررسی کارایی مدل‌های نروفازی، شبکه عصبی و رگرسیون چندمتغیره در پیش‌بینی مصرف انرژی کشور است. مطالعه موردنی این تحقیق مربوط به انرژی مصرفی در بخش حمل و نقل ایران است. از این‌رو، برای بررسی حاضر، از داده‌های سالانه مصرف انرژی بخش حمل و نقل کشور، به عنوان متغیر خروجی مدل‌های پیش‌بینی و از داده‌های سالانه جمعیت کل کشور، تولید ناخالص داخلی و تعداد خودرو به عنوان متغیرهای ورودی مدل‌های پیش‌بینی استفاده شد. در پایان، نتایج پیش‌بینی مدل‌های مختلف با استفاده از شاخص‌های خطای استاندارد نسبی (RSE) و میانگین خطای (ME) و محدود میانگین مربعات خطای (RMSE) ارزیابی شدند. نتایج ارزیابی نشان داد که مدل نروفازی (ANFIS)، نسبت به سایر مدل‌ها دارای بالاترین دقت در پیش‌بینی مصرف انرژی کشور است.

. G17, C67, C53, C45, C15, C14, Q47 **JEL**

کلیدواژه‌ها: مصرف انرژی، رگرسیون چندمتغیره، شبکه‌های عصبی مصنوعی، نروفازی.

* کارشناس ارشد مدیریت صنعتی، دانشگاه یزد، پست الکترونیکی: Babaeimaybodihamid@yahoo.com

** کارشناس ارشد مدیریت صنعتی، جهاد دانشگاهی یزد، پست الکترونیکی: Hooseintahari@yahoo.com

*** داشجویی دکتری دانشگاه تهران و عضو هیأت علمی دانشگاه یزد، پست الکترونیکی: Rh.taghizadeh@yahoo.com

۱- مقدمه

انرژی عنصر حیاتی و اساسی تولید است که در اشکال مختلف از چوب و سوخت‌های فسیلی در پایین‌ترین سطح پالایش تا انرژی هسته‌ای در بالاترین سطح فرآوری در طبیعت وجود دارد.^۱ وابستگی روزافرون جوامع به انرژی، به دلیل جایگزینی نیروی ماشین به جای نیروی انسانی، سبب شده است که انرژی در کنار سایر عوامل تولید، عاملی مؤثر در رشد و توسعه اقتصادی تلقی شود و در عملکرد بخش‌های مختلف اقتصادی نقش چشمگیری ایفا کند.^۲

تأمین امنیت عرضه انرژی در دنیا از مسایل استراتژیک پیش روی تمام دولت‌ها است. در کنار محور مدیریت سمت عرضه انرژی، بخشی که کمتر از آن نامی به میان می‌آید، مدیریت سمت تقاضای انرژی است.

در کشور ما امروزه تلاش‌ها در جهت مدیریت سمت عرضه انرژی است و کمتر به مدیریت سمت تقاضای انرژی توجه می‌شود، در حالی که مدیریت تقاضای انرژی و تلاش برای استفاده بهینه از انرژی در تمام کشورهای پیشرفته دنیا از مهم‌ترین عوامل پیشرفت صنعتی پایدار بوده است.^۳ از این‌رو، مسؤولان کشور باید تلاش کنند تا با پیش‌بینی دقیق‌تر مصرف انرژی و برنامه‌ریزی صحیح در هدایت مصرف، پارامترهای عرضه و تقاضای انرژی را به‌ نحوی مطلوب کنترل کنند.

از گذشته و به خصوص در چند دهه گذشته پیش‌بینی وقایع و درک آینده زمینه پژوهش‌های بسیاری بوده است. برآمد این تلاش‌ها، روش‌های گوناگونی است که بیشتر برپایه مدل‌های آماری و اقتصادسنجی بنا شده‌اند. اگرچه روش‌های آماری و اقتصادسنجی در زمینه پیش‌بینی سری‌های زمانی عملکرد نسبتاً خوبی داشته‌اند، اما در عین حال، دارای محدودیت‌هایی نیز بوده‌اند؛ اول اینکه ممکن است در این گونه روش‌ها فرم تبعی متغیرهای مستقل و وابسته در صورت عدم شناخت کافی، به درستی تصویر نشود. دوم آنکه داده‌های پرت ممکن است به تخمين اریب پارامترهای مدل بینجامد و در نهایت، بیشتر مدل‌های سری زمانی، خطی بوده و بنابراین، در توضیح رفتارهای

۱- کاظمی و همکاران، ۱۳۸۴.

۲- فضل زاده و تجویدی، ۱۳۸۷، ۱۶۲-۱۴۷.

۳- میینی دهکردی و همکاران، ۱۳۸۸، ۲۹۱-۲۷۱.

غیرخطی ناتوان هستند^۱. در تحقیقات اخیر، از شبکه‌های عصبی مصنوعی^۲ به طور متداول به عنوان ابزار تقریبی غیرخطی استفاده شده است، به طوری که می‌توان با استفاده از آن بر مشکلات فوق فایق آمد. شبکه‌های عصبی می‌توانند روابط خطی و غیرخطی بین داده‌ها و ستاندها را براساس داده‌های آموزش تشخیص دهنده و روابط ریشه‌ای بین آنها را کشف کند و سپس، روابط کشف شده را به سایر داده‌ها تعمیم دهنده، به طوری که با طراحی مناسب معماری شبکه عصبی و انتخاب داده‌های آموزش مناسب، می‌توان به ساختاری دست یافته که توانایی پیش‌بینی سری‌های زمانی را داشته باشد. از طرفی، امروزه، در خصوص ایجاد مدل ترکیبی از منطق فازی و شبکه‌های عصبی برای عملکرد بهتر در سیستم‌های تصمیم‌گیری تلاش زیادی به عمل آمده است.^۳ شبکه‌های عصبی مصنوعی مبتنی بر الگوریتم پس از انتشار خطا دارای بعضی از مشکلات مانند ماندن شبکه در نقطه مینیمم محلی هستند و سرعت هم‌گرایی محاسبات اغلب پایین است که بر روایی و دقت مدل پیش‌بینی تأثیر می‌گذارد.

بنابراین، پژوهشگران این مقاله ترغیب شدند تا مبحث تئوری استدلال فازی را با شبکه‌های عصبی مصنوعی برای بهبود سرعت هم‌گرایی و دقت مدل پیش‌بینی ترکیب کنند. در این پژوهش، سعی بر آن است تا با استفاده از روش‌های نروفازی، شبکه عصبی مصنوعی و رگرسیون چندمتغیره، مصرف انرژی بخش حمل و نقل کشور پیش‌بینی شود تا در نهایت، بتوان میزان کارایی این روش را در پیش‌بینی مصرف انرژی مقایسه کرد.

۲- پیشینه پژوهش

استفاده از الگوهای جدید پیش‌بینی برای انواع حامل‌های انرژی در زمینه قیمت و مصرف آنها بیان کننده اهمیت قابل ملاحظه پیش‌بینی در حوزه انرژی بوده که در ادامه، به تحقیقاتی که در این زمینه انجام گرفته است، اشاره می‌شود.

احمدی قراچه (۱۳۸۵)، به پیش‌بینی ماهیانه قیمت نفت خام با استفاده از شبکه‌های عصبی به صورت تک متغیره پرداخت. او با مقایسه مدل خود با مدل‌های مختلف، چنین نتیجه‌گیری می‌کند که مدل او، مدل بهتری نسبت به مدل‌های ارایه شده قبلی است.

۱- ابریشمی، حمید و همکاران، ۱۳۸۹، صص ۱۷۱-۱۹۲.

2- Artificial Neural Networks (ANN)

3- Javadpour and Knapp, 2003, PP.323-330.

۴- آذر و افسر، ۱۳۸۵، صص ۵۲-۳۳.

۵۰ فصلنامه پژوهشنامه اقتصادی (رویکرد اسلامی- ایرانی) سال دوازدهم شماره ۴۶

ابریشمی و همکاران (۱۳۸۷)، از شبکه عصبی GMDH، برای پیش‌بینی قیمت گازوییل مبتنی بر قواعد، تحلیل تکنیکی، شامل میانگین‌های متحرک کوتاه‌مدت و بلند‌مدت، به عنوان ورودی شبکه، طی دوره‌های مختلف بازار، استفاده کردند. در این بررسی نیز پیش‌بینی‌های شبکه عصبی نسبت به روش سری زمانی، از خطای کمتر و دقت بالاتری برخوردار بود. شکل‌بینی و همکاران (۱۳۸۷)، سعی کردند علاوه بر پیش‌بینی تولید نفت خام در یازده کشور تولید‌کننده، با استفاده از دو مدل رگرسیون خطی و شبکه‌های عصبی، نتایج بدست آمده در هر کشور به طور مجزا مقایسه شود. تخمین‌ها، حاکی از آن است که شبکه‌های عصبی پیش‌بینی‌های بهتری نسبت به مدل‌های رگرسیون خطی ارایه می‌کنند.

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

پور کاظمی و اسدی (۱۳۸۸)، به پیش‌بینی پویایی قیمت نفت خام با استفاده از شبکه‌های عصبی مصنوعی و روش اقتصادسنجی ARIMA پرداختند. نتایج این پژوهش حاکی از آن بود که پیش‌بینی‌های شبکه عصبی در مقایسه با روش ARIMA از خطای کمتر برخوردار است.

منهاج و همکاران (۱۳۸۹)، با استفاده از شبکه‌های عصبی مصنوعی و با در نظر گرفتن شاخص‌های اقتصادی و اجتماعی، تقاضای انرژی بخش حمل و نقل کشور را در سال‌های ۱۳۸۶ تا ۱۴۰۰ پیش‌بینی کردند. در پژوهش آنها از شبکه‌های عصبی رو به جلو با ناظر برای پیش‌بینی و از الگوریتم پس انتشار برای آموزش شبکه‌ها استفاده شد. نتایج حاصل از پیش‌بینی با این روش در مقایسه با روش رگرسیون چندمتغیره، نشان‌دهنده خطای به مرتب کمتری است، به طوری که درصد میانگین قدر مطلق خطای ۱۵ درصد به ۶ درصد کاهش یافت.

صادقی و همکاران (۱۳۹۰)، با استفاده از شبکه عصبی مصنوعی مبتنی بر انتظارات قیمتی برای داده‌های روزانه، به مدل‌سازی و پیش‌بینی روزانه قیمت سبد نفت خام اوپک پرداختند و نتایج آن با مقادیر پیش‌بینی شده مدل ARIMA براساس معیارهای اندازه‌گیری دقت پیش‌بینی، مورد

مقایسه قرار گرفت. نتایج تحقیق نشان می‌دهد که شبکه عصبی مورد استفاده، نسبت به مدل ARIMA از قدرت پیش‌بینی بهتری برخوردار است.

کالگیرا (۲۰۰۰)، از تکنیک شبکه‌های عصبی مصنوعی برای پیش‌بینی میزان انرژی گرمایی مصرفی در ساختمان‌ها و پیش‌بینی مصرف انرژی در یک ساختمان خورشیدی غیرفعال استفاده کرد^۱. نصر و همکاران^۲ (۲۰۰۲) نیز با استفاده از شبکه‌های عصبی و الگوریتم پس انتشار به پیش‌بینی مصرف بنزین در کشور لبنان پرداختند. مورات و سیلان^۳ (۲۰۰۵)، با استفاده از یک شبکه عصبی سه لایه و الگوریتم پس انتشار انرژی بخش حمل و نقل کشور ترکیه را پیش‌بینی کردند. در بررسی آنها از شاخص‌های تولید ناخالص داخلی، جمعیت و تعداد خودرو در هر کیلومتر به عنوان ورودی‌های شبکه عصبی استفاده شده است.

سازن و همکاران^۴ (۲۰۰۷)، به منظور پیش‌بینی مصرف فرآورده‌های نفتی در ترکیه، یک مدل شبکه عصبی ارایه کردند. در پژوهش آنها سه مدل مختلف طراحی شد و در پایان، آنها با استفاده از معیارهای خطأ، یک مدل را به عنوان مدل مناسب برای پیش‌بینی مصرف فرآورده‌های نفتی در ترکیه انتخاب کردند. تحقیقات یو و همکاران^۵ (۲۰۰۸)، از جمله این مطالعات است که یافته‌های آنها حاکی از برتری شبکه عصبی بر خودرگرسیون می‌انگین متحرک در پیش‌بینی است.

به طور کلی می‌توان گفت استفاده از شبکه عصبی در پیش‌بینی قیمت حامل‌های انرژی، بیشتر مورد توجه بوده و دقت بالاتر آن نیز در مطالعات مقایسه‌ای مورد تأکید قرار گرفته است. همان‌طور که در مطالعات بالا مشاهده می‌شود، با توجه به اهمیت موضوع انرژی، مطالعات متعددی در زمینه پیش‌بینی قیمت و مصرف انرژی انجام گرفته است که هر یک از این مطالعات به بررسی و پیش‌بینی این موضوع با استفاده از روش خاصی پرداخته‌اند. این مطالعات به دو گروه تقسیم می‌شوند؛ مطالعاتی که با روش اقتصادسنجی انجام گرفته‌اند و مطالعاتی که با روش هوش مصنوعی و شبکه‌های عصبی انجام شده‌اند. در این تحقیق نیز سعی بر آن است تا با کاربست شبکه‌های عصبی فازی برای پیش‌بینی در حوزه انرژی، نتایج آن با الگوهای شبکه‌های عصبی و رگرسیون مقایسه شود تا کارایی روش پیشنهادی با سایر روش‌ها مورد مقایسه قرار گیرد.

1- Jebaraj. and Iniyab, 2006, PP. 281-311.

2- Nasr et al

3- Murat and Ceylan

4- Sozen

5- Yu et al

۳- ادبیات تحقیق

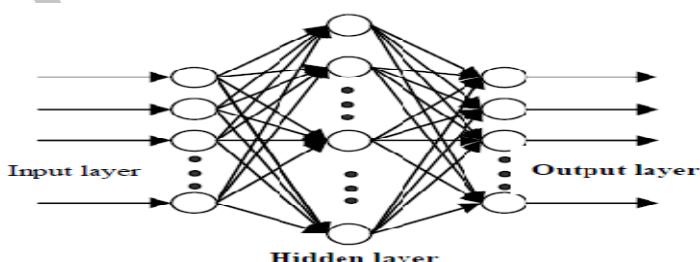
۱-۳- شبکه عصبی مصنوعی

شبکه عصبی مصنوعی یک روش شبیه‌سازی بوده که از مطالعه سیستم مغز و شبکه عصبی موجودات زنده الهام گرفته است. قدرت بالای عملکرد سیستم‌های بیولوژیک ناشی از طبیعت موازی برنامه‌ریزی نرون‌های آنها است. یک شبکه عصبی مصنوعی این ساختار را با توزیع شبیه‌سازی در واحدهای پردازشگر کوچک و ساده به هم پیوسته (که نرون نامیده می‌شود) انجام می‌دهد. نقش اصلی یک نرون بیولوژیک عمل جمع و رودی‌های خود تا جایی است که مجموع ورودی‌های آن از حدی که به آن آستانه می‌گوییم تجاوز نکند و آنگاه تولید یک خروجی است^۱.

ایجاد یک شبکه عصبی خوب برای یک کاربرد خاص بسیار مهم است. ایجاد یک شبکه مطلوب، انتخاب یک معماری مناسب، تعداد لایه‌ها، تعداد واحدهای در هر لایه و ارتباط بین واحدهای انتخاب توابع تبدیل واحدهای میانه به واحدهای ستداده، طراحی الگوریتم آموزش، انتخاب وزن‌های اولیه و به شکل خاص و قانون توافق را دربر می‌گیرد^۲.

یکی از مداول ترین شبکه‌های عصبی مورد استفاده، شبکه عصبی پرسپترون چندلایه است (شکل شماره ۱). پرسپترون چندلایه یک ترکیب استاندارد از ورودی‌ها، واحدهای عصبی خطی و غیرخطی و خروجی‌ها است. خروجی تمام واحدهای پردازش از هر لایه به تمام واحدهای پردازش لایه بعدی انتقال داده می‌شود. واحدهای پردازش لایه ورودی همگی خطی هستند، اما در لایه مخفی از نرون‌ها باتابع تائزانت سیگموئید، هایپربولیک یا هرتابع غیرخطی و پیوسته مشتق‌پذیر دیگری می‌توان استفاده کرد. به طور معمول برای افزایش سرعت آموزش، نرون‌های لایه خروجی خطی انتخاب می‌شود.

شکل ۱- ساختار پرسپترون با یک لایه پنهان



۱- البرزی، ۱۳۸۰.

2- Gorr and Nagin, 1994, PP. 17-34.

مسئله اصلی در این شبکه‌ها تعیین تعداد لایه‌های پنهان و تعداد نرون‌های آنهاست که در این رابطه نظرات متفاوتی وجود دارد. تعداد گره‌های مخفی به این علت اهمیت دارد که گره‌های مخفی نقشی قابل توجه در خاصیت پیکربندی غیرخطی شبکه‌های عصبی دارند.^۱ در تعیین تعداد گره‌های ورودی استفاده از روش آزمون و خطا بیشترین کاربرد را دارد، اما به طور کلی تعداد نرون‌های لایه ورودی بیان‌کننده تعداد متغیرهای ورودی است.^۲ در این مورد، نیلسون (۱۹۸۷) ثابت کرد که شبکه‌های عصبی با یک لایه مخفی با تابع سیگموئید $f(x) = \frac{1}{1+e^x}$ در لایه میانی و تابع خطی در لایه خروجی قادر به تقریب تمام توابع موردنظر با هر درجه تقریب خواهد بود، مشروط به اینکه به اندازه کافی نرون در لایه مخفی وجود داشته باشد، این قضیه به تقریب‌ساز جهانی معروف است.

۲-۳- شبکه عصبی فازی^۳ (ANFIS)

اگرچه شبکه‌های عصبی مصنوعی و سیستم‌های فازی با یکدیگر از نظر ساختاری متفاوت هستند، اما اگر به موارد ضعف و قوت آنها نگریسته شود، مشاهده می‌شود که این دو سیستم دارای ماهیت مکمل نسبت به یکدیگرند. بنابراین، با ترکیب سیستم‌های فازی و شبکه‌های عصبی مصنوعی، قابلیت‌های یادگیری شبکه‌های عصبی وارد سیستم‌های فازی خواهد شد. مدل شبکه عصبی فازی نخستین بار توسط ژانگ در سال ۱۹۹۳ معرفی شد. شبکه عصبی فازی دارای ویژگی‌هایی از جمله: قدرت یادگیری، هزینه کردن، طبقه‌بندی، نوشتن و تدوین کردن است. همچنین دارای این مزیت بوده که اجازه استخراج قوانین فازی از داده‌های متعدد و تخصصی را می‌دهد و به گونه‌ای متناسب قوانین پایه و اساسی را می‌سازد. ساختار نرون فازی، مانند نرون فضای قطعی است با این تفاوت که همه یا بعضی از اجزا و پارامترهای آن در قالب منطق فازی بیان می‌شوند. برای تبدیل یک نرون معمولی به نرون فازی، راههای مختلفی وجود دارد که استفاده از هر کدام از آنها ما را به انواع مختلفی از نرون‌های فازی می‌رساند. مطالعات اخیر بیان‌کننده قدرت و توانایی شبکه عصبی فازی در مدل‌سازی فرآیندهای متعدد و مختلف است.

فرض کنید که سیستم استنتاج فازی دارای دو ورودی X و Y و یک خروجی Z است. آنگاه سیستم

1- Zhang, 2003, PP.159-175.

2- Malik and Nasereddin, 2006, PP.168-180.

3- Adaptive-Network-based Fuzzy Inference Systems

فازی مورد استفاده با دو قانون زیر است:

$$\text{قانون ۱} \rightarrow \text{if } x \text{ is } A_1, y \text{ is } B_1 \text{ then } F_1 = P_1 + q_1y + r_1$$

$$\text{قانون ۲} \rightarrow \text{if } x \text{ is } A_2, y \text{ is } B_2 \text{ then } F_2 = P_1 + q_2y + r_2$$

مدل شبکه عصبی فازی انتخاب شده شامل پنج لایه است.

لایه ۱: گرههای موجود در این لایه سریهای فازی در ارتباط با بخش مقدم قوانین فازی را ارایه می-دهند. این لایه دارای پارامترهایی است که موقعیت بخش مرکزی و اصلی هر سری فازی را کنترل می‌کند. در این مطالعه ازتابع عضویت گوسی برای تعیین درجات عضویت استفاده شده است.

لایه ۲: هر گره در این لایه موظف به محاسبه نتایج ورودی‌های خود است. خروجی لایه به صورت $2, W_i = M_{Ai}(x) \times M_{Bi}(y)$ $i = 1, 2$ تعریف می‌شود که در این رابطه M_{Ai} و M_{Bi} سری‌های به صورت فازی هستند که به ترتیب برای متغیرهای X و Y تعریف شده‌اند. در این لایه، مقدار فعال‌سازی قوانین خاص فازی مشخص می‌شود.

لایه ۳: در این لایه بخش نسبت درجه فعالیت مربوط به هر یک از قوانین فازی نرم‌مال می‌شدن. رابطه مربوط در این لایه بدین شرح است:

$$W_i^* = \frac{w_i}{w_1 + w_2} \quad i = 1, 2 \quad (1)$$

لایه ۴: گرههای موجود در این لایه دیگر به صورت تطبیق‌پذیر درآمده است و هر تابع موجود گره‌ها یک مدل درجه اول با پارامترهای حاصل ارایه می‌دهد. خروجی حاصل از این لایه به صورت زیر نشان داده می‌شود.

$$O \quad (2)$$

خروجی لایه سوم

سری پارامتری

لایه ۵: لایه پنجم، لایه خروجی بوده که در این لایه هر گره دیگر به مرحله تکمیل خود رسیده است و در این لایه خروجی، گرهی که با علامت \sum مشخص شده، خروجی کلی و نهایی را به عنوان حاصل جمع تمام ورودی‌ها محاسبه می‌کند.

$$O \quad (3)$$

برای بهینه کردن مدل شبکه عصبی فازی لازم است پارامترهای مقدماتی در لایه اول و پارامترهای حاصل در لایه چهارم تعریف شوند. پارامترهای لایه اول به عنوان بخش مرکزی و دامنه تابع عضویت مقدم مطرح می‌شوند. پارامترهای لایه چهارم با سری $\{p_i, q_i, r_i\}$ که متناظر با ضریب‌های حاصل از معادله تابع گوسی هستند، تعریف می‌شوند. همچنین الگوریتم آموزش هیبرید برای تعیین پارامترهای شبکه عصبی فازی پیشنهاد شده است. نحوه آموزش شبکه عصبی به صورت یادگیری با ناظر است. بنابراین، هدف آن است که با آموزش شبکه‌ها، توابع ناشناخته بیان شده توسط داده‌های آموزشی را دریافت کند و یاد بگیرد و بتواند متناسب با ارزش پارامترهای ورودی، خروجی را تعیین کند. به همین علت در ساختار شبکه عصبی فازی از الگوریتم آموزش هیبرید استفاده می‌شود.

۳- رگرسیون خطی چند گانه

رگرسیون یک روش آماری برای بررسی و مدل‌سازی رابطه بین متغیرهای است. این روش تقریباً در تمام رشته‌های علوم از جمله مهندسی، فیزیک، اقتصاد، مدیریت، علوم زیستی، کشاورزی و علوم اجتماعی استفاده می‌شود.

شکل کلی معادله رگرسیون کلاسیک به صورت رابطه ۴ است، در آن y متغیر خروجی، X متغیر ورودی و a ضرایب معادله محسوب می‌شود.

$$y = a + b_1x_1 + b_2x_2 + \dots + b_nx_n \quad (4)$$

به طور معمول از روش کمترین مربعات برای برآورد ضرایب رگرسیون خطی چند گانه استفاده می‌شود.

۴- شاخص‌های ارزیابی مدل‌ها

نتیجه پیش‌بینی مدل‌ها توسط شاخص‌های عملکرد مختلفی سنجیده می‌شود، زیرا هیچ گونه اجماع کلی روی بهترین معیار عملکرد برای ارزیابی مدل پیش‌بینی وجود ندارد. در این تحقیق، به منظور ارزیابی عملکرد مدل‌های شبکه عصبی فازی، شبکه عصبی مصنوعی و رگرسیون چندمتغیره از پارامترهای خطای استاندارد نسبی (RSE) و میانگین خطای (ME)، مجدور میانگین مربعات خطای (RMSE) که از روابط زیر قابل محاسبه هستند، استفاده شد.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Z_0 - Z_p)^2} \quad (5)$$

$$RSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (Z_o - Z_p)^2}}{Z_{ave}} \quad (6)$$

$$ME = \frac{1}{n} \sum (Z_o - Z_p) \quad (7)$$

$$RI = \left(\frac{RMSE_a - RMSE_b}{RMSE_a} \right) \times 100 \quad (8)$$

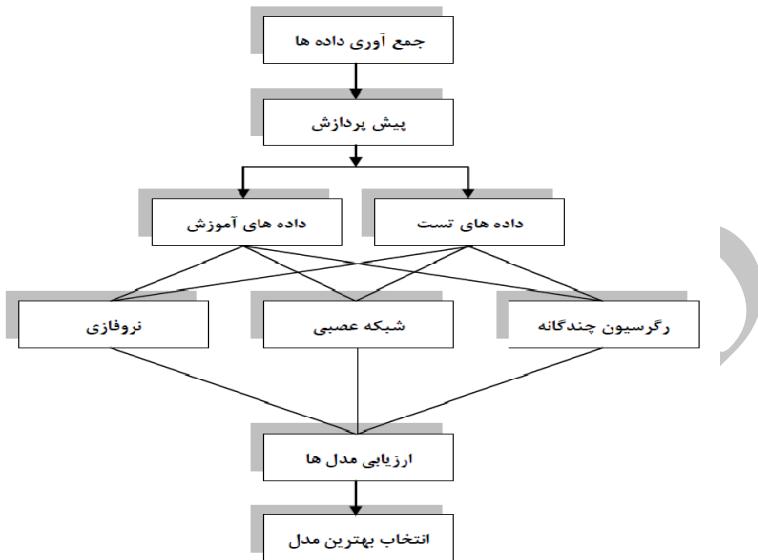
مقادیر پیش‌بینی شده، Z_p مقادیر مشاهداتی، Z_{ave} متوسط مقادیر مشاهداتی و n تعداد داده‌ها است.

۵- جمع آوری داده‌ها

از آنجا که شبکه‌های عصبی مصنوعی مبتنی بر داده هستند، آماده‌سازی داده‌ها یک گام مهم و در واقع، کلید موافقیت در استفاده از شبکه عصبی است. هر قدر تعداد داده‌ها بیشتر باشد، می‌توان در خصوص تقریب ساختار نهفته در مدل، اطمینان بیشتری حاصل کرد. در این تحقیق از داده‌های سالانه مصرف انرژی بخش حمل و نقل کشور (اعم از انرژی برق، گاز طبیعی و فرآورده‌های نفتی)، به عنوان متغیر خروجی مدل‌های پیش‌بینی و از داده‌های سالانه جمعیت کل کشور، تولید ناخالص داخلی و تعداد خودرو، به عنوان متغیرهای ورودی مدل‌های پیش‌بینی استفاده شد که بازه زمانی این متغیرها، از سال ۱۳۹۷ تا سال ۱۳۸۵ است. یادآوری می‌شود که داده‌های سالانه این متغیرها از منابع آماری وزارت نیرو و وزارت صنایع و معادن گردآوری شده است^۱ و تحلیل داده‌ها با استفاده نرم‌افزارهای Minitab و Neuro solution صورت گرفت. این تحقیق دارای چندین مرحله است که به صورت روندنا (شکل شماره ۲) ارایه شده است.

^۱- منهاج و همکاران، ۱۳۸۹، صص ۲۰۴-۲۲۰.

شکل ۲- روند انجام پژوهش



۶- نتایج

۶-۱- پیش پردازش

در این پژوهش در ابتدا، داده‌ها به دو دسته تقسیم شدند، به طوری که ۸۰ درصد داده‌ها برای آموزش و مابقی داده‌ها، یعنی ۲۰ درصد برای اعتبارسنجی اختصاص داده شد. برای این منظور دو دسته داده به‌طور تصادفی تعیین شد، به‌طوری که جدول شماره ۱، معیارهای آماری مربوط به داده‌های تست و آموزش را نشان می‌دهد.

جدول ۱- پارامترهای آماری داده‌های استفاده شده در مدل نروفازی، شبکه عصبی و رگرسیون چندمتغیره

پارامتر آماری	تعداد خودرو	جمعیت (هزار نفر)	تولید ناخالص داخلی (میلیارد ریال)	صرف نهایی انرژی بخش حمل و نقل (میلیون بشکه قت خام)
بیشترین	۸۸۱۹۳۶۶	۷۰۴۹۶	۴۴۶۸۸۰	۲۷۰/۴۱۴
کمترین	۱۹۲۵۴	۲۷۲۰۸	۹۹۰۰۱	۱۳/۳۸۲
میانگین	۲۷۶۶۲۸۱	۴۷۹۶۵/۴۵۲	۲۴۰۰۶۷/۷۷	۱۰۱/۸۲۲
انحراف معیار	۲۲۱۵۵۷۱/۹	۱۴۲۳۵/۲۰۸	۸۴۴۳۴/۵۳۸	۷۳/۲۰۴
بیشترین	۵۸۹۸۶۱۷	۶۷۳۱۵	۳۷۹۸۳۸	۲۲۰/۸۲۳
کمترین	۱۲۰۰۸	۲۹۴۸۴	۱۳۹۲۷۸	۱۹/۶۸۵
میانگین	۳۱۶۹۶۳۳/۹	۵۲۷۶۵/۷۵	۲۴۳۳۱۹/۸۸	۱۱۶/۴۹۷
انحراف معیار	۱۶۳۴۷۲۱/۹	۱۲۸۰۴/۰۸۳	۸۲۴۸۱/۰۹۳	۶۷/۱۰۹

۲-۶- نتایج رگرسیون چندمتغیره خطی

برای تعیین رگرسیون چندمتغیره پارامتر مورد مطالعه، رابطه رگرسیونی مربوط با استفاده از داده‌های آموزش تعیین شد (معادله ۹). سپس، این رابطه روی داده‌های آزمون اعمال شد و نتایج ریشه مربعات خطأ، خطای استاندارد نسبی، میانگین خطأ و ضریب تبیین به ترتیب $6/05$ ، $5/11$ و $0/993$ به دست آمد. مقادیر ضرایب رگرسیونی دارای عدد پی کوچک‌تر $0/01$ است، همچنین جدول تجزیه واریانس نیز برای رگرسیون محاسبه شد که نتایج از معنادار بودن معادله برآش داده شده حکایت دارد ($p < 0/01$). در نهایت، پراکنش مقادیر خطأ محاسبه شد که نشان‌دهنده صحت مدل رگرسیونی و فقدان هم راستایی در بین پارامترهای ورودی است (جدول شماره ۲). در معادله زیر X_1 : تعداد خودرو، X_2 : جمعیت، X_3 : تولید ناخالص داخلی و Y : مصرف نهایی انرژی بخش حمل و نقل کشور است.

$$y = -0/0826 + 0/290 X_1 + 0/313 X_2 + 0/483 X_3 \quad (9)$$

جدول ۲- نتایج تجزیه واریانس برای رگرسیون

منابع	درجه آزادی	مجموع مربعات	میانگین مربعات	اف فیشر	مقدار پی
رگرسیون	۳	۱/۵۳۱	۰/۵۱۰	۵۳۶/۷۵	<۰/۰۱
باقیمانده خطأ	۲۷	۰/۰۲۵	۰/۰۰۰۹۵		
کل	۳۰	۱/۵۵۷			

۳-۶- نتایج شبکه عصبی

در طراحی مدل شبکه عصبی، در واقع، باید اندازه مجموعه یادگیری و آزمایشی، نرمال کردن داده‌ها، تعداد لایه‌های پنهان شبکه، تعداد نرون‌های هر لایه، الگوریتم‌های یادگیری، تابع تبدیل، تابع عملکرد، نرخ یادگیری و تعداد تکرارها مشخص شود. در تعیین این موارد، روش‌های سیستماتیکی وجود ندارد، بنابراین، بهترین طراحی شبکه با استفاده از تجربه و آزمایش و خطابه دست می‌آید. در این پژوهش، پس از تعیین مجموعه داده‌های تست و آموزش، داده‌های ورودی به شبکه با استفاده از رابطه ۱۰ استانداردسازی شد. در صورتی که داده‌ها به صورت خام وارد شبکه شود، به علت تغییرات زیاد داده‌ها، تأثیر متفاوتی بر شبکه می‌گذارد، به طوری که برخی از نرون‌ها خیلی زود به حد آتش رسیده، در حالی که برخی دیگر از نرون‌ها حتی به آستانه فعالیت نیز نرسیده‌اند و این باعث خواهد شد که توان پیش‌بینی مدل پایین باید. از این‌رو، در ابتدا، داده‌ها با استفاده از رابطه زیر استاندارد می‌شود، یعنی بین یک دامنه عددی که به‌طور معمول ۰/۱ و ۰/۹ است، قرار گیرند.

$$y = 0.8 \times \frac{X_i - X_{min}}{X_{max} - X_{min}} + 0.1 \quad (10)$$

X_{min} کوچک‌ترین داده و X_{max} بزرگ‌ترین داده سری داده‌های ورودی هستند. با استفاده از این رابطه، داده‌های ورودی بین ۰/۱ و ۰/۹، قرار می‌گیرند.

در این تحقیق، شبکه با یک لایه مخفی دارای تابع فعال‌سازی سیگموئید $f(x) = \frac{1}{1+e^x}$ در لایه مخفی و تابع فعال‌سازی خطی در لایه خروجی بوده و تعداد نرون‌های آن از یک تا ۱۰ نرون متغیر است و بهترین تعداد نرون به صورت سعی و خطاب تعیین می‌شود. همچنین به علت کارایی، سادگی و سرعت بالا، در این تحقیق از الگوریتم آموزشی لوبرگ مارکوارت استفاده شد. برای پیش‌بینی مصرف انرژی، ورودی‌های شبکه، جمعیت، تعداد خودرو و تولید ناخالص داخلی بود. همچنین حداقل مقدار RMSE مربوط به شبکه با نه نرون در لایه مخفی است. تغییرات RMSE دارای روند مشخصی نیست، زیرا شبکه عصبی مدل جعبه سیاه است و وزن‌ها به‌طور تصادفی انتخاب می‌شوند، نمی‌توان این روند موجود را به‌طور کامل توضیح داد. تنها باید با سعی و خطابه بهترین ساختار را به‌دست آورد، اما توجیهی که می‌توان آورد این است که با پیچیده‌تر شدن مدل شبکه عصبی بیش از حد آموزش می‌بیند و قادر به برازش مناسب روی داده‌های جدید نیست.

۶-۴- نتایج شبکه عصبی فازی

در طراحی مدل شبکه‌های عصبی فازی این تحقیق، از شبکه عصبی چندلایه پیش‌خور، الگوریتم یادگیری پس انتشار خطأ و سیستم استنتاج فازی ساگو^۱ و تابع خروجی خطأ و برای غیرفازی کردن، از تابع میانگین وزنی استفاده شد. برای طراحی سیستم بهینه شبکه‌های عصبی فازی، از طریق تغییر مداوم تعداد لایه‌ها و تعداد نرون‌های لایه پنهان، توپولوژی مناسب شبکه عصبی بررسی و از طریق تغییر مداوم توابع عضویت مختلف و تعداد توابع عضویت، سیستم مناسب پایگاه استنتاج فازی طراحی شد.

این شبکه دارای ۲ تابع عضویت برای هر متغیر ورودی است و سایر پارامترهای آن عبارت‌اند از: تعداد مراحل آموزش = ۴۰، تولرانس خطأ = ۰، نرخ‌های یادگیری برای لایه اول و دوم = ۰/۰۵ و پارامترهای شبکه با استفاده از سعی و خطأ تعیین شد. در ضمن، ۸۰ درصد از داده‌ها به عنوان داده‌های آموزشی و ۲۰ درصد از داده‌ها به عنوان داده‌های آزمایشی و اعتبارسنجی انتخاب شدند.

جدول ۳- ویژگی‌های مدل ANFIS انتخابی برای پیش‌بینی

صرف انرژی بخش حمل و نقل	میانگین وزنی	هیبرید	مثالی	نکرار	نوع تابع عضویت	روش یادگیری	روش دفازی کردن	شرح
۲	۴۰							

۶-۵- ارزیابی مدل‌های پیش‌بینی

نتایج مربوط به مدل‌های نروفازی، شبکه‌های عصبی و رگرسیون چندمتغیره مربوط به پارامتر مورد اندازه‌گیری، در جدول‌های شماره ۴ و ۵ ارایه شده است. با توجه به این جدول‌ها، ملاحظه می‌شود، در کل بهترین عملکرد در پیش‌بینی ویژگی مورد مطالعه مربوط به مدل نروفازی است. از لحاظ هر چهار معیار بهتر از شبکه عصبی و رگرسیون چندمتغیره است. بعد از مدل ANFIS، شبکه عصبی مصنوعی پس انتشار بهترین عملکرد را به خود اختصاص داده است. همچنین نتایج نشان داد که در سطح ۵ درصد تفاوت معناداری بین مدل‌هایی که مصرف انرژی را تخمین زده‌اند، وجود ندارد. در چنین شرایطی، برای ارزیابی کارایی مدل‌ها می‌توان از شاخص RI استفاده کرد. این آماره نشان‌دهنده میزان کاهش خطأ در مدل‌های مختلف نسبت به روش رگرسیون است. همان‌طور که در

جدول شماره ۵، ارایه شده است، مدل نروفازی دقت پیش‌بینی را نسبت به روش رگرسیون خطی چند‌گانه برای مصرف انرژی به میزان ۵/۷۷ درصد افزایش داده است. همچنین آماره مثبت میانگین خطای نشان‌دهنده این است که تمام مدل‌ها مقداری بیش برآش داشته‌اند.

جدول ۴- مقادیر واقعی و پیش‌بینی شده مصرف انرژی به‌وسیله مدل‌های مختلف

ANFIS	ANN	REG	مقادیر واقعی	سال
۲۰/۱۶۲	۱۹/۸۴۷	۸/۶۱۳	۱۹/۶۸۵	۱۳۵۰
۵۵/۵۸۹	۵۷/۱۲۸	۵۷/۱۶۴	۵۳/۷۵۵	۱۳۶۰
۸۲/۳۴۶	۸۰/۷۱۶	۸۶/۴۶۲	۸۲/۷۹۴	۱۳۶۵
۸۴/۴۷۱	۸۲/۸۰۱	۸۸/۲۷۴	۸۶/۵۵۷	۱۳۶۶
۱۳۶/۰۸۳	۱۳۶/۰۹۹	۱۳۵/۹۵۵	۱۳۶/۹۷	۱۳۷۴
۱۶۲/۲۵۲	۱۶۳/۵۰۹	۱۵۷/۲۳۶	۱۶۱/۱۹۵	۱۳۷۷
۱۶۹/۴۴۲	۱۷۰/۲۹۵	۱۶۲/۶۲۹	۱۷۰/۱۹۶	۱۳۷۸
۲۲۵/۳۹۷	۲۲۶/۰۳۹	۲۱۲/۳۲۱	۲۲۰/۸۲۳	۱۳۸۲

جدول ۵- عملکرد مدل‌های مختلف در پیش‌بینی مصرف انرژی

	ANN	REG	ANFIS
RMSE	۲/۸۱	۶/۰۹	۱/۹۹
RSE	۰/۰۲۱	۰/۰۵	۰/۰۲
ME	۲/۲۳	۵/۱۱	۱/۵۱
RI	۵/۶۳	۰/۰۰	۵/۷۷

۷- نتیجه‌گیری

رشد و حتی بقای ییشتر فعالیت‌های اقتصادی کشورهای در حال توسعه به مسئله تأمین انرژی بستگی دارد. از این‌رو، مسؤولان این کشورها سعی می‌کنند با پیش‌بینی دقیق‌تر مصرف انرژی و برنامه‌ریزی صحیح در هدایت مصرف، پارامترهای عرضه و تقاضای انرژی را به‌ نحوی مطلوب کنترل کنند.

در این پژوهش، با استفاده از مدل‌های نروفازی، شبکه عصبی و رگرسیون چندمتغیره، مقادیر انرژی مصرفی در بخش حمل و نقل ایران برآورد شد. در مطالعه‌ای مشابه که بدین منظور صورت گرفته، از داده‌های سالانه مصرف انرژی بخش حمل و نقل کشور به‌عنوان متغیر خروجی مدل‌های پیش‌بینی و از داده‌های سالانه جمعیت کل کشور، تولید ناخالص داخلی و تعداد خودرو به‌عنوان متغیرهای ورودی

مدل‌های پیش‌بینی استفاده شده است.^۱ در نتیجه، در تحقیق حاضر از چنین پارامترهایی به عنوان ورودی و خروجی مدل‌ها استفاده شد. نتایج این بررسی نشان داد که در تمام شاخص‌های ارزیابی، شبکه‌های عصبی مصنوعی نسبت به معادلات رگرسیونی کارایی بهتر داشته است، به طوری که نتایج مطالعات گذشته انجام شده در حوزه پیش‌بینی قیمت و مصرف حامل‌های انرژی مانند احمدی قراچه (۱۳۸۵)، ابریشمی و همکاران (۱۳۸۷)، شکیبایی و همکاران (۱۳۸۷)، آذری و همکاران (۱۳۸۷)، پور کاظمی و اسدی (۱۳۸۸)، منهاج و همکاران (۱۳۸۹)، صادقی و همکاران (۱۳۹۰) و تحقیقات یو و همکاران (۲۰۰۸) دقت بیشتر مدل‌های شبکه عصبی را نسبت به مدل‌های رگرسیونی تأیید می‌کند. در این تحقیق نیز سعی شد تا با کاربرد شبکه‌های عصبی فازی برای پیش‌بینی در حوزه انرژی، نتایج آن با الگوی‌های شبکه‌های عصبی و رگرسیون مقایسه شود تا کارایی روش پیشنهادی با دیگر روش‌ها مورد مقایسه قرار گیرد. نتایج بررسی نشان داد که مدل نزوافازی بالاترین دقت را در پیش‌بینی مصرف انرژی دارد. بعد از این مدل، شبکه‌های عصبی مصنوعی نسبت به معادلات رگرسیونی پایه کارایی بهتری داشتند. در پایان، باید اذعان داشت که با توجه به ماهیت تقریبی بودن مقادیر و پارامترهای اندازه‌گیری شده، به نظر می‌رسد کارایی بالاتر مدل مبتنی بر مجموعه‌های فازی در پیش‌بینی مصرف انرژی به همین علت باشد. تحقیق حاضر، به بررسی کارایی مدل‌های یادشده در پیش‌بینی مصرف انرژی در بخش حمل و نقل ایران پرداخته است. پیشنهاد می‌شود در تحقیقات آتی به پیش‌بینی مصرف انرژی در سایر بخش‌های اقتصادی ترکیب شبکه‌های عصبی و الگوریتم ژنتیک برای پیش‌بینی مصرف انرژی، میزان دقت آن را با مدل‌های پیش‌بینی این تحقیق مقایسه کند.

منابع

الف- فارسی

آذر، عادل و امیر افسر (۱۳۸۵)، مدل‌سازی پیش‌بینی قیمت سهام با رویکرد شبکه‌های عصبی فازی، پژوهشنامه بازارگانی، شماره ۴۰.

آذری، احمد، مجتبی شریعتی نیاسر، محمود البرزی و افشنین بختیاری (۱۳۸۷)، برآورد میزان بارگاز مصرفی شهر تهران با استفاده از فناوری شبکه‌های عصبی، نشریه دانشکده فنی، دوره چهل و دوم، شماره ۸

۱- منهاج و همکاران، ۱۳۸۹.

ابریشمی، حمید، حجت‌الله غنیمی‌فرد، مهدی احراری و منیژه رضایی (۱۳۸۹)، پیش‌بینی قیمت گازویل خلیج فارس، مبتنی بر تحلیل تکنیکی و شبکه‌های عصبی، *فصلنامه مطالعات اقتصاد انرژی*، سال هفتم، شماره ۲۴.

احمدی قراچه، احسان (۱۳۸۵)، ارایه یک مدل شبکه عصبی مناسب برای پیش‌بینی قیمت نفت با در نظر گرفتن شوک‌های نفتی، *دانشگاه تربیت مدرس، پایان‌نامه کارشناسی ارشد*.

البرزی، محمود (۱۳۸۰)، آشنایی با شبکه عصبی، *انتشارات علمی شریف*. پور کاظمی، محمدحسین و محمدباقر اسدی (۱۳۸۸)، پیش‌بینی پویای قیمت نفت خام با استفاده از شبکه‌های عصبی مصنوعی و با به کار گیری ذخیره‌سازی‌های نفتی کشورهای OECD، *مجله تحقیقات اقتصادی*، دوره چهل و چهار، شماره ۸۸.

شکیایی، علیرضا، حسین نظام‌آبادی‌پور و سید جعفر حسینی (۱۳۸۸)، پیش‌بینی عرضه نفت خام در یازده کشور تولید‌کننده با استفاده از شبکه‌های عصبی و رگرسیون خطی، *مجله دانش و توسعه*، سال شانزدهم، شماره ۲۷.

صادقی، حسین، مهدی ذوالفقاری و مجتبی الهامی‌نژاد (۱۳۹۰)، مقایسه عملکرد شبکه‌های عصبی و مدل ARIMA در مدل‌سازی و پیش‌بینی کوتاه‌مدت قیمت سبد نفت خام اوپک (با تأکید بر انتظارات تطبیقی)، *فصلنامه مطالعات اقتصاد انرژی*، سال هشتم، شماره ۲۸.

فضل‌زاده، علیرضا و مینا تعویدی (۱۳۸۷)، مدیریت انرژی در صنایع ایران: مطالعه موردی: رابطه علی‌بین مقدار برق مصرفی و ارزش‌افزوده صنایع کوچک، *فصلنامه مطالعات اقتصاد انرژی*، سال پنجم، شماره ۱۹.

کاظمی، عالیه، محمدباقر منهاج، محمدرضا مهرگان و امین کامیاب مقدس (۱۳۸۴)، طراحی مدل رتبه‌بندی پالایشگاه‌های نفت کشور به روش تحلیل پوششی داده‌های فازی، اولین کنگره سیستم‌های فازی و خبره، *دانشگاه فردوسی مشهد*.

میینی دهکردی، علی، حامد حوری جعفری و عطیه حمیدی‌نژاد (۱۳۸۸)، بررسی وضعیت شاخص‌های مدیریت انرژی، *فصلنامه راهبرد*، سال هجدهم، شماره ۵۱.

منهاج، محمدباقر (۱۳۸۴)، *مبانی شبکه‌های عصبی، انتشارات دانشگاه صنعتی امیرکبیر*، چاپ سوم.

منهاج، محمدباقر، عالیه کاظمی، حامد شکوری گنجوی، محمدرضا مهرگان و محمدرضا تقیزاده (۱۳۸۹)، پیش‌بینی تقاضای انرژی بخش حمل و نقل با استفاده از شبکه‌های عصبی: مطالعه موردی در ایران، مجله مدرس علوم انسانی، دوره چهاردهم، شماره ۲.

ب- لاتین

- Gorr, W. L., & Nagin, D (1994), Comparative Study of Artificial Neural Network and Statistical Models for Predicting Student Grade Point Averages. International Journal of Forecasting, 10.
- Jang, J (1993), ANFIS: Adaptive-Network-based Fuzzy Inference Systems. IEEE Transactions on Systems, Man, and Cybernetics. 23.
- Jang, J., Sun, C., & Mizutani, E (1997), Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence, Prentice Hall, Upper Saddle River, New Jersey, USA.
- Javadpour, R and Knapp, GM, (2003), A Fuzzy Neural Network Approach to Machine Condition Monitoring, J Computers and Industrial Engineering, 45.
- Jebaraj, S. & Iniyanb, S (2006), A Review of Energy Model, Renewable and Sustainable Energy Reviews, 10.
- Malik, F; & Nasereddin, M (2006), Forecasting Output Using Oil Prices: A Cascaded Artificial Neural Network Approach, Journal of Economics and Business, 58.
- Murat, Y & Ceylan, H (2006), Use of Artificial Neural Networks for Transport Energy Demand Modeling, Energy Policy, 34.
- Nasr, G.E, Badr, E.A, & Joun, C (2003), Backpropagation Neural Networks for Modeling Gasoline Consumption, Energy Conversion and Management, 44.
- Sozen, A & Arcaklioglu, E (2007), Prediction of Net Energy Consumption Based on Economic Indicators (GNP and GDP) in Turkey, Energy Policy, 35.
- Yu, L., Wang, S. & Lai, K. K (2008), Forecasting Crude Oil Price with an EMD-Based Neural Network Ensemble Learning Paradigm. Energy Economics, 30.
- Zhang, G.P (2003), Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model, Neurocomputing, 50.
- Zhang, G., & Hu, M.Y (1998), Neural Network Forecasting of The British Pound/US Dollar Exchange Rate, Omega, The International Journal of Management Science, 26..