

طراحی روشی نوین برای پیش‌بینی تقاضای کوتاه مدت گاز طبیعی در بخش خانگی

حسین صادقی

استادیار دانشگاه تربیت مدرس sadeghiah@modares.ac.ir

مهدی ذوالفقاری

کارشناس ارشد اقتصاد انرژی دانشگاه صنعت آب و برق zolfaghari_mahdi@yahoo.com

تاریخ دریافت: ۸۸/۹/۲۴ تاریخ پذیرش: ۸۸/۱۱/۱۲

چکیده

در این پژوهش، با طراحی یک روش جدید که تلفیقی از مدل‌های خطی و غیرخطی است، به بررسی روند تقاضای روزانه‌ی گاز طبیعی کشور و عوامل مؤثر بر تقاضای روزانه‌ی این حامل پرداخته شد. در ادامه تقاضای روزانه‌ی گاز طبیعی در بخش خانگی براساس مدل‌های ARIMA، شبکه‌ی عصبی مصنوعی پیش‌خور، شبکه‌ی عصبی - تبدیل موجک و روش پیشنهادی، برای ۱۰ روز آینده به صورت "گام‌به‌گام (روز یکم تا روز دهم)"، پیش‌بینی شد. نتایج نشان داد که روش پیشنهادی نسبت به بقیه‌ی الگوها دارای خطای کم و دقت بالایی در پیش‌بینی تقاضای روزانه‌ی گاز طبیعی در بخش خانگی است. پس از روش پیشنهادی، شبکه‌ی عصبی - تبدیل موجک، شبکه‌ی عصبی پیش‌خور و فرآیند ARIMA، در اولویت‌های بعدی قرار گرفتند.

طبقه‌بندی JEL : C53, E37, Q30

کلید واژه: پیش‌بینی، تقاضای گاز طبیعی در بخش خانگی، تبدیل موجک، شبکه‌های ARIMA، عصبی

۱- مقدمه

امروزه انرژی گاز به دلیل دارا بودن مزایای فراوان به ویژه از نظر شاخص‌های زیست‌محیطی، مزیت عمده‌ای را نسبت به سایر حامل‌های انرژی دارد. هم‌چنین به دلیل ارتباط با سایر بخش‌ها و نهادهای اقتصادی (در قالب نهاده یا کالای نهایی)، نقش قابل توجه‌ای در فرایند تصمیم‌گیری‌های اقتصادی و پیشبرد اهداف توسعه‌ی کشورها ایفا می‌کند.

سیاست‌گذاران بخش‌های عرضه‌ی انرژی برای تأمین نیاز تقاضا شده از حامل‌های انرژی، نیازمند کسب اطلاعات و آگاهی از رفتار مصرف‌کنندگان این حامل‌ها هستند. با توجه به اهمیت راهبردی این حامل در میزان تقاضا شده، اطلاعات آکتسابی می‌باشد تا حد امکان دقیق و مطابق با واقعیت‌های آینده باشد. این اطلاعات می‌تواند بر اساس روند مشاهدات در دوره‌های زمانی گذشته، به دست آید. یکی از مزایای این روش، آگاهی از رفتار و تغییرات رفتاری متقارضیان در دوره‌های زمانی خاص می‌باشد، که احتساب این موارد در داده‌های پیش‌بینی شده‌ی آتی، مفید است، اما چگونگی در نظر گرفتن این داده‌ها، اهمیت‌گوهای پیش‌بینی را نمایان می‌کند. با توجه به این که بیش‌تر مدل‌های پیش‌بینی سری زمانی معرفی شده در مطالعات اقتصادی مانند ARMA^۱ و ARIMA^۲ به صورت خطی هستند، درنظر گرفتن نوسانات سری زمانی در این مدل‌ها با محدودیت‌هایی مواجه است. از سوی دیگر به موازات پیشرفت‌های قابل توجه در پردازش اطلاعات با روش‌های هوش مصنوعی، به کارگیری‌گوهای غیرخطی در حوزه‌ی پیش‌بینی، محدودیت‌های مذکور را تا حد قابل توجه‌ی کاهش داده است. اما الگوهای اخیر نیز در طول دوره‌ی زمانی، حالت تکاملی دارند و محدودیت‌های تحمیل شده بر آن‌ها که منتج به خطای پیش‌بینی می‌شود، به تدریج در حال کاهش است. از این‌رو در راستای این حرکت تکاملی، ارائه روشی جدید، منطقی و باکارایی بالاتر در پیش‌بینی، می‌تواند این حرکت را به جلو را به سمت حداقل کردن خطاهای احتمالی در حوزه‌ی پیش‌بینی شتاب بخشد. لذا ارائه‌ی روشی کارا برای پیش‌بینی تقاضای این حامل‌های انرژی با توجه به شرایط خاص کشور، از اهمیت ویژه‌ای برخوردار است. مهم‌ترین هدف این تحقیق ارائه‌ی یک چنین الگوی سازگار با شرایط کشور و از سوی دیگر امکان استفاده از این روش در پیش‌بینی سایر متغیرهای سری زمانی است.

1- gressive Integrated Moving AverageRe-Auto.

2- Auto-Regressive Moving Average.

در این راستا، روش‌های مختلفی برای پیش‌بینی متغیرهای سری زمانی معرفی شده‌اند. در حالت کلی روش‌های پیش‌بینی را می‌توان به دو دسته‌ی خطی و غیرخطی تقسیم‌بندی کرد. با این حال پرکاربردترین روش‌های پیش‌بینی خطی، روش‌های فرآیند خطی ARIMA و ARMA هستند. یکی از الگوهای غیرخطی که توانایی بالقوه خوبی برای پیش‌بینی سری‌های زمانی از خود نشان داده، شبکه‌های عصبی مصنوعی (ANN)^۱ است. شبکه‌های عصبی، تکنیک‌هایی هستند که به تقلید سیستم عصبی بیولوژیکی انسان می‌پردازند (مرزبان و همکاران، ۱۳۸۳).

از سوی دیگر به تازگی علاقه‌ی دوباره‌ی به گسترش‌های خطی سیگنال‌ها، به‌ویژه استفاده از موجک‌ها^۲ و تعمیمات آن‌ها پدیدار شده است (عباسی‌نژاد و محمدی، ۱۳۸۶ و بهرام‌مهر، ۱۳۸۷). تئوری موجک، یک ابزار ریاضی برای تجزیه‌ی سیگنال‌ها و نیز تکنیکی مفید برای نمایش آن‌ها در سطوح مختلف را ارائه می‌دهد. لیانگ و پیچ^۳ (۱۹۹۷)، نشان داده‌اند که چند نمایشی سیگنال‌ها، قدرت تعمیم‌دهی و توانایی شبکه‌ی عصبی در پیش‌بینی را تقویت می‌کند.

از نوآوری‌های مهم این تحقیق می‌توان به ارائه‌ی روشی جدید و منطقی (برای اولین بار) در مطالعات داخلی و خارجی، برای پیش‌بینی متغیرهای سری زمانی یاد کرده، که روش اقتصادسنجی (ARIMA) را با روش‌های غیرخطی شبکه‌ی عصبی و تبدیل موجک تلفیق می‌کند. هم‌چنین متغیرهای تاثیرگذار بر تقاضای روزانه‌ی گاز طبیعی در طراحی مدل درنظر گرفته می‌شود.

در بخش دوم، پیشینه‌ی تحقیق ارائه می‌شود. بخش سوم، به معرفی مبانی نظری شبکه‌های عصبی و تبدیل موجک به همراه مدل پیشنهادی می‌پردازد. در بخش چهارم، به مدل‌سازی و تخمین مدل‌های مذکور با استفاده از داده‌های روزانه‌ی تقاضای گاز طبیعی در بخش خانگی، برای دوره‌ی ۱۳۸۳/۱۱/۱ تا ۱۳۸۷/۱۱/۲۹ پرداخته می‌شود و تقاضای روزانه‌ی گاز طبیعی در بخش خانگی توسط مدل‌های مذکور در بازه‌ی زمانی یک گام تا ده گام به جلو، پیش‌بینی می‌شود. در بخش پنجم با به‌کارگیری معیارهای سنجش، به ارزیابی قدرت پیش‌بینی مدل‌های فوق پرداخته و در بخش ششم نتایج ارائه می‌گردد.

1- Artificial Neural Networks.

2- Wavelet.

3- Liang & Peach.

۲- پیشینه‌ی تحقیق

از دهه‌ی ۱۹۷۰ مطالعات نسبت‌آزادی در مورد برآورد تقاضای انرژی به طور اعم و گاز طبیعی به طور ویژه در کشورهای مختلف انجام گرفته است. بیشتر روش‌های مورد استفاده در این حوزه با استفاده از رویکرد نظام‌مند مبتنی بر نظریه‌ی مصرف‌کننده، انجام پذیرفته است. اولین مطالعات مربوط به تقاضای گاز طبیعی به اواسط دهه‌ی ۱۹۶۰ برمی‌گردد (مشیری و شاهمرادی، ۱۳۸۴). مطالعات بیشتر در این زمینه در دهه‌های ۱۹۷۰ و ۱۹۸۰ انجام گرفت و در دهه‌ی ۱۹۹۰ با افزایش تقاضای بین‌الملی برای گاز طبیعی و مطرح شدن آن به عنوان یک منبع انرژی تمیزتر و ارزان‌تر و با پیشرفت فناوری تبدیل گاز به صورت مختلف، مطالعات تقاضا گسترش بیشتری یافت. که از آن جمله می‌توان به مطالعه‌ی راتمن و همکارانش^۱ (۱۹۹۴) اشاره کرد که تقاضای انرژی در بخش خانگی (از جمله گاز طبیعی) را با استفاده از اطلاعات ۵۳ کشور که توسط پروژه‌ی مقایسه‌ی بین‌المللی سازمان ملل ارائه شد، برآورد کرد. مطالعه‌ی مذکور با استفاده از نظام تقاضای ترانسلوگ^۲، نظام تقاضای تقریباً ایده‌آل و نظام تقاضای لاجیت^۳ تعیین یافته، انجام گرفت.

مطالعات محدودی در زمینه‌ی پیش‌بینی تقاضای گاز طبیعی نسبت به سایر حامل‌های انرژی به ویژه با استفاده از روش‌های خطی انجام گرفته است که از جمله‌ی آن می‌توان به مطالعه‌ی ادیگر و آکار^۴ (۲۰۰۷) در پیش‌بینی تقاضا برای انواع حامل‌های انرژی ترکیه (از جمله گاز طبیعی)، اشاره کرد. آن‌ها در مطالعه‌ی خود از مدل ARIMA و مدل فصلی ARIMA (SARIMA) برای پیش‌بینی تقاضای انرژی ترکیه از ۲۰۰۵ تا ۲۰۲۰ بهره گرفتند. پیش‌بینی ARIMA از تقاضای انرژی کل، قابلیت اطمینان بالاتری نسبت به مجموعه‌ی تک تک پیش‌بینی‌ها از منابع انرژی داشته است. نتایج این مطالعه نشان داد که متوسط رشد سالیانه‌ی منابع انرژی و انرژی کل، در همه‌ی موارد به جز چوب و بیوماس، کاهش خواهد یافت و ضرایب رشد، منفی خواهند بود.

کاربرد شبکه‌های عصبی مصنوعی در مباحث اقتصادی از اواخر دهه‌ی ۸۰ با مطالعه‌ی وايت^۵ (۱۹۸۸) در بازارهای مالی و پیش‌بینی قیمت سهام شرکت IBM آغاز

1- Rothman et al.

2- Translog Demand.

3- Logit.

4- Edigera & Akar.

5- White.

شد. مؤقتیت شبکه‌های عصبی در مطالعات مربوط به حوزه‌های مالی، نظر متخصصان اقتصاد کلان و اقتصاد سنجی را به خود جلب کرد و مطالعات متعددی نیز در زمینه‌ی استفاده از شبکه‌های عصبی مصنوعی در پیش‌بینی متغیرهای مختلف اقتصاد انجام گرفت. به‌طور عمده، کاربرد شبکه‌های عصبی در مطالعات داخلی، مربوط به پیش‌بینی داده‌های مالی بوده است. در زمینه‌ی به‌کارگیری شبکه‌های عصبی مصنوعی در پیش‌بینی متغیرهای کلان نیز می‌توان به مطالعات قدیمی و مشیری (۱۳۸۱) در پیش‌بینی رشد اقتصادی در ایران، مشیری (۱۳۸۰) در پیش‌بینی تورم در ایران و مرزبان و همکاران (۱۳۸۴) در پیش‌بینی نرخ ارز اشاره کرد. در حوزه‌ی انرژی نیز می‌توان به مطالعات ابریشمی و همکاران (۱۳۸۷) در پیش‌بینی قیمت بنزین، زمانی (۱۳۸۴)، معینی و همکاران (۱۳۸۵) مهرآرا و همکاران (۱۳۸۵) در پیش‌بینی قیمت نفت خام و شرзе‌های و همکاران (۱۳۸۷) در پیش‌بینی تقاضای آب شهری اشاره داشت.

در سال‌های اخیر مطالعات مختلفی در زمینه‌ی استفاده از مدل‌های ترکیبی انجام گرفته است. از جمله مطالعاتی که در حوزه‌ی انرژی با استفاده از این مدل‌ها برای پیش‌بینی انجام گرفته است، می‌توان به کارهای رومرا و همکاران^۱ (۲۰۰۸) اشاره کرد که با به‌کارگیری یک مدل ترکیبی از شبکه‌ی عصبی مصنوعی و سری‌های فوريه، تقاضای ماهیانه‌ی برق اسپانیا را پیش‌بینی کردند.

بای و همکاران^۲ (۲۰۰۸)، با استفاده از یک مدل تلفیقی موجک-عصبی، به پیش‌بینی بار کوتاه مدت برق برای کویزلند در بازار برق استرالیا پرداختند.

کنجو و همکارانش^۳ (۲۰۰۵)، با استفاده از شبکه‌های عصبی و تبدیل موجک قیمت روز بعد برق را در بازار انرژی اسپانیا پیش‌بینی کردند. این تکنیک شامل تحلیل سری‌های زمانی، شبکه‌های عصبی و تبدیل موجک است. در میان روش‌های سری زمانی، روش‌های مورد نظر شامل ARIMA، رگرسیون پولیا و تابع انتقال هستند. رمضانی (۱۳۸۴)، با ترکیب مدل شبکه‌ی عصبی و ARIMA، به پیش‌بینی تقاضای ماهیانه‌ی برق کشور ایران برای دوره‌ی ۱۳۷۰-۸۱ پرداخت.

1 -Romera et al.

2- Bai et al.

3- Conejo et al.

شمبارا و روستیر^۱ (۲۰۰۵)، با استفاده از شبکه‌ی عصبی مصنوعی و میانگین متحرک‌های متناوب، به پیش‌بینی قیمت نفت خام در بازارهای آتی پرداختند. وانگ و همکاران^۲ (۲۰۰۵)، قیمت نفت خام را براساس ترکیبی از مدل‌های خطی و غیرخطی، که خود مدل TEL@I نامیدند، پیش‌بینی و عنوان کردند که این مدل بر پیش‌بینی با یک شبکه‌ی عصبی به تنها یی، برتری دارد.

در زمینه‌ی پیش‌بینی تقاضای گاز طبیعی، پورکاظمی و همکاران (۱۳۸۴)، به بررسی عملکرد شبکه‌های عصبی - فازی در پیش‌بینی تقاضای هفتگی گاز شهری - خانگی تهران پرداختند. نتایج این تحقیق بیانگر این مطلب بود که شبکه‌های عصبی - فازی در تمامی معیارهای ارزیابی عملکرد، بر روش ARIMA برتری داشتند. در مطالعه‌ی دیگری نیز آذری و همکاران (۱۳۸۷)، با استفاده از شبکه‌ی عصبی مصنوعی با الگوریتم پس انتشار خطا در پرسپترون چند لایه، میزان بار روزانه‌ی گاز مصرفی شهر تهران را برآورد کردند. مقایسه‌ی نتایج حاصل از پیش‌بینی با مقادیر واقعی مصرف گاز حاکی از آن است که الگوی طراحی شده، برای تخمین مصرف گاز شهر تهران مناسب است. در این زمینه مطالعه‌ی خارجی مبنی بر پیش‌بینی تقاضای گاز طبیعی یافت نشد. از مطالعه‌ی داخلی انجام گرفته در حوزه اقتصاد که از تکنیک تبدیل موجک استفاده شده، می‌توان به مطالعه‌ی عباسی نژاد و محمدی (۱۳۸۶) در زمینه‌ی پیش‌بینی نرخ‌های ارز (دلار، پوند، یورو، ین)، اشاره کرد. در این تحقیق، ابتدا نرخ‌های ارز اصلی که باید پیش‌بینی شود، با استفاده از تبدیل موجک به مؤلفه‌های مقایسه‌ی متفاوتی تجزیه شدند. در مرحله‌ی بعد، تکنیک شبکه‌های عصبی برای مدل‌سازی هر کدام از مؤلفه‌های سری زمانی به کار گرفته شد و پیش‌بینی نهایی سری‌های زمانی اصلی با ترکیب پیش‌بینی این مؤلفه‌ها بدست آمد. این روش برای پیش‌بینی یک گام به جلوی نرخ‌های ارز روزانه به کار گرفته شد. نتایج برآورد تبدیل موجک با نتایج شبکه‌های عصبی و ARIMA بر اساس معیار^۳ RMSE مورد مقایسه قرار گرفت. نتایج تحقیق نشان داد که در پیش‌بینی یک گام به طور عمدۀ شبکه‌ی عصبی بینه، در پیش‌بینی

1- Shambora & Rossiter.

2 -Wang et al.

3- Root Mean Square Error.

دو گام تا پنج گام به جلو روش ترکیبی شبکه‌ی عصبی و تبدیل موجک، بهینه بودند. در پیش‌بینی شش گام تا ده گام به جلو، شبکه‌ی عصبی، مدل بهینه است. بهزادمهر (۱۳۸۷) در مطالعه‌ای با استفاده از هموارسازی موجک و شبکه‌ی عصبی مصنوعی به پیش‌بینی روزانه قیمت نفت خام نیویورک و نفت خام خلیج مکزیک برای دوره‌ی ۲۰۰۰/۱/۴ تا ۲۰۰۰/۴/۹ پرداخت. در این مطالعه، در مدل ترکیبی از خاصیت هموارسازی تبدیل موجک برای کاهش سطح نویز داده‌ها استفاده شده و سپس بهوسیله‌ی شبکه‌ی عصبی مصنوعی و با داده‌های هموارسازی شده، قیمت نفت پیش‌بینی شد. نتایج حاصل از مقایسه‌ی RMSE مدل‌های رقیب با مدل ترکیبی مورد اشاره، دلالت بر آن دارد که کاهش نویز و هموارسازی داده‌ها، عملکرد پیش‌بینی قیمت نفت را بهبود می‌دهد.

به‌طور کلی مدل‌های غیرخطی و تلفیقی، به‌ویژه با محوریت شبکه‌های عصبی، چون عوامل بیش‌تری را در الگوسازی لحاظ می‌کنند، توانایی بالاتر و دقیق‌تری در پیش‌بینی قیمت نفت نسبت به مدل‌های رقیب دارند (بهزادمهر، ۱۳۸۷).

۲- مبانی نظری

در این بخش نخست به تشریح ساختار شبکه‌ی عصبی مصنوعی و ویژگی‌های آن پرداخته می‌شود. سپس تبدیل موجک و قابلیت‌های آن معرفی می‌شود. در نهایت روش پیشنهادی و ساختار آن ارائه می‌شود.

۳- شبکه‌های عصبی

شبکه‌های عصبی از دهه‌ی ۵۰ شناخته شده بودند، اما در اواسط دهه‌ی ۸۰ بود که الگوریتم‌ها و روش‌های مربوط به شبکه‌های عصبی مصنوعی به درجه‌ای از پیشرفت رسید که در حل مسائل واقعی از آن‌ها استفاده شد. در حقیقت شبکه‌ی عصبی مصنوعی مجموعه‌ای از نرون‌های به هم متصل در لایه‌های مختلف هستند، که اطلاعاتی را برای یکدیگر ارسال می‌کنند. به‌طور کلی نقش نرون‌ها در شبکه‌ی عصبی، پردازش اطلاعات است و این امر در شبکه‌ی عصبی مصنوعی به وسیله‌ی یک پردازشگر ریاضی که همان تابع فعال‌سازی است، انجام می‌گیرد. تابع فعال‌سازی می‌تواند خطی و یا غیرخطی باشد، که بر اساس نیاز خاص مسئله که قرار است بهوسیله‌ی شبکه‌ی عصبی حل شود از سوی

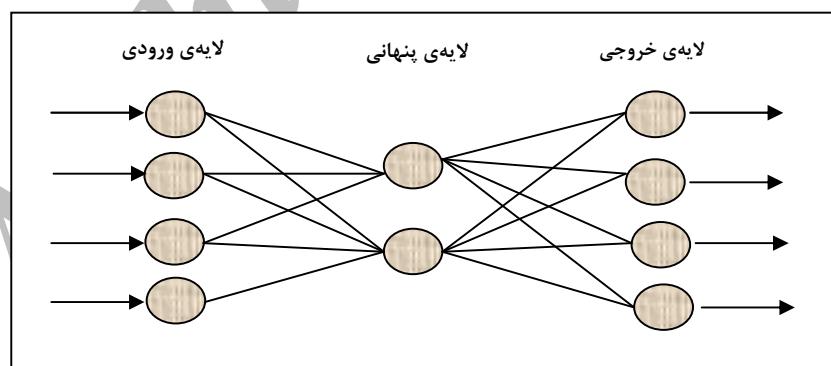
طرح انتخاب می‌شود. برای بهره برداری واقعی از توانایی شبکه‌ی عصبی، باید از توابع فعال‌سازی غیرخطی استفاده شود. این مسئله اجازه می‌دهد که شبکه، الگوهای غیرخطی مناسبی از مجموعه داده‌های پیچیده تولید کند. رایج‌ترین تابع فعال‌سازی مورد استفاده در ادبیات شبکه‌ی عصبی، تابع توزیع تجمعی لجستیک یا تابع سیگموئید است:

$$\varphi(x) = \frac{1}{1 + e^{-a(x)}} \quad (1)$$

این تابع پیوسته و مشتق پذیر است.

مقدار تابع لجستیک در محدوده [۰, ۱] قرار دارد، به‌گونه‌ای که وقتی تابع نزدیک به یک می‌شود، نرون نسبت به علائم دریافتی بسیار فعال عمل می‌کند و وقتی تابع به صفر نزدیک می‌شود، نرون به ندرت به علایم دریافتی واکنش نشان می‌دهد. دو نوع متفاوت از شبکه‌های عصبی تشخیص داده شده است؛ شبکه‌ی عصبی پیشخور، شبکه‌ی عصبی پسخور^۱

در مقاله‌ی حاضر، از شبکه‌ی عصبی پیشخور استفاده شده، که در آن یک شبکه‌ی عصبی نوعی، از لایه‌هایی تشکیل شده است. در یک شبکه‌ی دو لایه، یک لایه‌ی ورودی از منبع نرون‌ها و یک لایه‌ی خروجی از نرون‌ها وجود دارد. یک شبکه‌ی عصبی چند لایه، یک یا چند لایه‌ی پنهانی از نرون‌ها را نیز علاوه بر لایه‌ی ورودی و خروجی دارد. شکل (۱) نمایشی از شبکه‌ی عصبی ۳ لایه‌ای را نمایش می‌دهد.



شکل ۱- نمایش شبکه‌ی عصبی با ۳ لایه‌ی ورودی، پنهان و خروجی

- 1- Feed forward.
2- Recurrent.

ساختار شبکه‌ی عصبی نشان داده شده در شکل (۱) دارای یک لایه‌ی ورودی، یک لایه‌ی خروجی و یک لایه‌ی بین آن‌ها که مستقیماً به داده‌های ورودی و نتایج خروجی متصل نیست. در حقیقت این لایه را لایه‌ی مخفی یا پنهان^۱ می‌نامند.

لایه‌های مخفی اضافی توانایی شبکه را بالا می‌برند تا آمار بهتری از داده‌های ورودی استخراج کنیم. این موضوع یک کیفیت مهم است، به ویژه آن‌که یک لایه‌ی بزرگ ورودی وجود داشته باشد. اگر هر نرون در هر لایه‌ی شبکه به هر نرون دیگر در لایه‌ی همسایه جلویی متصل شده باشد، یک شبکه‌ی دارای اتصال کامل است.

در ادبیات شبکه‌ی عصبی به جای اصطلاح تخمین ضرایب، از اصطلاح یادگیری یا آموزش برای پیدا کردن ارزش وزن‌های شبکه استفاده می‌شود. دو نوع یادگیری در این ادبیات، مورد بحث قرار می‌گیرد: یادگیری تحت نظارت^۲ و یادگیری بدون نظارت^۳، در یادگیری بانظارت که به یادگیری با معلم نیز معروف است، ارزش‌های متغیر هدف که شبکه باید بر اساس ارزش‌های متغیرهای ورودی از طریق محاسباتش، آن‌ها را دوباره تولید کند، مشخص است، در نتیجه می‌توان خطای پیش‌بینی برای هر مشاهده را به وسیله‌ی محاسبه‌ی اختلاف خروجی شبکه با ارزش‌های متغیرهای هدف اندازه‌گیری کرد و سپس با استفاده از الگوریتم‌های مختلف تکرار، که مشهورترین آن‌ها الگوریتم پس انتشار خطاست^۴، وزن‌های شبکه تعديل می‌شود (اصطلاحاً شبکه‌ی آموزش داده می‌شود)، به گونه‌ای که خطای پیش‌بینی داخل نمونه که به وسیله‌ی مجموع مربعات خطای میانگین خطای مطلق اندازه‌گیری می‌شود، حداقل شود. وقتی که وزن‌ها با هر تکرار تغییر می‌کند، اصطلاحاً گفته می‌شود که شبکه در حال یادگیری است.

مهم‌ترین مزیت شبکه‌های عصبی، توانایی در یادگیری از داده‌های ورودی است، بنابراین پتانسیل عمومیت بخشیدن شبکه‌های عصبی به وجود می‌آید. به عبارت دیگر یک خروجی قابل قبول برای داده‌های ورودی دیده نشده‌ی قبلی، ایجاد می‌کند. اهمیت این موضوع در پیش‌بینی بسیار زیاد است. ارزش دیگر این شبکه، طبیعت غیرخطی بودن آن است. به این ترتیب تعداد زیادی از مسائل، قابلیت حل پیدا می‌کنند.

1- hidden layer.

2- Supervised Learning.

3- Unsupervised Learning.

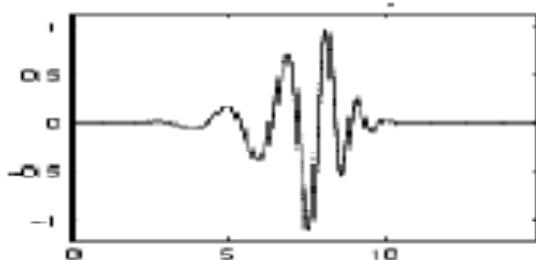
4- Error Back Propagation.

انعطاف‌پذیری و توانایی عمومیت بخشیدن بدون طرح فرضی لازم از مدل، از جمله مزایای دیگر آن است. شبکه‌ی عصبی پیشخور با یک لایه‌ی پنهان، تابع فعال ساز سیگموئید در لایه‌ی پنهان، تابع فعال ساز خطی در لایه‌ی خروجی و تعداد نرون‌های کافی در لایه‌ی پنهان، قادر است هر تابعی را با دقت دلخواه تقریب بزند^۱، به همین علت به این نوع شبکه‌ی عصبی با ساختار فوق، تقریب زننده‌ی جامع^۲ گفته می‌شود (اصغری اسکویی، ۱۳۸۱).

۲-۳- تبدیل موجک

^۳ موجک، در لغت به معنی یک موج کوچک است. یک تبدیل موجک دارای ویژگی‌های زیر است:

- تبدیل یک سیگنال به مجموعه‌ای از موجک‌ها
 - ایجاد و ارائه‌ی یک مسیر برای آنالیز کردن شکل موج‌های مختلف در دو حوزه‌ی زمان و فرکانس.
 - امکان ذخیره کردن سیگنال‌ها با بازدهی بسیار بهتر نسبت به تبدیل فوریه.
 - توانائی تقریب سیگنال‌ها با کیفیتی بسیار بهتر.
- موجک‌ها توابعی هستند که مقدار محدودی دارند و مقدار متوسط آن‌ها برابر صفر است. این موجک‌ها دارای انواع متعددی هستند. در شکل (۲)، یک موجک از خانواده‌ی دبوچی^۴ نشان داده شده است.



شکل ۲- یک موجک از خانواده‌ی دبوچی

1- Kuan & White.

2- Universal Approximator.

3- Wavelet.

4- Dubochis.

تبديل موجک پيوسته را می‌توان به صورت مجموع حاصل ضرب سيگنال اصلی در موجک‌های تغيير مقیاس يافته و انتقال داده شده در زمان نمايش داد.

$$C(s, \tau) = \int_{-\infty}^{\infty} f(t) \cdot \psi_{s, \tau}(t) dt \quad (2)$$

در رابطه‌ی بالا، $\psi_{s, \tau}(t)$ ، موجک مادر تغيير مقیاس يافته به اندازه‌ی s و انتقال يافته در زمان به اندازه τ است. نتيجه‌ی تبدل موجک پيوسته، ضرایب موجک C است که توابعی از مقیاس و ضریب جابه‌جایی می‌باشد. با ضرب کردن هر کدام از این ضرایب در موجک‌های مادر تغيير مقیاس يافته و جابه‌جا شده در زمان، می‌توان موجک‌های تشکیل دهنده‌ی سيگنال اصلی را به‌دست آورد.

سيگنال اصلی توسط توابع موجک تغيير مقیاس يافته که در طول زمان جابه‌جا می‌شوند، ضرب می‌شود و سپس از آن‌ها انتگرال‌گیری می‌شود. بنابراین با استفاده از تبدل موجک می‌توان یک سيگنال را به‌وسیله‌ی از مجموعه‌ای از توابع که از تغيير مقیاس و انتقال دادن یک تابع اصلی به‌نام موجک مادر به‌دست می‌آید به زیر سيگنال‌هایی تجزیه کرد.

در صورت استفاده از تبدل موجک پيوسته حجم اطلاعات بسیار زیاد می‌شود، چرا که بايستی برای مقیاس‌های مختلف (S مختلف) در طول زمان از سيگنال اصلی و تابع موجک، انتگرال‌گیری کرد. بنابراین حجم اطلاعات و محاسبات بسیار زیاد می‌شود، زیرا S به صورت پيوسته تغيير می‌کند، همچنین در برخی از موارد ممکن است به یک تابع غیرتحلیلی برخورد کنیم که امکان انتگرال‌گیری از آن وجود نداشته باشد و یا این که انتگرال جواب خاصی نداشته باشد، از این رو بهتر است که از تبدل موجک گستته استفاده شود. این تبدل ویژگی‌های بسیار مناسبی را ارائه می‌دهد که از جمله‌ی آن‌ها می‌توان به موارد زیر اشاره کرد:

- به اندازه‌ی کافی اطلاعات مورد نیاز را برای تحلیل و بررسی موج اصلی ارائه می‌دهد.

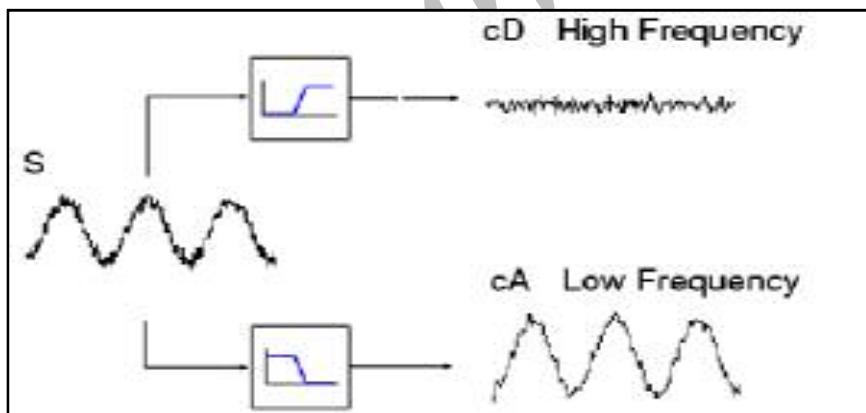
- مقدار محاسبات مورد نیاز را به مقدار بسیار مناسبی کاهش می‌دهد.
- می‌توان توسط آن سيگنال اصلی را در فرکانس‌های مختلف و با وضوح‌های کاملاً متفاوت بررسی و تحلیل کرد.

- می‌توان سیگنال اصلی را به سیگنال‌هایی با تقریب نه چندان خوب، ولی با اطلاعات بسیار خوب و مفید تجزیه کرد.

در تبدیل موجک گستته^۱، متغیرهای S و c که در حالت پیوسته، مقادیر پیوسته‌ای داشتند، در حالت گستته مقادیر گستته‌ای به خود می‌گیرند و پیاده‌سازی تبدیل به صورت ساده‌تری انجام می‌گیرد.

برای بیش‌تر سیگنال‌ها، مؤلفه‌های فرکانس پایین اهمیت بسیار زیادی دارند. این مؤلفه‌ها، مشخصات کلی سیگنال را مشخص و از سوی دیگر مؤلفه‌های فرکانس بالا، جزئیات ریز سیگنال را بیان می‌کنند.

در آنالیز موجک، معمولاً از تقریب^۲ سیگنال و جزئیات^۳ آن بحث می‌شود. تقریب سیگنال معمولاً از مقیاس‌های بزرگ و یا از مؤلفه‌های فرکانس پایین تشکیل می‌شود، ولی جزئیات سیگنال از مقیاس‌های کوچک و یا مؤلفه‌های فرکانس بالا تشکیل می‌شود. عملیات فیلتر کردن را به صورت کلی و ساده می‌توان به صورت شکل (۳) نمایش داد:



شکل ۳ - عملیات فیلتر نمودن یک سیگنال

به همین ترتیب می‌توان عملیات فیلترسازی را طی مراحل مختلفی انجام داد. مطابق آن‌چه که در شکل (۳) نشان داده شده است، می‌توان مؤلفه‌های فرکانس پائین را دوباره

1- Distinct Wavelet Transform.

2- Approx.

3- Details.

از دو فیلتر پایین گذر و بالا گذر عبور داد و ضرایب دیگری از تبدیل موجک گسسته در سطوح مختلف فرکانسی را به دست آورد.

۳-۳- روش پیشنهادی

ترکیب مدل‌های شبکه‌ی عصبی مصنوعی به عنوان یک مدل غیرخطی با مدل ARIMA به عنوان یک مدل خطی در پیش‌بینی سری‌های زمانی، عملکرد بهتری نسبت به پیش‌بینی انجام گرفته با استفاده از هر یک از مدل‌ها به تنها‌ی دارد (زانگ جی‌پتر^۱، ۲۰۰۳). از سویی تبدیل موجک، توانایی شبکه‌ی عصبی را در تجزیه و تحلیل و پیش‌بینی سری زمانی داده‌ها ارتقاء می‌بخشد(شانگوا کو و جیکونگ کو^۲، ۲۰۰۵)، لذا با نگاهی به مطالعات انجام گرفته در به کارگیری روش‌های تلفیقی که بین روش‌های شبکه‌های عصبی و مدل ARIMA و شبکه‌ی عصبی و تبدیل موجک انجام گرفته است، این ایده به وجود آمد که روشی طراحی شود که تلفیقی از مدل‌های ARIMA شبکه‌عصبی و تبدیل موجک است.

روش پیشنهادی اطلاعات مفیدی را از تاثیرگذاری رویدادهای مختلف بر روی سری زمانی ارائه می‌دهد. این روش، تلفیقی از مدل‌های ARIMA و تبدیل موجک به همراه شبکه‌های عصبی مصنوعی است.

در مرحله‌ی نخست با استفاده از موجک (از نوع دیوچی)، سری زمانی تا سطحی تجزیه می‌شود که سطح هموارشده(تقریبی) به صورت یک خط نسبتاً راست دربیاید و با در نظر گرفتن این نکته که ARIMA در پیش‌بینی سری‌های خطی قدرت بالایی دارد، این سری را به وسیله‌ی آن پیش‌بینی می‌کنیم. در مرحله‌ی بعد، با جمع کردن توابع جزئیات (مؤلفه‌ها) یک سری به دست می‌آوریم که روند زدایی شده است و فقط شامل نوسانات در طول دوره است. از آن جایی که:

سری اصلی = سری سطح هموار شده (تقریبی) + مجموع سری‌های توابع جزئیات (مؤلفه‌ها)
در مرحله‌ی بعد عوامل تاثیرگذار بر این نوسانات را تعیین می‌کنیم. با تعیین عوامل تاثیرگذار بر این نوسانات، آن‌ها را به عنوان متغیرهای توضیحی این نوسانات به عنوان

1- Zhang G Peter.

2 - Shuanghua Cao and Jiacong Cao.

ورودی به شبکه‌ی عصبی داده و مقدار مجموع توابع جزئیات را به عنوان خروجی آن تعیین می‌کنیم و در شبکه‌ی عصبی به طراحی و تخمین مدل در این زمینه می‌پردازیم. در مرحله‌ی نهایی، این نوسانات را به وسیله‌ی شبکه‌ی عصبی، با در نظر گرفتن عوامل تاثیرگذار برای آینده، پیش‌بینی کرده و آن را با مقادیر پیش‌بینی شده‌ی سری هموار شده توسط ARIMA جمع می‌کنیم. (وانگ و همکاران^۱ ۲۰۰۵)

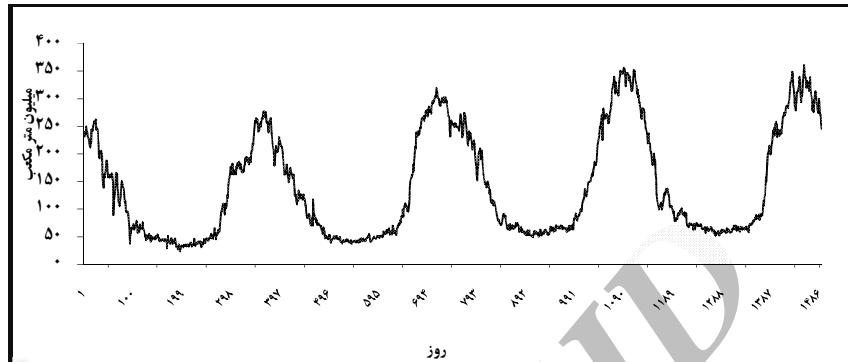
این روش دارای ۲ مزیت قابل توجه است، اولاً سه الگوی خطی و غیرخطی ARIMA، شبکه‌ی عصبی و تبدیل موجک را با هم تلفیق می‌کند که در این زمینه نقاط ضعف هر یک از الگوها در پیش‌بینی با نقاط قوت الگوی دیگری حذف یا کم رنگ‌تر می‌شود. ثانیاً این روش با درنظر گرفتن سری زمانی، عوامل تاثیرگذار بر روی این سری را نیز در مدل دخیل می‌کند، که قاعده‌ای می‌باشد قدرت پیش‌بینی سری زمانی را افزایش دهد.

۴- طراحی و تخمین الگوها

داده‌های مورد استفاده در این تحقیق آمار روزانه‌ی تقاضای گاز طبیعی کشور در بخش خانگی، استحصال شده از شرکت ملی گاز ایران، برای دوره‌ی ۱۳۸۳/۱۱/۱ تا ۱۳۸۷/۱۲/۹ هستند که در مجموع ۱۵۰۰ مشاهده را دربرمی‌گیرند. این داده‌ها از دو بخش تشکیل شده‌اند. نخست از تاریخ ۱۳۸۳/۱۱/۱ تا ۱۳۸۷/۱۱/۲۹ (۱۴۹۰ مشاهده) برای تخمین ARIMA، همین‌طور آموزش و مدل‌سازی شبکه‌ی عصبی مصنوعی و تبدیل موجک و بخش دوم از ۱۳۸۷/۱۱/۳۰ تا ۱۳۸۷/۱۱/۲۹ برای پیش‌بینی و مقایسه‌ی الگوهای مذکور مورد استفاده قرار می‌گیرد. همچنان داده‌های مربوط به دمای هوا و ساعت تاریکی از سازمان هواشناسی استحصال شده است.

نمودار (۱)، روند مصرف روزانه‌ی گاز طبیعی در بخش خانگی کشور را برای دوره ۱۳۸۳/۱۱/۱ تا ۱۳۸۷/۱۱/۲۹ نشان می‌دهد. در حالت کلی مصرف گاز طبیعی در بخش خانگی با توجه به روند سالیانه‌ی آن در حال افزایش است (به‌طور متوجه با رشد سالیانه‌ی ۱۱/۸ درصد)، تقاضای گاز طبیعی دارای نوسانات فصلی است، به‌صورتی که در ماه‌های سرد سال، تقاضا برای گاز طبیعی افزایش می‌یابد، که مهم‌ترین دلیل آن را

۱- Wang et al.



مأخذ: شرکت ملی گاز ایران

نمودار ۱- تقاضای روزانه‌ی گاز طبیعی در بخش خانگی (۱۳۸۷/۱۱/۲۹ تا ۱۳۸۳/۱۱/۰۱)

می‌توان استفاده از وسایل گرمایشی که انرژی زیادی مصرف می‌کنند، دانست. همچنان استفاده از این وسایل با توجه به طولانی بودن ساعتهای تاریکی و استمرار درجه‌ی دمای پایین هوا در این ساعات، افزایش می‌یابد. نوسانات روزانه تحت تأثیر ایام تعطیلات یا روزهای هفته قرار نمی‌گیرد. نکته‌ی دیگری که لازم است به آن اشاره شود، ذکر این مطلب است که نوسانات روزانه‌ی تقاضای گاز طبیعی در بخش خانگی در ماههای گرم به دلیل مصرف پایین، بسیار کم است و نظمی بر آن حاکم است، اما این نوسانات در ماههای سرد از یک نظم منطقی برخوردار نیست، که دلیل آن را می‌توان به تغییرات در دمای هوا در طول این ایام نسبت داد، به‌گونه‌ای که با کاهش نسبی دما مصرف به شدت افزایش می‌یابد و در برخی روزها با تغییر دما، مصرف نیز تغییر می‌کند.

ARIMA - ۱-۴

برای پیش‌بینی داده‌های سری زمانی به وسیله‌ی ARIMA، ابتدا مانایی سری زمانی را بررسی کرده و مرتبه‌ی انباشتگی (d) تعیین می‌شود. در مطالعه‌ی حاضر سری زمانی تقاضای روزانه‌ی گاز طبیعی با تفاضل مرتبه‌ی (۱) و سالانه براساس آزمون دیکی-فولر تعمیم یافته^۱، مانا شد. سپس تعداد جملات خودگرسیو (p) و تعداد جملات میانگین متحرک (p)، با استفاده از توابع خودهمبستگی (AC)، خودهمبستگی جزئی (PAC)

1- Augmented Dickey-Fuller test statistic.

براساس مراحل باکس- جنکینز، محاسبه شد. اما از آن جایی که ممکن است مدل‌های دیگری وجود داشته باشند که مقدار آکائیک یا شوارتز کمتری داشته باشند و بر الگوی مذکور ترجیح داده شوند، آن‌ها را نیز بررسی می‌کنیم. بر این اساس، کمترین مقدار آکائیک مربوط به فرایند تعداد جملات خودرگرسیو و میانگین‌متحرک است، که نتایج تفصیلی حاصل از برآورد آن، در جدول (۱) آورده شده است.

جدول ۱- نتایج حاصل از برآورد دوره‌ی ۱۳۸۳/۱۱/۰۱ - ۱۳۸۷/۱۱/۲۹

نام متغیر	ضریب	خطای معیار	نام متغیر	ضریب	خطای معیار
C	-۰.۴۵	-۰.۴۹	MA(1)	-۰.۵۸	-۰.۴۵
AR(1)	۰.۹۱	۶۱.۵	MA(2)	۰.۳۷	۱۲.۳۵
AR(2)	-۰.۱۱	-۰.۰۵	MA(3)	-۰.۱۷	-۰.۶۹
AR(365)	۰.۰۸	۰.۸			
$\bar{R}^2 = 63\%$	F = ۲۰.۸				

مأخذ: یافته‌های تحقیق

در جدول (۱)، همهٔ متغیرها در سطح خطای ۰/۰۱ و کل مدل به لحاظ آماری معنی‌دار هستند. تقاضای روزهای گذشته و جملات اخلال مذکور در جدول (۱)، ۶۳ درصد از تغییرات تقاضای روزانه‌ی گاز طبیعی (با توجه به نوسانات نامنظم سری زمانی) را توضیح می‌دهند.

۲-۴- شبکه‌ی عصبی

انواع مختلفی از شبکه‌های عصبی مصنوعی با توجه به اهداف تحقیق استفاده می‌شود. در این تحقیق از شبکه‌ی عصبی چند لایه‌ی پیشخور (MFNN)^۱ استفاده شده است. جدول (۲)، چگونگی طراحی و مدل‌سازی تقاضای روزانه‌ی گاز طبیعی را در شبکه‌ی عصبی نشان می‌دهد.

از آن جایی که یکی از اهداف اصلی این مقاله، بررسی کارایی تبدیل موجک در بالا بردن توانایی شبکه‌ی عصبی است، لذا ساختار شبکه‌ی عصبی در دو الگوی شبکه‌ی عصبی و شبکه‌ی عصبی همراه با تبدیل موجک، یکسان می‌باشد.

1- Multilayered Feedforward Neural Network.

جدول ۲- طراحی و مدل‌سازی تقاضای گاز طبیعی در شبکه‌ی عصبی

نوع شبکه‌ی عصبی	پیشخور چندلایه‌ای	الگوریتم آموزش شبکه‌های عصبی	لونبرگ- مارکوات
تابع فعال‌سازی	سیگموئید	متد توقف فرآیند آموزش	early stopping
تعداد نرون ورودی	۱	دوره‌ی زمانی آموزش و آزمایش	- ۱۳۸۷/۱۱/۲۹ ۱۳۸۳/۱۱/۱
تعداد نرون خروجی	۱	نسبت تعداد داده‌های آموزش و آزمایش	۰/۰۵ به ۰/۹۵
معیار تعیین تعداد نرون‌های مخفی	MSE	نرخ یادگیری	۰/۰۲
تعداد لایه‌ی پنهان	۱	دوره‌ی زمانی پیش‌بینی	- ۱۳۸۷/۱۲/۹ ۱۳۸۷/۱۱/۳۰
تعداد نرون‌های پنهان	۲۰		

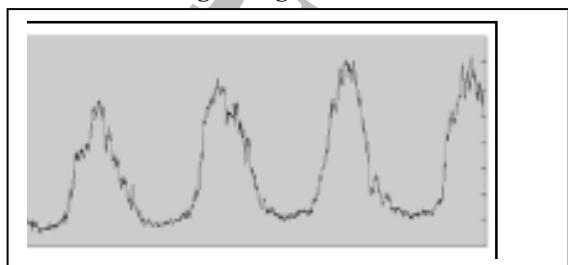
۳-۳- طراحی تبدیل موجک

در این روش ابتدا سری زمانی تقاضای گاز طبیعی، به صورت ترکیبی از مؤلفه‌های مجزا در مقیاس و سطوح نوسان متفاوت در نظر گرفته شده است. از این رو با توجه به این مطلب، ابتدا تجزیه‌ی موجک را به دست می‌آوریم و بعد برای هر مؤلفه‌ی (تابع جزئیات) تجزیه شده از سری اولیه، یک مدل شبکه‌ی عصبی طراحی می‌کنیم. آن‌چه باقی می‌ماند یک سری تقریبی (همراه شده) است که آن را نیز با شبکه‌ی عصبی الگوسازی کرده و روش شبکه‌ی عصبی - تبدیل موجک^۱ (WDNN) می‌نامیم. پیش‌بینی سری اصلی از مجموع پیش‌بینی سری هموار شده و مؤلفه‌ها به دست می‌آید. برای بررسی عملکرد سطح تجزیه، داده‌ها را با استفاده از موجک دبوچی ۳ تا ۳ سطح شکافته و سطح هموارشده را با جزئیات سطوح یک تا سه به دست آورده و هر یک را با استفاده از شبکه‌ی عصبی مدل می‌کنیم. نتایج این کار در نمودارهای (۲) تا (۶) نشان داده شده است.

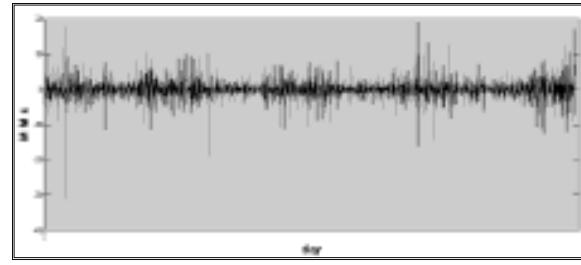
1-Wavelet Decomposition Neural Network.

نمودارهای (۲) تا (۶) مؤلفه‌های تجزیه شده سری زمانی تقاضای گاز طبیعی در بخش خانگی توسط موجک دبوچی ۳

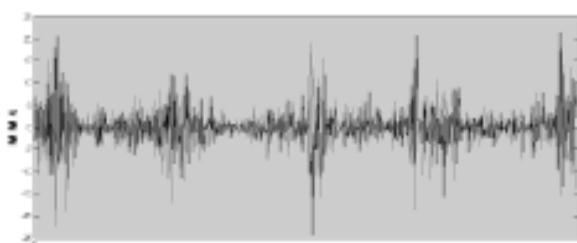
Original signal



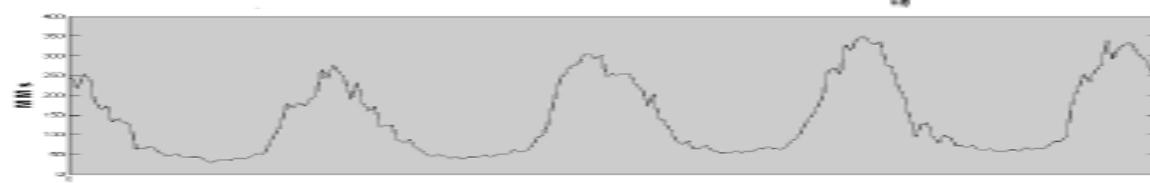
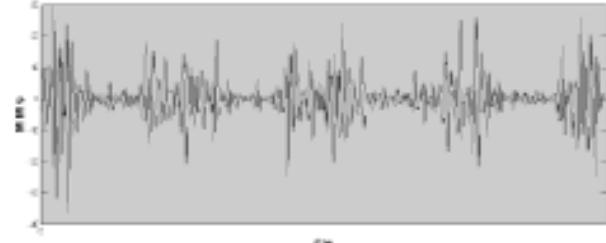
Details level 1 for db3



Details level 2 for db3



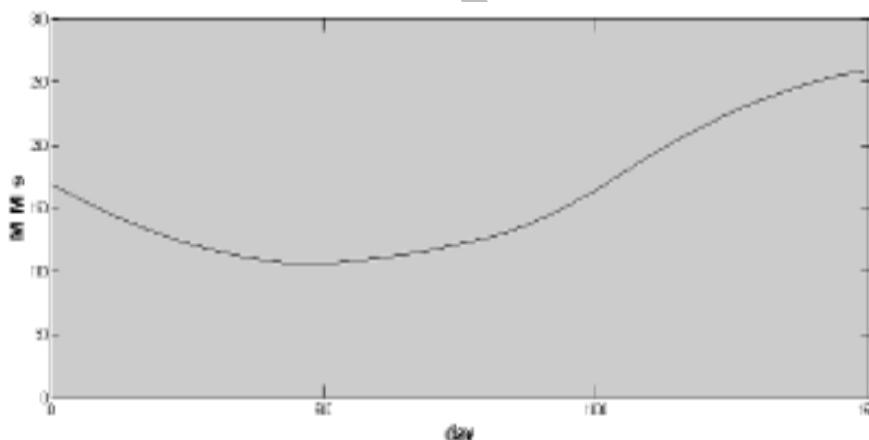
Details level 3 for db3



Approx.level 3 for db3

۴-۴- روش پیشنهادی

از تفسیر آمار روزانه‌ی تقاضای گاز طبیعی در بخش خانگی در بخش قبل به یاد داریم که این سری زمانی با درنظر گرفتن متوسط تقاضای سالیانه، دارای یک روند صعودی است. در مرحله‌ی نخست با استفاده از موجک (از نوع دبوچی)، سری زمانی تا سطحی تجزیه می‌شود که سطح هموارشده (تقریبی) به صورت یک خط نسبتاً راست در بیاید (سری تقاضای روزانه‌ی گاز طبیعی در بخش خانگی تا ۱۰ سطح شکافته شد) و با در نظر گرفتن این نکته که مدل ARIMA در پیش‌بینی سری‌های خطی قدرت بالایی دارد، این سری به وسیله‌ی ARIMA برای ۱۰ روز بعدی پیش‌بینی می‌شود. نمودار (۷)، سطح هموار شده (تقریبی) را برای تقاضای روزانه‌ی گاز طبیعی در بخش خانگی نشان می‌دهد.



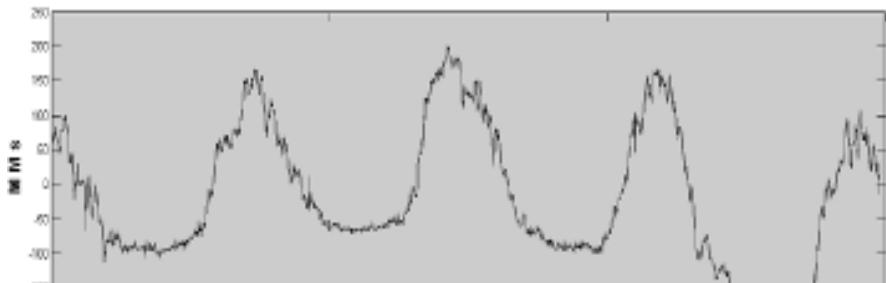
نمودار ۷- سری زمانی هموار شده‌ی (تقریبی) تقاضای روزانه‌ی گاز طبیعی در بخش خانگی برای پیش‌بینی (A pprox.level 10 for db5) ARIMA

در مطالعه‌ی حاضر سری زمانی تقاضای روزانه‌ی گاز طبیعی در بخش خانگی برای دوره‌ی (۱۱/۱۱/۲۹ تا ۱۳۸۳/۱۱/۲۹) با تفاضل‌گیری مرتبه‌ی (۲) مانا شد. سپس تعداد جملات خودرگرسیو (p) و تعداد جملات میانگین متحرک (p)، با توجه به توضیحاتی که در قسمت ۴-۱ بیان شد، به دست آمد. جدول (۳) نتایج حاصل از برآورد مدل ARIMA را نشان می‌دهد.

جدول ۳- نتایج حاصل از برآورد دوره‌ی ۱۳۸۷/۱۱/۲۹ - ۱۳۸۲/۱۱/۱

نام متغیر	ضریب	خطای معیار	نام متغیر	ضریب	خطای معیار
-۰.۳۰	-۰.۰۲	AR (4)	۰.۵۵	۹.۰۸E-۰۷	C
-۷.۶۷	-۰.۲۵	AR (5)	۱۰.۹۲	۰.۹۲	AR(1)
۱۱.۷۱	۰.۳۸	AR (6)	-۸.۷۲	-۰.۶۵	AR(2)
۲.۰۲	۰.۰۹	AR (7)	-۴.۴۵	-۰.۲۸	AR (3)
$\bar{R}^2 = ۰.۹۸$			$F = ۳۶۷$		

در مرحله‌ی بعد با جمع کردن سایر توابع جزئیات یک سری به دست می‌آید که روند زدایی شده است و فقط شامل نوسانات در طول دوره است. نمودار (۸)، این سری را نمایان می‌کند.

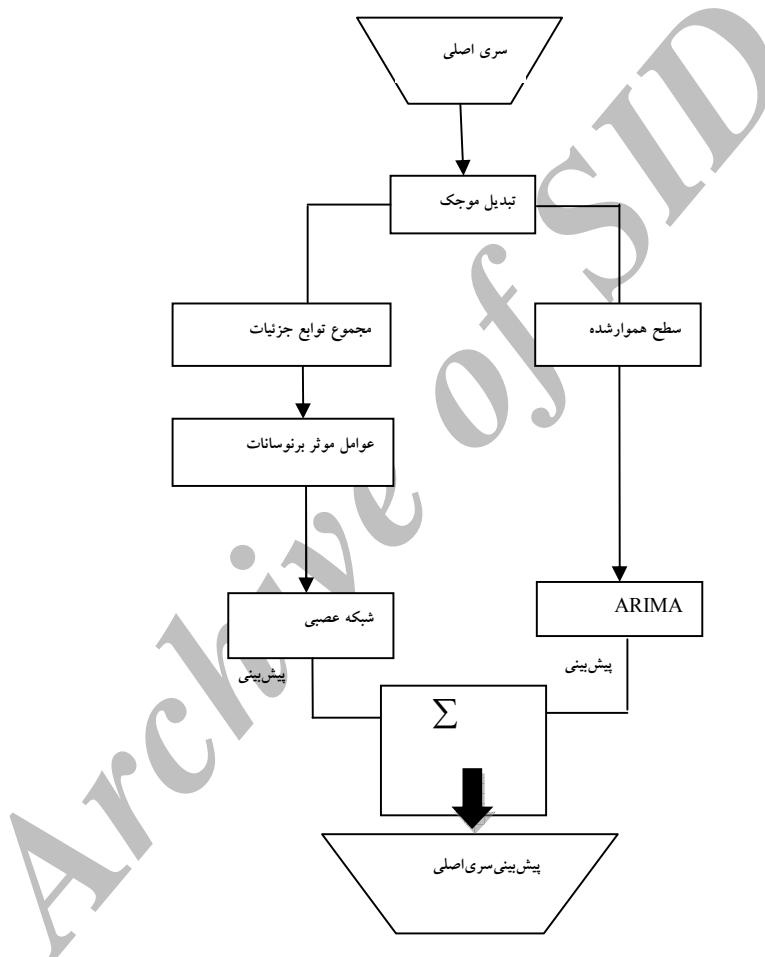


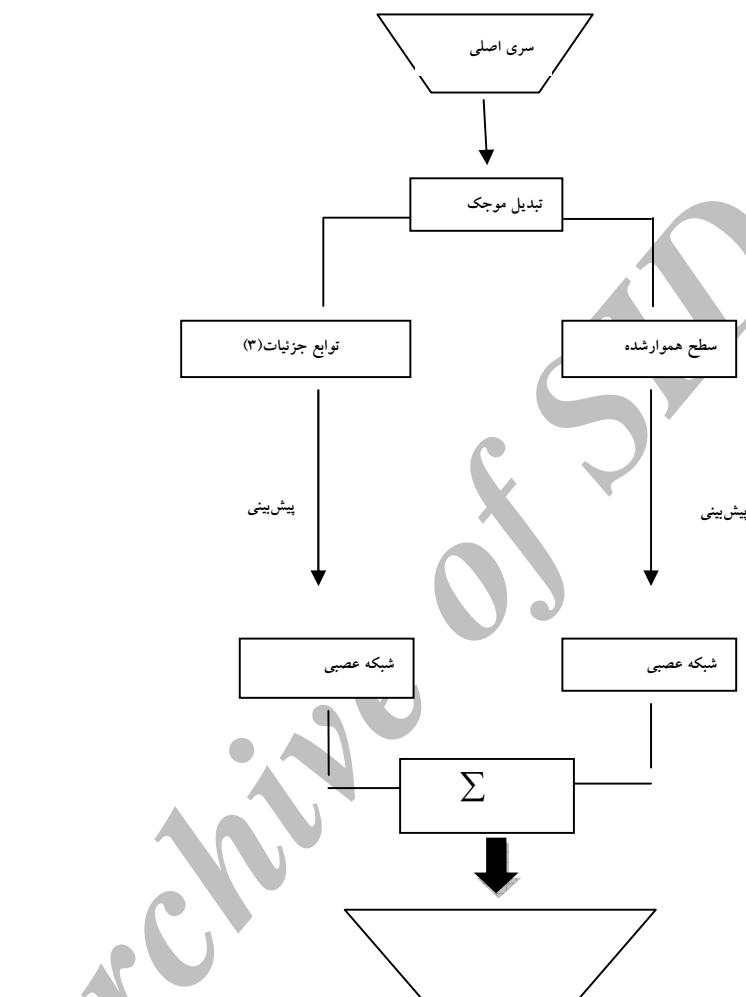
نمودار ۸- مجموع توابع جزئیات(مؤلفه‌ها) تقاضای روزانه‌ی گاز طبیعی در بخش خانگی

با توجه به ماهیت تقاضای گاز طبیعی در بخش خانگی، روزهای هفته، ایام تعطیل و غیرتعطیل تاثیر چندانی بر تقاضای گاز طبیعی در بخش خانگی ندارند، اما دمای هوا بهویژه در ماههای سرد و ساعت‌های تاریکی در این ماهها بر تقاضای گاز طبیعی در بخش خانگی مؤثر است که آن (دمای هوا) به صورت حداقل دما و ساعت‌های تاریکی به عنوان عوامل مؤثر بر نوسانات در ورودی شبکه عصبی در نظر گرفته می‌شود. هم‌چنین از یک متغیر فصلی نیز برای تمییز فصول سرد و گرم در طراحی شبکه استفاده شد. بنابراین شبکه‌ی عصبی دارای ۳ نرون در لایه‌ی ورودی و ۱۸ نرون در لایه‌ی پنهان است. بقیه مشخصه‌های ساختار شبکه همانند بخش ۲-۴ می‌باشد.

اشکال (۴) و (۵)، ساختار استفاده از روش پیشنهادی و شبکه عصبی- تبدیل موجک را نشان می‌دهد:

شکل ۴- ساختار روش پیشنهادی



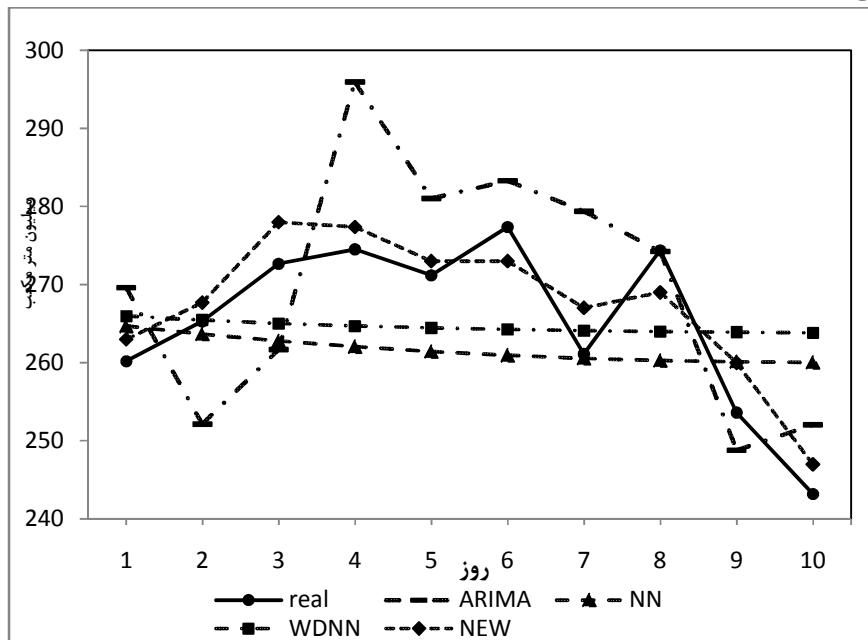


شکل ۵- ساختار شبکه‌ی عصبی - تبدیل موجک

۵- ارزیابی الگوهای پیش‌بینی

نمودار (۹) مقادیر پیش‌بینی شده توسط شبکه‌ی عصبی پیشخور (NN)، شبکه‌ی عصبی - تبدیل موجک (WDNN)، فرایند ARIMA و روش پیشنهادی (NEW) به

همراه مقادیر واقعی برای ۱۰ روز آینده (۱۳۸۷/۱۲/۹ تا ۱۳۸۷/۱۱/۳۰) رانشان می‌دهد.



نمودار ۹- مقایسه نتایج پیش‌بینی بر مبنای الگوهای پیش‌بینی به همراه مقادیر واقعی

به منظور مقایسه قدرت پیش‌بینی الگوهای از معیارهای میانگین مربع خطای استاندارد (MSE)، مجدول میانگین مربع خطای استاندارد (RMSE)، میانگین قدر مطلق خطای (MAE) و میانگین در صدقه مطلق خطای (MAPE) به صورت گام به گام (روز یکم تا روز دهم) استفاده شده که نتایج آن در جدول (۴) آورده شده است.

دلیل استفاده از پیش‌بینی نوع گام به گام (روز یکم تا روز دهم) بیان این نکته است که برای مثال یک مدل، در طول ۱۰ روز پیش‌بینی، ممکن است در چند روز اول نسبت به مدل دیگری از قدرت پیش‌بینی بالاتری برخوردار باشد اما در ارزیابی مجموع ۱۰ روز این گونه نباشد، که توانایی پیش‌بینی این مدل در نوع دوم نادیده گرفته می‌شود. هر گام معرف یک روز می‌باشد به عنوان مثال در گام دوم الگوهای مذکور برای دو روز آینده پیش‌بینی می‌کنند و در گام هفتم مدل‌ها برای ۷ روز آینده پیش‌بینی می‌کنند.

این معیارها بر اساس مقیاس داده‌های واقعی دوره ۱۳۸۷/۱۱/۰۳ - ۱۳۸۷/۱۲/۹ محاسبه شده‌اند.

جدول ۴- مقایسه قدرت پیش‌بینی الگوهای شبکه‌ی عصبی و ARIMA

ARIMA	شبکه‌ی عصبی	شبکه‌ی عصبی - عصبی موجک	روش پیشنهادی	گام	معیار	ARIMA	شبکه‌ی عصبی	شبکه‌ی عصبی - عصبی موجک	روش پیشنهادی	گام	معیار
۲۵۴۶	۴.۴۹	۵.۷۸	۲۸	۱	MAE	۸۸.۲۷	۲۰.۲۳	۳۳.۴۴	۷۸.۴	۱	MSE
۲۵۷.۱	۳.۰۵	۲.۹۶	۲۶	۲		۱۳۰.۶	۱۱.۴۱	۱۶.۷۲	۶.۸	۲	
۲۶۰.۵	۵.۳۳	۴.۵۳	۳۵	۳		۱۲۷.۷	۴۰.۲۳	۳۰.۷۵	۱۳.۸۹	۳	
۲۶۲.۵	۷.۱۱	۵.۸۴	۳.۳۵	۴		۲۱۰.۵	۶۸.۵۸	۴۷.۰۵	۱۲.۵۲	۴	
۲۶۳.۱	۷.۶۴	۶.۰۲	۳.۰۴	۵		۱۸۷.۵	۷۴.۱۳	۴۶.۷۵	۱۰.۶۶	۵	
۲۶۴.۶	۹.۱۰	۷.۲۱	۳.۲۶	۶		۱۶۲.۱	۱۰.۶۹	۶۷.۷۵	۱۲.۱۱	۶	
۲۶۳.۲	۷.۸۸	۶.۶۱	۳.۶۴	۷		۱۸۶.۷	۹۱.۶۷	۵۹.۳۶	۱۵.۳۵	۷	
۲۶۳.۹	۸.۶۶	۷.۰۸	۳.۸۶	۸		۱۶۳.۴	۱۰.۵۱	۶۵.۵	۱۷.۰۸	۸	
۲۶۲.۲	۸.۴۲	۷.۴۴	۴.۱۴	۹		۱۴۷.۸	۹۸.۱۵	۷۰	۱۹.۷۳	۹	
۲۵۹.۷	۹.۲۶	۸.۷۶	۴.۱۱	۱۰		۱۴۰.۹	۱۱۶.۷	۱۰.۵۵	۱۹.۲۱	۱۰	
۳۶۱	۱.۷۲	۲.۲۲	۱.۰۷	۱	MAPE	۹.۳۹	۴.۴۹	۵.۷۸	۲۸	۱	RMSE
۴.۲۸	۱.۱۶	۱.۱۳	.۹۹	۲		۱۱.۴۲	۳.۳۷	۴.۰۸	۲۶	۲	
۴.۲۰	۱.۹۸	۱.۶۹	۱.۳۰	۳		۱۱.۳	۶.۳۴	۵۵.۴	۳.۷۲	۳	
۵.۱۰	۲.۶۲	۲.۱۶	۱.۲۴	۴		۱۴.۵	۸.۳۹	۶۸.۸	۳.۵۳	۴	
۴.۸۰	۲.۸۱	۲.۲۲	۱.۱۲	۵		۱۳.۶۹	۸.۶۰	۶۸.۳	۳.۲۶	۵	
۴.۳۶	۳.۳۳	۲.۶۴	۱.۲	۶		۱۲.۷۳	۱۰.۳۳	۸.۲۳	۳.۴۷	۶	
۴.۷۳	۲.۸۹	۲.۴۳	۱.۳۵	۷		۱۳.۶۶	۹.۵۷	۷.۷	۳.۹۱	۷	
۴.۱۵	۳.۱۷	۲.۶	۱.۴۳	۸		۱۲.۷۸	۱۰.۲۵	۸.۰۹	۴.۱۳	۸	
۳.۹۰	۲.۱	۲.۷۶	۱.۵۵	۹		۱۲.۱۵	۹.۹۰	۸.۳۶	۴.۴۴	۹	
۳۸۷	۳.۴۸	۳.۳۳	۱.۵۵	۱۰		۱۱.۸۷	۱۰.۸	۱۰.۲۷	۴.۳۸	۱۰	

ماخذ: یافته‌های تحقیق

با توجه به جدول (۴) بر اساس هر ۴ معیار ارزیابی، روش پیشنهادی در تمام گام‌ها دارای کمترین خطای پیش‌بینی می‌باشد و نسبت به بقیه الگوها از دقت بالایی در پیش‌بینی برخوردار می‌باشد. پس از روش پیشنهادی، شبکه‌ی عصبی پیشخور بر اساس هر ۴ معیار در گام اول و دوم نسبت به شبکه‌ی عصبی - تبدیل موجک دارای خطای پیش‌بینی کم تری می‌باشد. این در حالی است که در بقیه گام‌ها (از گام سوم تا گام دهم) شبکه‌ی عصبی - تبدیل موجک نسبت به شبکه‌ی عصبی از دقت پیش‌بینی

بالاتری برخوردار می‌باشد و در مجموع نسبت به شبکه‌ی عصبی برتزی دارد. مدل ARIMA نیز از لحاظ دقیق‌تر پیش‌بینی در اولویت آخر قرار دارد. درنهایت روش پیشنهادی با درنظر گرفتن عوامل مؤثر بر تقاضای گاز طبیعی به‌ویژه دمای هوا و پیاده سازی یک الگوی تلفیقی از الگوهای خطی و غیرخطی دارای قدرت بالایی در پیش‌بینی تقاضای روزانه‌ی گاز طبیعی در بخش خانگی می‌باشد.

۶- نتیجه‌گیری

امروزه انرژی گاز به دلیل ارتباط با سایر بخش‌ها و نهادهای اقتصادی (در قالب نهاده‌ی کالای نهایی)، نقش قابل توجه‌ای در فرایند تصمیم‌گیری‌های اقتصادی و پیشبرد اهداف توسعه‌ی کشورها ایفا می‌کنند. آگاهی از رفتار مصرف کنندگان و میزان تقاضای آن‌ها از انرژی گاز طبیعی در آینده عاملی مهم در سیاست‌گذاری‌ها بوده به‌طوری‌که با آگاهی و اطلاعات درست در این مورد می‌توان تعادل بین عرضه و تقاضا را در آینده ایجاد نمود. با توجه به اهمیت موضوع، اطلاعات فوق می‌بایست تا حدامکان دقیق و مبتنی بر واقعیت‌های آینده باشد. از این‌رو پیش‌بینی میزان تقاضای گاز طبیعی در هر دوره امری مهم بوده که براساس آن می‌توان میزان تقاضا را در موعد مقرر به‌ویژه در کوتاه مدت تأمین نمود.

در این مطالعه روشی نوین جهت پیش‌بینی تقاضای گاز طبیعی ارائه شده که با شرایط آب و هوایی و سیستم اقلیمی کشور منطبق بوده و متغیرهای مؤثر بر میزان مصرف روزانه‌ی گاز طبیعی در بخش خانگی در آن لحاظ شده است. در ادامه براساس معیارهای ارزیابی MAPE، MAE، RMSE، MSE مدل‌های ARIMA، شبکه‌ی عصبی مصنوعی پیشخور و شبکه‌ی عصبی - تبدیل موجک پرداخته شد. نتایج تحقیق نشان داد که بر اساس همه معیارهای ارزیابی و در تمام گام‌ها، روش پیشنهادی از دقت بالایی در پیش‌بینی روزانه‌ی گاز طبیعی نسبت به سایر الگوها برخوردار می‌باشد. پس از روش پیشنهادی، شبکه‌ی عصبی - تبدیل موجک نسبت به شبکه‌ی عصبی مصنوعی پیشخور در هشت گام از ده گام از خطای پیش‌بینی کم‌تری برخوردار بود و پس از آن، شبکه‌ی عصبی پیشخور و فرآیند ARIMA در رده‌های بعدی با خطای پیش‌بینی کم‌تر قرار گرفتند.

فهرست منابع

- ابریشمی حمید، مهرآرآ، محسن، معینی، علی، احراری، مهدی و سلیمانی کیا، فاطمه (۱۳۸۷)، مدل سازی و پیش‌بینی قیمت بنزین با استفاده از شبکه‌های عصبی، فصلنامه‌ی پژوهش‌های اقتصادی ایران، سال دوازدهم، شماره‌ی ۳۶، صص ۳۷-۵۸.
- اصغری اسکویی، محمد رضا (۱۳۸۱)، کاربرد شبکه‌های عصبی در پیش‌بینی سری‌های زمانی، فصلنامه‌ی پژوهش‌های اقتصادی ایران، شماره‌ی ۱۲، صص ۹۵-۶۹.
- بهزادمهر، نفیسه (۱۳۸۷)، پیش‌بینی قیمت نفت خام با استفاده از هموارسازی موجک و شبکه‌ی عصبی مصنوعی، فصلنامه‌ی مطالعات اقتصاد انرژی، سال پنجم، شماره‌ی ۱۸، صص ۸۱-۹۸.
- پور کاظمی، محمد حسین، افسر، امیر و نهادوندی، بیژن (۱۳۸۴)، مطالعه تطبیقی روش‌های خطی ARIMA و غیرخطی شبکه‌های عصبی فازی در پیش‌بینی تقاضای اشتراک گاز شهری، مجله‌ی تحقیقات اقتصادی، شماره‌ی ۷۱، صص ۱۴۶-۱۳۳.
- شرزه‌ای غلامعلی، احراری، مهدی و فخرائی، حسن (۱۳۸۷)، پیش‌بینی تقاضای آب شهر تهران با استفاده از الگوی ساختاری، سری‌های زمانی و شبکه‌ی عصبی نوع GMDH، مجله‌ی تحقیقات اقتصادی، شماره‌ی ۸۴، صص ۱۷۵-۱۵۱.
- رمضانی مریم و رمضانی، رضا (۱۳۸۴)، پیش‌بینی تقاضای ماهیانه برق با استفاده از مدل‌های شبکه‌ی عصبی مصنوعی و آریما در ایران، بیستمین کنفرانس بین‌المللی برق، تهران، وزارت نیرو.
- زمانی مهرزاد (۱۳۸۴)، مدل سازی و پیش‌بینی قیمت نفت خام WTI، فصلنامه‌ی مطالعات اقتصاد انرژی، سال دوم، شماره‌ی ۴، صص ۳۸-۲۲.
- عباسی‌نژاد، حسین و محمدی، احمد (۱۳۸۶)، پیش‌بینی نرخ ارز با استفاده از شبکه‌های عصبی و تبدیل موجک، نامه‌ی اقتصادی، ج ۳، شماره‌ی ۱، صص ۱۹-۴۲.
- مشیری، سعید و شاهمرادی، اکبر (۱۳۸۴)، برآورد تقاضای گاز طبیعی و برق خانوارهای کشور: مطالعه خرد مبتنی بر بودجه‌ی خانوار، تحقیقات اقتصادی، شماره‌ی ۷۲، صص ۳۳۵-۳۰۵.

Bai-Ling Zhang, Zhao-Yang Dong(2005), Anadaptive neural-wavelet Model for short term load forecasting, Electric Power Systems Research, Volume 59, 2005, Pages 121–129.

Beccali, M., M. Cellura, V. Lo Brano and A. Marvuglia(2008), Short-term prediction of household electricity consumption: Assessing weather sensitivity in a Mediterranean area, journal of Renewable and Sustainable Energy Reviews, Volume 12, Pages 2040-2065.

Benaoudaa, D., F. Murtagh, J.-L. Starck and O. Renaud(2008), short-run load forecasting by Wavelet-based nonlinear multiscale decomposition model, journal of forecasting,Volume 30, Pages 1984-1998.

Chang-ilKim, In-keun Yu, Y.H. Song(2002), Kohonen neuralNetwork wavelet transform based approach to short-term load forecasting, Electric and Power Systems Research, Volume 63, Pages 169-176.

Conejoa, Antonio J., Javier Contrerasa, Rosa Espíñola, Miguel A. Plazas(2005), Forecasting electricity prices for a day-ahead pool-based electric energy market, International Journal of Forecasting, Volume 21 Pages 435– 462.

Gonzalez-Romera, M.A. Jaramillo-Moran, D. Carmona-Fernandez (2008), Monthly electric energy demand forecasting with neural networks, Energy Conversion and Management, Volume 49, Pages 3135–3142.

Rothman, Dale, Ho Hong, and Timothy Mount (1994), Estimating Consumer Energy Demand Using International Data: Theoretical and Policy Implications, The Energy Journal, Volume15, No. 2.

Shambora, Ravichandran, Chan, Vidhya, Ramakrishna, Krishna, Exponentiated back propagation algorithm for multilayer feed forward neural network, Neural Information processing, ICONIP 2002. Proceedings of the 9th International Conference on, Volume 1, Issue 18-22, pages 327-331.

Shuanghua Cao, Jiacong Cao (2005), Forecast of solar irradiance using recurrent neural networks combined with wavelet analysis, Applied Thermal Engineering Volume 25, pages 161–172.

Valens, C., (1999), a Really Friendly Guide to Wavelets.

Volkan S-Ediger, Sertac-Akar(2007), ARIMA forecasting of primary energy demand by fuel in Turkey, Energy Policy, Volume 35, pages 1701–1708.

Wang S, Yu L, Lai K.K, (2005), Crude Oil Price Forecasting with TEI@I Methodology, Journal of Systems Science and Complexity; 18.

White H. (1988), Economic Prediction Using Neural Networks: The Case Of IBM Daily Stock Returns, Proceeding of the IEEE International Conference on Neural Network, Pages 451-458.

www.wavelet.org/wavelet/index.html

www.mathsoft.com/wavelets.html

Zhang G Peter. (2003), Time series forecasting using a hybrid ARIMA and neural network model, Neurocomputing Volume 50, pages159-175.