

# مدل‌سازی و پیش‌بینی مصرف کوتاه‌مدت برق کشور با استفاده از شبکه‌های عصبی و تبدیل موجک (با تأکید بر اثرات محیطی و اقلیمی)

کاظم یآوری\*

دانشیار اقتصاد دانشگاه تربیت مدرس [kyavary@modares.ac.ir](mailto:kyavary@modares.ac.ir)

مهدی ذوالفقاری

دانشجوی دکترای اقتصاد نظری دانشگاه تربیت مدرس [mahdzolfaghari1985@gmail.com](mailto:mahdzolfaghari1985@gmail.com)

تاریخ دریافت: ۸۹/۹/۲ تاریخ پذیرش: ۹۰/۱۲/۱۸

## چکیده

امروزه انرژی الکتریکی به عنوان یکی از مهم‌ترین بخش‌های انرژی کشور ضمن داشتن نقش مؤثر در تولید و مصرف، اهمیت ویژه‌ای در فرآیند تصمیم‌گیری‌های اقتصادی دارد. آگاهی از میزان تقاضای انرژی الکتریکی در هر دوره به منظور برنامه‌ریزی دقیق، جهت اعمال سیاست‌گذاری‌های لازم، امری ضروری می‌باشد. از این رو پیش‌بینی تقاضای آن برای بخش‌های مختلف اقتصادی حائز اهمیت است. در پژوهش حاضر با تلفیق مدل خطی ARIMA و مدل‌های غیرخطی شبکه‌ی عصبی شعاع‌مدار و تبدیل موجک، الگوی جدیدی طراحی شده است تا براساس آن روند تقاضای روزانه‌ی برق کشور و عوامل مؤثر بر آن ارزیابی شود. در ادامه تقاضای روزانه‌ی برق کشور براساس مدل‌های ARIMA، شبکه‌ی عصبی شعاع‌مدار، شبکه‌ی عصبی شعاع‌مدار - تبدیل موجک و مدل تلفیقی در بازه‌ی زمانی یک‌گام تا ده‌گام به جلو پیش‌بینی شده است. نتایج حاصل از ارزیابی معیارهای سنجش دقت پیش‌بینی نشان می‌دهد که مدل تلفیقی نسبت به بقیه‌ی مدل‌ها دارای خطای کم و دقت بالایی در پیش‌بینی تقاضای روزانه‌ی برق می‌باشد.

طبقه‌بندی JEL: C53, E37, Q30

کلید واژه: پیش‌بینی، تقاضای برق، تبدیل موجک، شبکه‌های عصبی شعاع‌مدار، ARIMA.

## ۱- مقدمه

با توجه به رشد نسبتاً بالای مصرف انرژی برق در کشور، نیاز به تأمین این حامل به عنوان یک نهاده‌ی واسطه‌ای مهم در تولیدات صنعتی و به عنوان یک کالای نهایی و ضروری در بخش خانگی و تجاری، از الزامات نهاده‌ای اجرایی کشور می‌باشد. از سوی دیگر، پروسه‌ی تولید، توزیع و انتقال انرژی برق با توجه به ارقام بالای هزینه‌ای این جریان، بایستی برنامه‌ریزی شده و مطابق با میزان تقاضا شده‌ی آن باشد، لذا در صورت ایجاد هرگونه اختلال در برقراری تعادل بین تقاضای بخش‌های مختلف از این حامل و عرضه‌ی آن، خسارات سنگینی را بر پیکره‌ی اقتصاد کشور وارد می‌کند. اما پیش‌بینی دقیق میزان تقاضای آینده، نه تنها از تحمیل یک چنین هزینه‌هایی جلوگیری می‌کند، بلکه به عنوان نمونه در حوزه‌ی صنعت برق، منجر به تنظیم میزان تولید نیروگاه‌ها، بهبود کارایی بازار برق، شفافیت قیمت‌گذاری، کاهش خاموشی و افزایش کیفیت برق تحویلی می‌شود. هم‌چنین یکی از پیش‌شرط‌های حرکت به سمت بازار رقابتی که بیش‌ترین بهره‌مندی را برای نیروهای بازار فراهم می‌کند، داشتن اطلاعات دقیق و کامل از جریانات بازار، به‌ویژه میزان تقاضاست.

سیاست‌گذاران بخش‌های عرضه‌ی انرژی برای تأمین نیاز تقاضا شده از حامل‌های انرژی، نیازمند کسب اطلاعات و آگاهی از رفتار مصرف‌کنندگان این حامل‌ها می‌باشند. با توجه به اهمیت استراتژیکی این حامل در میزان تقاضا شده، اطلاعات اکتسابی می‌بایست تا حد امکان دقیق و مطابق با واقعیت‌های آینده باشد. این اطلاعات می‌تواند بر اساس روند مشاهدات در دوره‌های زمانی گذشته به‌دست آید. یکی از مزایای این روش، آگاهی از رفتار و تغییرات رفتاری متقاضیان در دوره‌های زمانی خاص می‌باشد که احتساب این موارد در داده‌های پیش‌بینی شده‌ی آتی، مفید است (صادقی و همکاران، ۱۳۸۸)، اما چگونگی در نظر گرفتن این داده‌ها، اهمیت مدل‌های پیش‌بینی را نمایان می‌کند. با توجه به این که بیش‌تر مدل‌های پیش‌بینی سری زمانی معرفی شده در مطالعات اقتصادی مانند  $ARIMA^1$  و  $ARMA^2$  به‌صورت خطی می‌باشند، در نظر گرفتن نوسانات سری زمانی در این مدل‌ها با محدودیت‌هایی مواجه است. از سوی دیگر به

1- Auto-Regressive Integrated Moving Average .

2- Auto-Regressive Moving Average .

موازات پیشرفت‌های قابل توجه در پردازش سریع اطلاعات به‌وسیله‌ی ماشین‌های الکترونیکی، به کارگیری مدل‌های غیرخطی در حوزه‌ی پیش‌بینی، محدودیت‌های مذکور را تا حدود قابل توجه‌ای کاهش داده است (احمدی و همکاران، ۱۳۸۸)، اما مدل‌های 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 این رو در راستای این حرکت تکاملی، ارائه‌ی مدلی جدید، منطقی و با کارایی بالاتر در پیش‌بینی، می‌تواند این حرکت رو به جلو را به سمت حداقل کردن خطاهای احتمالی در حوزه‌ی پیش‌بینی شتاب بخشد.

از سوی دیگر تجربیات مطالعات اخیر نشان می‌دهد که مدل‌های ترکیبی، توانایی بالاتری در پیش‌بینی نسبت به استفاده صرف از یک مدل پیش‌بینی‌کننده دارند، به‌طور کلی مدل‌های غیرخطی و ترکیبی، به‌ویژه با محوریت شبکه‌های عصبی، از آن جایی که عوامل بیش‌تری را در الگوسازی لحاظ می‌کنند، توانایی بالاتر و دقت بیش‌تری در پیش‌بینی دارند (بهرادمهر، ۱۳۸۷).

از این نظر ارائه‌ی مدلی کارا برای پیش‌بینی تقاضای این حامل انرژی با توجه به شرایط خاص کشور از اهمیت ویژه‌ای برخوردار است. مهم‌ترین هدف این تحقیق ارائه یک چنین مدلی سازگار با شرایط کشور و از سوی دیگر امکان استفاده از این مدل در پیش‌بینی سایر متغیرهای سری زمانی است.

در این مقاله در بخش دوم، پیشینه‌ی تحقیق ارائه می‌شود. بخش سوم، به معرفی روش شناسی شبکه‌های عصبی شعاع‌مدار و تبدیل موجک به همراه مدل پیشنهادی می‌پردازد. در بخش چهارم به مدلسازی و تخمین مدل‌های مذکور با استفاده از داده‌های روزانه‌ی تقاضای برق کشور<sup>۱</sup> پرداخته می‌شود. در مرحله‌ی بعد، تقاضای روزانه‌ی برق کشور توسط مدل‌های مذکور در بازه‌ی زمانی یک گام تا ده گام به جلو پیش‌بینی می‌شود. در نهایت با به‌کارگیری معیارهای سنجش به ارزیابی قدرت پیش‌بینی مدل‌های فوق پرداخته شده و در پایان نتیجه‌گیری ارائه می‌شود.

## ۲- پیشینه تحقیق

مطالعات شکل گرفته در حوزه‌ی استفاده‌ی محض از مدل ARIMA به ندرت انجام شده و در بیش‌تر موارد این مدل با انواع مختلف شبکه‌های عصبی مقایسه شده است. در این‌جا به مطالعه‌ی ادیگر و آکار<sup>۱</sup> (۲۰۰۷) در پیش‌بینی تقاضا برای انرژی سوخت (از جمله برق) ترکیه به‌وسیله‌ی مدل ARIMA اکتفا می‌شود. در این مطالعه آن‌ها از مدل‌های ARIMA و مدل فصلی ARIMA (SARIMA) برای پیش‌بینی تقاضای انرژی ترکیه از ۲۰۰۵ تا ۲۰۲۰ بهره گرفته‌اند.

در حوزه‌ی پیش‌بینی تقاضای برق با استفاده از شبکه‌های عصبی، در مطالعه‌ی داربلای و سلاما<sup>۲</sup> (۲۰۰۰)، به پیش‌بینی تقاضای کوتاه‌مدت برق جمهوری چک پرداخته و با مقایسه‌ی مدل شبکه‌ی عصبی مصنوعی و مدل ARIMA نشان داده‌اند که شبکه‌های عصبی از نظر غیرخطی بودن روند تقاضای برق، پیش‌بینی بهتری نسبت به مدل ARIMA ارائه می‌کنند.

هیپرت، بان و سوزنا<sup>۳</sup> (۲۰۰۵)، با به‌کارگیری شبکه‌ی عصبی به پیش‌بینی مصرف برق برزیل پرداخته‌اند. در این مطالعه با استفاده از متدهای مختلف، مصرف ساعتی برق پیش‌بینی و عملکرد مناسب شبکه‌ی عصبی در پیش‌بینی ۲۴ ساعته نسبت به مدل‌های رقیب از جمله ARIMA، مفید ارزیابی شده است.

سایو تین پاو<sup>۴</sup> (۲۰۰۶)، با در نظر گرفتن چهار فاکتور درآمد ملی، جمعیت، تولید ناخالص داخلی و شاخص قیمت مصرف‌کننده، مصرف برق در تایوان را با استفاده از مدل شبکه‌ی عصبی مورد ارزیابی قرار داده و نتایج آن را با مدل ARMAX مقایسه نمود که در مجموع شبکه‌ی عصبی در پیش‌بینی مصرف برق نسبت به مدل رقیب از دقت بالایی برخوردار بوده است. مدل ARMAX علاوه بر روند گذشته‌ی خود متغیر، یک متغیر توضیحی دیگر را نیز در پیش‌بینی متغیر مربوطه لحاظ می‌کند.

ماندال و همکاران<sup>۵</sup> (۲۰۰۶)، با استفاده از شبکه‌های عصبی به پیش‌بینی قیمت و تقاضای برق برای ساعات مختلف در بازار برق ژاپن پرداخته و نشان داده‌اند که

1- Edigera and Akar.

2- Darbellay and Slama.

3- Hippert, Bunn, Souza.

4- Hsiao-Tien Pao.

5- Mandal et al.

شبکه‌های عصبی در پیش‌بینی مقادیر در ساعات دورتر خطای بالایی از خود آن‌ها می‌دهند. ایشان بیان کرده‌اند که شبکه‌های عصبی برای پیش‌بینی‌های کوتاه‌مدت مناسب هستند.

جیمز و همکاران<sup>۱</sup> (۲۰۰۶)، به مطالعه‌ی تطبیقی روش‌های شبکه‌ی عصبی مصنوعی و ARIMA برای ایرلند و ولز پرداخته‌اند که نتایج مطالعه‌ی آن‌ها بیانگر قدرت بالای شبکه‌ی عصبی در پیش‌بینی کوتاه‌مدت (روزانه) بوده است. هامزا چبی<sup>۲</sup> (۲۰۰۷)، مصرف برق ترکیه را بر پایه داده‌های فصلی تا سال ۲۰۲۰ با به‌کارگیری مدل شبکه‌عصبی پیش‌بینی نمود. رومرا و همکاران<sup>۳</sup> (۲۰۰۷)، با استفاده از شبکه‌های عصبی مصنوعی، تقاضای ماهیانه برق برای کشور اسپانیا را پیش‌بینی کرده‌اند. در مطالعه‌ی دیگری فرانک و همکاران<sup>۴</sup> (۲۰۰۸) با به‌کارگیری شبکه‌ی عصبی مصنوعی و سری‌های فوریه، تقاضای ماهیانه برق اسپانیا را برآورد کرده‌اند. در این مطالعه‌ی سری‌فوریه نتایج مناسب‌تری نسبت به مدل‌های شبکه‌ی عصبی مصنوعی و ARIMA ارائه کرده است.

بکالی و همکاران<sup>۵</sup> (۲۰۰۸)، به پیش‌بینی تقاضای کوتاه‌مدت برق خانگی ایتالیا با استفاده از شبکه‌های عصبی مصنوعی اقدام نمودند. این مطالعه با در نظر گرفتن جریان‌ات آب و هوایی که شامل متغیرهای رطوبت و تابش خورشید می‌باشد، به صورت منطقه‌ای برای دوره‌ی ۱ ژانویه ۲۰۰۲ تا ۱۰ سپتامبر ۲۰۰۳ انجام گرفته است.

از مطالعات داخلی انجام گرفته در این زمینه می‌توان به مطالعات آزاده و همکاران<sup>۶</sup> (۲۰۰۸) اشاره کرد که با استفاه از شبکه‌ی عصبی پیش‌خور، مصرف ماهیانه‌ی برق صنعتی در ایران را طی دوره‌ی ۲۰ ساله ۲۰۰۳-۱۹۷۹ مورد بررسی قرار داده و برتری مدل شبکه‌ی عصبی پیش‌خور در مقایسه با مدل رگرسیون را نشان داده‌اند. در مطالعه‌ی دیگر، طباطبایی و همکاران<sup>۷</sup> (۲۰۰۸) تقاضای کوتاه‌مدت برق را بر اساس شبکه‌ی عصبی پرسپترون ۲ لایه پیش‌بینی کرده‌اند. در این مطالعه داده‌های مربوط به دما

1- James et al.

2- Hamzaçebi.

3- Romera et al.

4- Frank et al.

5- Beccali et al.

6- Azadeh et al.

7- Tabatabai et al.

به‌عنوان متغیر آب و هوایی برای آموزش شبکه‌ی عصبی استفاده شده است. کمانکش و همکاران (۱۳۸۶)، در پیش‌بینی بار کوتاه‌مدت شبکه‌ی برق ایران با در نظر گرفتن شرایط خاص نظیر روزهای قبل و بعد و بین تعطیلی و سال‌های کبیسه، از شبکه‌ی‌های عصبی پرسپترون کمک گرفته‌اند. احمدی و همکاران (۱۳۸۸)، در مطالعه‌ی کارایی مدل شبکه‌ی عصبی را با مدل ARIMA برای پیش‌بینی متوسط ماهیانه‌ی نیاز داخلی برق کشور، برای یک دوره‌ی ۳ ساله (۸۷-۱۳۸۴) با استفاده از معیارهای سنجش خطا و ضریب تعیین مقایسه کرده‌اند. نتایج حاصل از این تحقیق بیانگر برتری مدل شبکه‌ی عصبی پرسپترون نسبت به مدل ARIMA می‌باشد.

در زمینه‌ی استفاده از تکنیک تبدیل موجک، تای ننگلینگ و همکاران<sup>۱</sup> (۲۰۰۶)، با استفاده از تکنیک تبدیل موجک به پیش‌بینی کوتاه‌مدت بار شرق چین پرداخته‌اند. بر اساس این مدل امکان تجزیه‌ی یک سیگنال بار در داخل سطح‌های مختلف به‌وسیله‌ی تبدیل موجک وجود دارد. این مقاله یک مدل پیش‌بینی ترکیبی بر اساس تبدیل موجک را برای پیش‌بینی کوتاه‌مدت بار نشان می‌دهد. مدل جدید به‌وسیله‌ی پیش‌بینی بار برق شرق چین مورد بررسی قرار گرفته و یک دقت پیش‌بینی بالایی را برای ۲۴ ساعت آینده در طول یک هفته معمولی، پایان هفته و روزهای تعطیل فراهم کرده است.

بای و همکاران<sup>۲</sup> (۲۰۰۸)، با استفاده از یک مدل تطبیقی موجک-عصبی به پیش‌بینی بار کوتاه‌مدت برق برای کوپزلند در بازار برق استرالیا پرداخته‌اند. مدل پیش‌بینی بر پایه‌ی تجزیه‌ی تحلیل چندگانه‌ی موجک<sup>۳</sup> می‌باشد. در روش مورد نظر یک تکنیکی از نمایش پوشش خودهمبستگی برای تجدید ساختار سیگنال‌ها بعد از تجزیه‌ی موجک به کار گرفته شده است. با کمک این تکنیک یک سری زمانی می‌تواند به عنوان یک ترکیب جمع پذیر از ضرایب موجک در سطوح حل مختلف توضیح داده شود.

کنجو و همکاران<sup>۴</sup> (۲۰۰۵)، با استفاده از شبکه‌های عصبی و تبدیل موجک، قیمت روز بعد برق را در بازار انرژی اسپانیا پیش‌بینی کرده‌اند. این تکنیک شامل تحلیل سری‌های زمانی، شبکه‌های عصبی و تبدیل موجک می‌باشد. در میان روش‌های سری

1- Tai Nengling et al.

2- Bai et al.

3- Wavelet Multi-Resolution Decomposition .

4- Conejo et al.

زمانی، روش‌های مورد نظر شامل ARIMA، رگرسیون پویا و تابع انتقال می‌باشد. تحلیل جامع با استفاده از داده‌های داخلی وزارت انرژی اسپانیا محاسبه شده است. بنودا و همکاران<sup>۱</sup> (۲۰۰۹)، با استفاده از مدل تجزیه‌ی چندمقیاسی غیرخطی موجک<sup>۲</sup> به پیش‌بینی برق استرالیا پرداخته‌اند. در این مطالعه یک روش خودرگرسیو پیشنهاد شده است که بر پایه‌ی تجزیه‌ی چندمقیاسی موجک به پیش‌بینی ۱ ساعت به جلو براساس داده‌های گذشته می‌پردازد. آن‌ها نتایج تولید شده به‌وسیله‌ی متد خودرگرسیو چندمقیاسی را در دو حالت خطی و غیرخطی همراه با اتورگرسیون (AR) و شبکه‌ی عصبی پرسپترون چند لایه بر اساس معیارهای  $APE^3$ ,  $RMSE^4$ ,  $MAPE^5$  بررسی کرده‌اند.

از مطالعات داخلی انجام گرفته در حوزه‌ی اقتصاد که از تکنیک تبدیل موجک استفاده کرده است 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 مقیاسی متفاوتی تجزیه شده است. در مرحله‌ی بعد تکنیک شبکه‌های عصبی برای مدل‌سازی هر کدام از مؤلفه‌های سری زمانی به‌کار گرفته شده و پیش‌بینی نهایی سری‌های زمانی اصلی با ترکیب پیش‌بینی این مؤلفه‌ها به‌دست آمده است. این روش برای پیش‌بینی یک تا ده گام به جلوی نرخ‌های ارز روزانه به‌کار گرفته شده است. نتایج برآورد تبدیل موجک با نتایج شبکه‌های عصبی و ARIMA براساس معیار  $RMSE$  مورد مقایسه قرار گرفته است. نتایج تحقیق نشان داد که در پیش‌بینی یک گام عمدتاً شبکه‌ی عصبی بهینه بوده، در پیش‌بینی دو گام تا پنج گام به جلو روش ترکیبی شبکه‌ی عصبی و تبدیل موجک، بهینه بوده‌اند. در پیش‌بینی شش گام تا ده گام به جلو، شبکه‌ی عصبی، مدل بهینه است.

بهرادمهر (۱۳۸۷)، در مطالعه‌ای با استفاده از هموارسازی موجک و شبکه‌ی عصبی مصنوعی به پیش‌بینی روزانه‌ی قیمت نفت خام نیویورک و نفت خام خلیج مکزیک برای

1- Benaouda et al.

2- Wavelet-based Nonlinear Multiscale Decomposition Model .

3- Absolute Percent Error.

4- Root Mean Square Error.

5- Mean Absolute Percent Error.

دوره‌ی ۲۰۰۰/۱/۴ تا ۲۰۰۴/۹/۲ پرداخته است. 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 شده است. 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 می‌بخشد.

صادقی و همکاران (۱۳۸۸)، با طراحی یک مدل تلفیقی از شبکه‌های عصبی پرسپترون، ARIMA و تبدیل موجک، تقاضای روزانه‌ی گاز طبیعی در بخش خانگی را پیش‌بینی و نتایج آن را با مدل‌های ARIMA، شبکه‌ی عصبی پرسپترون و تبدیل موجک به صورت گام‌به‌گام مقایسه کرده‌اند. نتایج این تحقیق نشان می‌دهد که مدل ترکیبی نسبت به بقیه‌ی الگوها دارای خطای کم و دقت بالایی در پیش‌بینی تقاضای روزانه‌ی گاز طبیعی در بخش خانگی می‌باشد.

از آن‌جایی که شبکه‌های عصبی شعاع‌مدار رقیب سرسخت شبکه‌های عصبی پرسپترون می‌باشند (پیکتن، فلیپ، ترجمه‌ی غضنفری و ارکات، ۱۳۸۳، ص ۱۶۲)، در این مطالعه تلاش شده است ضمن معرفی یک مدل تلفیقی، از مدل‌های پیش‌بینی خطی و غیرخطی، از قدرت پیش‌بینی مدل شبکه‌های عصبی شعاع‌مدار نیز در پیش‌بینی روزانه تقاضای برق استفاده شود.

### ۳- شبکه‌های عصبی

شبکه‌های عصبی از دهه‌ی ۵۰ شناخته شده‌اند، اما تنها در اواسط دهه‌ی ۸۰ بوده است که الگوریتم‌ها و روش‌های مربوط به شبکه‌های عصبی مصنوعی به‌درجه‌ای از پیشرفت رسیده‌اند که در حل مسائل واقعی از آن‌ها استفاده شده است.

#### شبکه‌های عصبی شعاع‌مدار


شبکه‌های عصبی شعاع‌مدار ( $RBF^1$ ) با توجه به کاربردهای متنوعی که برای آن توسعه یافته است، به یکی از پرکاربردترین گونه‌های شبکه‌ی عصبی تبدیل شده است و



به همین جهت مهم‌ترین رقیب برای پرسپترون چندلایه به شمار می‌آید (فلیپ، ترجمه‌ی غضنفری و اراکات، ۱۳۸۸، ص ۱۶۲)

معماری اصلی شبکه‌های عصبی شعاع‌مدار متشکل از یک شبکه‌ی سه لایه می‌باشد که در شکل (۱) نشان داده شده است.

لایه‌ی ورودی فقط یک لایه‌ی کشنده است و در آن هیچ پردازشی انجام نمی‌گیرد. لایه‌ی پنهان، یک انطباق غیرخطی مابین فضای ورودی و یک فضا (معمولاً) با بعد بزرگ‌تر برقرار می‌کند که در آن الگوها به صورت تفکیک‌پذیر خطی درمی‌آیند. لایه‌ی سوم، جمع وزنی را به همراه یک خروجی خطی تولید می‌کند. در صورتی که از شبکه‌های عصبی شعاع‌مدار برای تقریب تابع استفاده شود، چنین خروجی‌ای مفید خواهد بود، ولی در صورتی که نیاز باشد، طبقه‌بندی الگوها انجام شود، آن‌گاه یک محدودکننده‌ی سخت یا یک تابع سیگموئید را می‌توان بر روی نرون‌های خروجی قرار داد تا مقادیر ۰ یا ۱ تولید شوند.



شکل ۱- شبکه‌ی عصبی شعاع‌مدار (پیکتن، فلیپ، شبکه‌های عصبی، اصول و کاربردها)

خصوصیت منحصربه‌فرد شبکه‌های عصبی شعاع‌مدار، پردازشی است که در لایه‌ی پنهان انجام می‌گیرد. ایده‌ی اصلی آن است که الگوهای فضای ورودی، تشکیل خوشه‌ی

دهند. در صورتی که مراکز این خوشه‌ها مشخص باشد، می‌توان فاصله از مرکز خوشه را اندازه گرفت. به‌علاوه این اندازه‌گیری فاصله، به‌صورت غیرخطی انجام می‌گیرد، لذا در صورتی که الگویی در ناحیه‌ی مجاور مرکز یک خوشه قرار داشته باشد، مقداری نزدیک به ۱ تولید می‌شود. در خارج از این ناحیه، مقدار به‌دست آمده به‌طور قابل ملاحظه‌ای کاهش می‌یابد. نکته مهم آن است که این ناحیه به‌صورت شعاعی در اطراف مرکز خوشه متقارن است، بنابراین تابع غیرخطی به‌صورت تابع شناخته شده‌ی شعاع‌مدار درمی‌آید. معمولی‌ترین شکل تابع شعاع‌مدار به صورت زیر است:

$$\varphi(r) = \exp\left(-\frac{r^2}{2\sigma^2}\right) \quad (8)$$

در معادله‌ی بالا  $r$  برابر مقدار عددی فاصله از مرکز خوشه می‌باشد.  $\sigma$  به عنوان عرض یا شعاع منحنی زنگی تعریف می‌شود.

معمولاً فاصله‌ی اندازه‌گیری شده تا مرکز خوشه، از نوع فاصله‌ی اقلیدسی است. برای هر نرون موجود در لایه‌ی پنهان، وزن‌ها، مختصات مرکز خوشه را نشان می‌دهند، بنابراین زمانی که نرون، یک الگوی ورودی  $X$  را دریافت می‌کند، فاصله‌ی مزبور با استفاده از معادله‌ی زیر به‌دست می‌آید:

$$r_j = \sqrt{\sum_{i=1}^n (x_i - w_{ij})^2} \quad (9)$$

بنابراین خروجی نرون  $j$  در لایه‌ی پنهان به شکل زیر می‌باشد:

$$\varphi(r) = \exp\left(-\frac{\sum_{i=1}^n (x_i - w_{ij})^2}{2\sigma^2}\right) \quad (10)$$

مزایای زیادی برای شبکه‌های عصبی شعاع‌مدار در مقایسه با پرسپترون‌های چند لایه ( $MLP^1$ ) عنوان شده است. شبکه‌های عصبی شعاع‌مدار سریع‌تر از یک MLP

آموزش داده می‌شوند و نیز محدوده‌های تصمیم‌گیری بهتری را ایجاد می‌کنند<sup>۱</sup>. مزیت دیگر شبکه‌های عصبی شعاع‌مدار این است که در این شبکه، تعبیر و تفسیر لایه‌ی خروجی به مراتب آسان‌تر از یک MLP است (لئونارد و کرامر<sup>۲</sup>، ۱۹۹۱). از سوی دیگر شبکه‌های عصبی شعاع‌مدار نیازمند نرون‌های بیش‌تری نسبت به شبکه‌های استاندارد پیشخور با الگوریتم پس انتشار خطا می‌باشند<sup>۳</sup> ولی بیش‌تر این شبکه‌ها را می‌توان در زمانی کوتاه‌تر نسبت به زمان مورد نیاز برای شبکه‌های پیشخور، آموزش داد (صیادی و همکاران، ۱۳۸۸). هم‌چنین شبکه‌های عصبی شعاع‌مدار از نظر تعدد توابع آموزش و یادگیری و برخورداری بیش از یک لایه‌ی پنهان، در تجزیه و تحلیل و پیش‌بینی داده‌های سری زمانی نسبت به شبکه‌های ANN، قابلیت بالاتری دارند (غفاری‌نژاد، ۱۳۸۸).

### تبدیل موجک

ایده‌ی اساسی در موجک، تحلیل بر اساس مقیاس است. این امر موجک را به ابزار مفید و جالب تبدیل می‌کند. تحلیل موجک ابزار بسیار قدرتمندی است که می‌توان از آن برای بررسی اطلاعات کیفی سری‌های زمانی نامانا استفاده کرد. موجک‌ها در تحلیل موقعیت‌های فیزیکی که در آن سیگنال‌ها دارای خصوصیات عدم پیوستگی و نقاط اوج نوک تیز می‌باشند، مزایایی بر تحلیل فوریه دارد (میترا<sup>۴</sup>، ۲۰۰۵). از دیگر ویژگی‌های تبدیل موجک می‌توان به پیش‌بینی و بررسی تغییرات ساختاری، نویززدایی، تجزیه‌ی مقیاسی- زمانی داده‌های مالی و اقتصادی و بررسی روابط علت و معلولی میان متغیرهای اقتصادی، اشاره کرد (رمزی و آندرسون<sup>۴</sup>، ۲۰۰۲). در این مقاله از توانایی موجک‌ها در زمینه‌ی تجزیه‌ی داده‌ها برای انجام پیش‌بینی‌های بهتر استفاده شده است که در قسمت بعدی به‌طور مفصل به آن پرداخته می‌شود.

۱- این موضوع توسط لئوناردو و همکاران (۱۹۹۲) با مقایسه‌ی RBF و MLP برای برخی مسائل اثبات شده است.

2- Leonard and Kremer.  
3- Ramsey and Anderson.  
4- Mitra.

تجزیه‌ی موجک و تبدیل گسسته‌ی موجک<sup>۱</sup>

باز نمایی سری‌های موجک<sup>۲</sup> یک تابع قابل انتگرال‌گیری مربع  $L^2(k)$   $f(t) \in L^2(k)$  فضای تمامی توابع مربع قابل انتگرال‌گیری می‌باشد و  $\int_{-\infty}^{\infty} f^2(t) dt < \infty$  if  $f \in L^2(k)$  به صورت زیر نشان می‌دهند<sup>۳</sup>:

$$f(t) = \sum_{j=-\infty}^{\infty} \sum_{k=-\infty}^{\infty} \eta_{j,k} \psi_{j,k}(t) \quad (11)$$

که در آن:

$$\Psi_{j,k} = \Psi(2^j t - k) \quad ; j, k \in E = \{0, \pm 1, \pm 2, \dots\} \quad (12)$$

و ضرایب موجک<sup>۴</sup> نامیده و به صورت زیر تعریف می‌شوند:

$$\eta_{j,k}(t) = \langle f, \Psi_{j,k} \rangle = \int_{-\infty}^{\infty} f(t) \Psi_{j,k}(t) dt \quad (13)$$

برای محاسبه‌ی تبدیل موجک پیوسته‌ی یک تابع، محاسبات ریاضی مربوطه به ترتیب زیر انجام داده می‌شوند:

گام ۱: ابتدا موجک مادر در ابتدای سیگنال مربوطه و  $S=1$  قرار داده می‌شود.

گام ۲: تابع موجک با اندازه‌ی مقیاس یک، در سیگنال مورد نظر ضرب می‌شود و در همه‌ی بازه‌های زمانی از آن انتگرال‌گیری و سپس حاصل در  $\frac{y}{\Delta} <$  ضرب می‌شود.

گام ۳: موجک  $\theta \leq G \leq \theta$  شیفته شده و مقدار این تبدیل در زمان  $G \leq \theta$  و در  $S=1$  به دست آورده می‌شود.

گام ۴: این فرآیند تا زمانی که موجک به انتهای سیگنال اصلی نرسیده است، تکرار می‌شود.

1- Wavelet Decompositon.

2- Wavelet Series Representation.

۳- معادلات ریاضی از کتاب "مبانی مدل‌های پیش‌بینی در علوم اقتصادی" نوشته‌ی دکتر حسین صادقی و همکاران (۱۳۸۶) استخراج شده است.

4- Wavelet Coefficients.

گام ۵: مقدار  $S$  به مقدار مناسب کوچکی افزایش داده شده و فرآیند بالا برای همه‌ی مقادیر  $S$  تکرار می‌شود.

گام ۶: هر کدام از محاسبات بالا برای  $S$  انتخاب شده، یک ردیف یکتا برای حوزه زمانی به‌دست می‌دهد.

گام ۷: اگر همه‌ی مقادیر  $S$  در فرآیندهای بالا منظور شود، تبدیل موجک پیوسته به‌صورت کامل به‌دست می‌آید.

در صورت استفاده از تبدیل موجک پیوسته حجم اطلاعات بسیار زیاد می‌شود، چرا که بایستی برای مقیاس‌های مختلف ( $S$  مختلف) در طول زمان از سیگنال اصلی و تابع موجک، انتگرال‌گیری کرد، بنابراین حجم اطلاعات و محاسبات بسیار زیاد می‌شود، چرا که  $S$  به‌صورت پیوسته تغییر می‌کند<sup>۱</sup>. از این رو بهتر است که از تبدیل موجک گسسته استفاده شود. این تبدیل ویژگی‌های بسیار مناسبی را ارائه می‌دهد که از جمله‌ی این ویژگی‌ها می‌توان به موارد زیر اشاره کرد:

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

۲- مقدار محاسبات مورد نیاز را به مقدار بسیار مناسبی کاهش می‌دهد.

۳- می‌توان توسط آن سیگنال اصلی را در فرکانس‌های مختلف و با وضوح‌های کاملاً متفاوت، بررسی و تحلیل کرد.

در تبدیل موجک گسسته متغیرهای  $S$  و  $D$  که در حالت پیوسته، مقادیر پیوسته‌ای داشته‌اند، در حالت گسسته مقادیر گسسته‌ای به خود می‌گیرند و پیاده‌سازی تبدیل به‌صورت ساده‌تری انجام می‌گیرد.

۱- هم‌چنین در برخی از موارد ممکن است به یک تابع غیر تحلیلی برخورد شود که امکان انتگرال‌گیری از آن وجود نداشته باشد و یا این‌که انتگرال جواب خاصی نداشته باشد

## مدل پیشنهادی (NEW)

به نظر می‌رسد مدل پیشنهادی برای اولین بار در تجزیه و تحلیل و پیش‌بینی سری زمانی تقاضای کوتاه‌مدت برق مورد استفاده قرار می‌گیرد و اطلاعات مفیدی را از تأثیرگذاری رویدادهای مختلف بر روی سری زمانی ارائه می‌دهد. این مدل تلفیقی از مدل‌های ARIMA و تبدیل موجک به همراه شبکه‌های عصبی شعاع‌مدار می‌باشد.

در مرحله‌ی نخست با استفاده از موجک (از نوع دبوچی)، سری زمانی تا سطحی تجزیه می‌شود که سطح هموار شده (تقریبی) به صورت یک خط نسبتاً هموار دربیاید و با در نظر گرفتن این نکته که مدل ARIMA در پیش‌بینی سری‌های خطی قدرت بالایی دارد (صادقی، ذوالفقاری، ۱۳۸۸)، این سری به وسیله‌ی آن پیش‌بینی می‌شود. در مرحله‌ی بعد با جمع کردن توابع جزئیات (مؤلفه‌ها) یک سری به دست می‌آید که روند زدایی شده و فقط شامل نوسانات در طول دوره است. از آن جایی که:

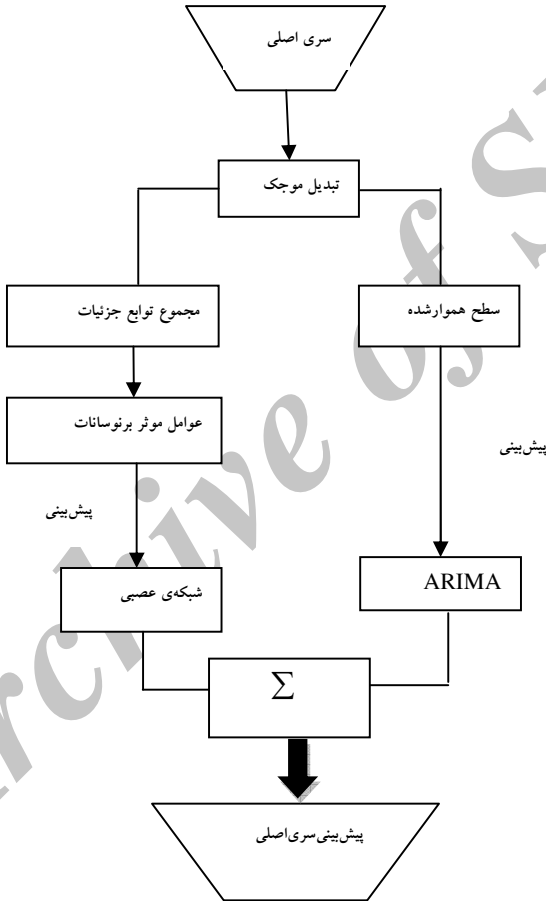
سری اصلی = سری سطح هموار شده (تقریبی) + مجموع سری‌های توابع جزئیات (مؤلفه‌ها)  
در ادامه نوسانات فیلتر شده (مجموع سری‌های توابع جزئیات) در شبکه‌ی عصبی مدل‌سازی می‌شود. بنابراین با افزایش سطوح تجزیه (افزایش سری‌های توابع جزئیات) هیچ یک از اطلاعات مربوط به سری زمانی حذف نمی‌شود، در مرحله‌ی بعد عوامل تأثیرگذار بر این نوسانات را تعیین می‌شود. با تعیین عوامل تأثیرگذار بر این نوسانات، آن‌ها را به عنوان متغیرهای توضیحی این نوسانات به عنوان 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 تأثیرگذار برای آینده، پیش‌بینی نموده و آن را با مقادیر پیش‌بینی‌شده‌ی سری هموار شده توسط ARIMA جمع می‌شود، که در نتیجه پیش‌بینی سری اصلی به دست می‌آید.

این مدل دارای ۲ مزیت قابل توجه است، اولاً سه مدل خطی و غیرخطی ARIMA، شبکه‌ی عصبی و تبدیل موجک را با هم تلفیق می‌کند که در این زمینه نقاط ضعف هر یک از مدل‌ها در پیش‌بینی با نقاط قوت مدل دیگری حذف یا کم رنگ‌تر می‌شود. ثانیاً

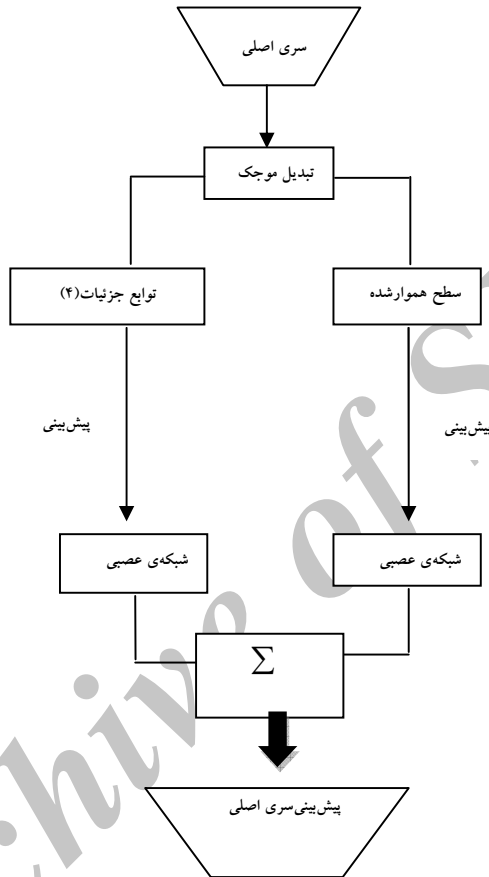
این مدل با در نظر گرفتن سری زمانی، عوامل تأثیرگذار بر این سری را نیز در مدل دخیل می کند که قاعدتاً می بایستی قدرت پیش بینی سری زمانی را افزایش دهد.<sup>۱</sup>

اشکال (۶) و (۷)، ساختار استفاده از مدل پیشنهادی و شبکه ی عصبی RBF - تبدیل موجک را نشان می دهد:



شکل ۶ - ساختار مدل پیشنهادی

۱- در مدلی که توسط صادقی و ذوالفقاری (۱۳۸۸) برای پیش بینی گاز طبیعی انجام گرفته، از شبکه ی عصبی پرسپترون استفاده شده در صورتی که در مدل AWNN شبکه ی عصبی شعاع مدار به کار رفته است.



شکل ۷- ساختار شبکه‌ی عصبی RBF تبدیل موجک


#### ۴- یافته‌های تحقیق

داده‌های مورد استفاده در این تحقیق آمار روزانه‌ی تقاضای برق کشور برای دوره‌ی ۱۳۸۴/۱۱/۶ تا ۱۳۸۸/۱۲/۱۴ می‌باشد که در مجموع ۱۵۰۰ مشاهده را دربرمی‌گیرد. این داده‌ها از دو بخش تشکیل شده‌اند. نخست از تاریخ ۱۳۸۴/۱۱/۶ تا ۱۳۸۸/۱۲/۴ (۱۴۹۰ مشاهده) برای تخمین مدل ARIMA، هم‌چنین آموزش و مدل‌سازی شبکه‌ی عصبی شعاع‌مدار و تبدیل موجک و بخش دوم از ۱۳۸۸/۱۲/۵ تا ۱۳۸۸/۱۲/۱۴ برای پیش‌بینی و مقایسه‌ی مدل‌های مذکور مورد استفاده قرار می‌گیرد. داده‌های تقاضای



روزانه‌ی برق کشور از شرکت مدیریت شبکه‌ی برق ایران، وابسته به وزارت نیرو و آمار مربوط به دمای هوا (حداکثر، حداقل و متوسط)، ساعات روشنایی و تاریکی از سازمان هواشناسی به‌دست آمده است.

نمودار (۱)، روند خطی تقاضای روزانه‌ی برق کشور را برای دوره‌ی ۱۳۸۴/۱۱/۶ تا ۱۳۸۸/۱۲/۴ نشان می‌دهد. در حالت کلی تقاضای برق با توجه به روند سالیانه‌ی آن در حال افزایش است (به‌طور متوسط با رشد سالیانه ۶.۶ درصد). نکته‌ی قابل توجه در تقاضای برق، نوسانات فصلی آن می‌باشد به‌گونه‌ای که در ماه‌های گرم سال، تقاضا برای برق افزایش می‌یابد که مهم‌ترین دلیل آن را می‌توان استفاده از وسایل خنک‌کننده دانست که انرژی زیادی می‌طلبد. همچنین طولانی بودن ساعات‌های روشنایی با توجه به دمای بالای هوا، زمان استفاده از این وسایل را افزایش می‌دهد. البته با توجه به کم بودن ساعات تاریکی میزان مصرف وسایل روشنایی کاهش می‌یابد. یکی از دلایل دیگر برای تفهیم این نوسانات ذکر این مطلب است که بسیاری از فعالیت‌هایی که در محیط‌های باز انجام می‌گیرند (مانند فعالیت‌های عمرانی) در ماه‌های سرد به‌ویژه در مناطق سردسیر با توجه به دمای پایین هوا تعطیل می‌شوند و یا کاهش می‌یابند و در ماه‌های گرم سال این فعالیت‌ها دوباره شروع می‌شوند و در نتیجه به سهم خود در مصرف برق تأثیر می‌گذارند (برای مثال عملیات جوشکاری و عمرانی). نکته دیگر در مورد تقاضای برق نوسانات روزانه‌ی آن است. در ایام تعطیلات مصرف روزانه کاهش



مأخذ: مدیریت شبکه‌ی برق ایران (وزارت نیرو)

نمودار ۱- تقاضای روزانه‌ی برق کشور (۱۳۸۴/۱۱/۶ تا ۱۳۸۸/۱۲/۴)

می‌یابد (با توجه به زیاد بودن داده‌ها در نمودار (۱)، برخی از این نوسانات به‌ویژه ایام عید نوروز قابل رؤیت می‌باشد). به طول معمول در روزهای اول هفته مصرف برق افزایش می‌یابد و در اواخر هفته به‌ویژه پنجشنبه‌ها مصرف روند کاهنده‌ای را طی می‌کند و در روز جمعه، مصرف به پایین‌ترین حد خود می‌رسد و دوباره با آغاز هفته این روند تکرار می‌شود.

## ARIMA

برای پیش‌بینی داده‌های سری زمانی توسط ARIMA، ابتدا مانای سری زمانی بررسی و مرتبه‌ی انباشتگی (d) تعیین می‌شود. در مطالعه‌ی حاضر برای آزمون ریشه‌ی واحد متغیر سری زمانی از آزمون دیکی فولر تعمیم یافته<sup>۱</sup> استفاده شده است. از آنجایی که سری زمانی تقاضای روزانه‌ی برق برای دوره‌ی (۱۳۸۴/۱۱/۶) تا (۱۳۸۸/۱۲/۴) دارای روند فصلی (نوسانات سالیانه) می‌باشد، ابتدا به‌صورت سالیانه (Δ۳۶۵) روند زدایی و سپس با تفاضل‌گیری مرتبه‌ی (۱) مانا شده است. تعداد جملات خودرگرسیو (p) و تعداد جملات میانگین متحرک (q) نیز با استفاده از توابع خودهمبستگی (AC) و خودهمبستگی جزئی (PAC) بر اساس مراحل باکس-جنکینز محاسبه شده و سپس براساس معیارهای آکائیک و بیزین - شوارتز مورد بازبینی قرار گرفته است. بر این اساس کم‌ترین مقدار آکائیک و بیزین - شوارتز، مربوط به فرایند تعداد جملات خودرگرسیو و میانگین متحرک می‌باشد که نتایج تفصیلی حاصل از برآورد آن، در جدول (۱) ارائه شده است.

جدول ۱- نتایج حاصل از برآورد تقاضای روزانه‌ی برق (۱۳۸۴/۱۱/۶ - ۱۳۸۸/۱۲/۴)

نام متغیر	ضریب	خطای معیار	نام متغیر	ضریب	خطای معیار
C	-۲.۳۱	-۰.۲۸	AR (۵)	-۰.۲۱	-۷.۳۸
AR(1)	-۰.۲۳	-۷.۶۵	AR (۶)	-۰.۲۴	-۸.۰۲
AR(2)	-۰.۲۸	-۹.۴۹	AR (۷)	۰.۴۶	۱۵.۶۹
AR(3)	-۰.۲۲	-۷.۴۱	AR (۸)	-۰.۰۸	-۲.۵۴
AR(4)	-۰.۲۲	-۷.۴۲	MA(1)	-۰.۹۸	-۱۶۹.۳
$\bar{R}^2 = ۰.۸۰$			$F = ۴۷۳$		

ماخذ: یافته‌های تحقیق

در جدول (۱) همه‌ی جملات خودرگرسیو و میانگین متحرک در سطح خطای  $0/01$  از نظر آماری معنی‌دار می‌باشند. کل مدل معنی‌دار می‌باشد و تقاضای روزهای گذشته و جملات اخلاص مذکور در جدول (۱)،  $80$  درصد از تغییرات تقاضای روزانه‌ی برق کشور را توضیح می‌دهند.

### شبکه‌ی عصبی شعاع‌مدار

با توجه به اهداف تحقیق از انواع مختلفی از شبکه‌های عصبی مصنوعی می‌توان استفاده کرد. در این تحقیق شبکه‌ی عصبی شعاع‌مدار (RBF) به کار رفته است. جدول (۲)، چگونگی طراحی و مدل‌سازی تقاضای روزانه‌ی برق را در شبکه‌ی عصبی شعاع‌مدار نشان می‌دهد.

جدول ۲- طراحی و مدل‌سازی تقاضای روزانه‌ی برق در شبکه‌ی عصبی شعاع‌مدار


نوع شبکه‌ی عصبی	Radial Basis Function	تعداد نرون در لایه‌ی پنهان دوم و تابع آموزش	TANSIG, 10
تابع آموزش	TrainLM	تعداد نرون در لایه‌ی ورودی	۱
تعداد مشاهدات	۱۵۰۰	تعداد نرون در لایه‌ی خروجی	۱
تابع یادگیری تعدیل شده	LearnGDM	دوره‌ی زمانی آموزش و آزمایش	۱۳۸۸/۱۲/۴ - ۱۳۸۴/۱۱/۶
معیار ارزیابی	MSE	نسبت تعداد داده‌های آموزش و آزمایش	۰/۹۰ به ۰/۱۰
تعداد لایه‌های پنهان	۲	نرخ یادگیری	۰/۰۱
تعداد نرون در لایه‌ی پنهان اول و تابع آموزش	TANSIG, 10	دوره‌ی زمانی پیش‌بینی	۱۳۸۸/۱۲/۱۴ - ۱۳۸۴/۱۲/۵

لازم به ذکر است 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 مدل شبکه‌ی عصبی و شبکه‌ی عصبی همراه با تبدیل موجک، یکسان می‌باشد.

### طراحی مدل تلفیقی پیشنهادی

در این روش ابتدا سری‌زمانی تقاضای برق، به‌صورت 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 به‌دست آورده شده و بعد برای هر مؤلفه‌ی (تابع جزئیات) تجزیه شده از سری اولیه، یک مدل شبکه‌ی عصبی طراحی می‌شود. آنچه باقی می‌ماند یک سری تقریبی (همراه شده) می‌باشد که آن نیز با شبکه‌ی عصبی مدل‌سازی می‌شود. این مدل، مدل شبکه‌ی عصبی - تبدیل موجک<sup>۱</sup> (WDNN) نامیده می‌شود. پیش‌بینی سری اصلی از مجموع پیش‌بینی سری هموار شده و مؤلفه‌ها به‌دست می‌آید. برای بررسی عملکرد سطح تجزیه، داده‌ها با استفاده از موجک دبوچی ۴ تا ۴ سطح شکافته و سطح هموار شده با جزئیات سطوح یک تا سه به‌دست آورده شده و هر یک با استفاده از شبکه‌ی عصبی مدل‌بندی می‌شوند.

از تفسیر آمار روزانه‌ی تقاضای برق در بخش قبل به یاد داریم که این سری زمانی با در نظر 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 هموار شده (تقریبی) به‌صورت یک خط نسبتاً هموار دربیاید (سری تقاضای روزانه‌ی برق تا ۱۰ سطح شکافته شد) و با در نظر گرفتن این نکته که مدل ARIMA در پیش‌بینی سری‌های خطی قدرت بالایی دارد، این سری به‌وسیله‌ی مدل ARIMA برای ۱۰ روز بعد پیش‌بینی می‌شود. نمودار (۸)، سطح هموار شده (تقریبی) را برای تقاضای روزانه‌ی برق نشان می‌دهد.




نمودار ۸- سری زمانی هموار شده (تقریبی) تقاضای روزانه‌ی برق برای پیش‌بینی ARIMA (A approx.level 10 for db4)

در مطالعه‌ی حاضر سری زمانی تقاضای روزانه‌ی برق برای دوره‌ی (۱۳۸۳/۱۱/۶) تا (۱۳۸۷/۱۲/۴) با تفاضل‌گیری مرتبه‌ی (۲) مانا و سپس تعداد جملات خودرگرسیون (p) و تعداد جملات میانگین متحرک (p)، با استفاده از توابع خودهمبستگی (AC) و خودهمبستگی جزئی (PAC) بر اساس مراحل باکس-جنکینز محاسبه شده است. اما از آن‌جایی که ممکن است مدل‌های دیگری وجود داشته باشند که مقدار آکائیک یا شوارتز کم‌تری داشته باشند و بر الگوی مذکور ترجیح داده شوند، مدل‌های دیگری نیز بررسی شده‌اند. بر این اساس کم‌ترین مقدار آکائیک و شوارتز بی‌زین مربوط به فرایند تعداد جملات خودرگرسیون و میانگین متحرک می‌باشد که نتایج تفصیلی حاصل از برآورد آن در جدول (۳) آورده شده است.

جدول ۳- نتایج حاصل از برآورد دوره‌ی ۱۳۸۷/۱۲/۴ - ۱۳۸۳/۱۱/۶

نام متغیر	ضریب	خطای معیار	نام متغیر	ضریب	خطای معیار
C	-۲,۵۴	-۱,۴E-۰۹	AR (3)	۱۹,۹	۰,۵۴
AR(1)	۳۵,۶۲	۰,۸۳	AR (4)	-۲۰,۷	-۰,۵۸
AR(2)	-۱۶,۰۶	-۰,۴۵	AR (5)	۱۷,۹۲	۰,۴۲
		$\bar{R}^2 = ۰,۵۵$			F= ۳۵۴

در مرحله‌ی بعد با جمع کردن سایر توابع جزئیات یک سری به‌دست می‌آید که روند زدایی شده و فقط شامل نوسانات در طول دوره است. نمودار (۹) این سری را نمایان می‌کند.



ماخذ: خروجی MATLAB

نمودار ۹- مجموع توابع جزئیات (مؤلفه‌ها) تقاضای روزانه‌ی برق

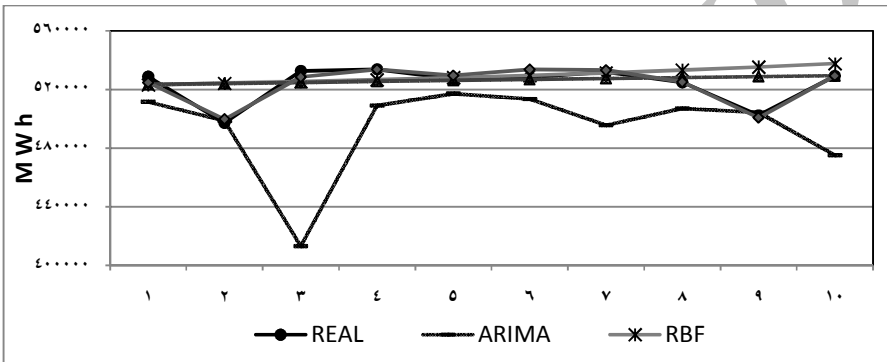
سپس عوامل تأثیرگذار بر این نوسانات تعیین می‌شوند. مهم‌ترین عوامل مؤثر بر تقاضای روزانه‌ی برق، درجه‌ی دما (حداکثر، حداقل و متوسط)، میزان ساعات روشنایی<sup>۱</sup> (در ماه‌های گرم از طریق استفاده از وسایل خنک‌کننده با توجه به ساعات روشنایی زیاد و در ماه‌های سرد استفاده از وسایل روشنایی با توجه به ساعات تاریکی زیاد)، روزهای هفته، ایام تعطیلات و روزهای خاص (مانند ماه رمضان و .....) می‌باشند که در لایه‌ی ورودی شبکه‌ی عصبی منعکس می‌شوند. حال در طراحی و مدل‌سازی شبکه‌ی عصبی RBF، ۱۲ نرون ورودی و یک نرون خروجی که همان مجموعه توابع جزئیات روندزدایی شده می‌باشد، به کار می‌رود. بقیه‌ی ویژگی‌ها همانند آن‌چه که در بخش ۴-۲ بیان شد می‌باشد و از توضیح دوباره‌ی آن صرفه نظر می‌شود.

در نهایت برای ۱۰ روز بعدی، روند خطی پیش‌بینی شده توسط ARIMA با نوسانات آن که بر اساس شبکه‌ی عصبی پیش‌بینی شده، جمع می‌شود و پیش‌بینی سری اصلی به‌دست می‌آید.

۱- برای تعیین ساعات روشنایی، فاصله‌ی زمانی بین طلوع و غروب خورشید در نظر گرفته شده است. (ماخذ: سازمان هواشناسی کشور).

## ۵- ارزیابی مدل‌های پیش‌بینی

نمودار (۱۰)، مقادیر پیش‌بینی شده توسط شبکه‌ی عصبی شعاع‌مدار (RBF)، شبکه‌ی عصبی شعاع‌مدار- تبدیل موجک (WDNN)، فرایند ARIMA و مدل پیشنهادی (NEW) به همراه مقادیر واقعی برای ۱۰ روز آینده (۱۳۸۷/۱۲/۵) تا (۱۳۸۷/۱۲/۱۴) را نشان می‌دهد.



ماخذ: یافته‌های تحقیق

نمودار ۱۰- مقادیر پیش‌بینی شده‌ی تقاضای روزانه‌ی برق برای ۱۰ روز آتی

با توجه به نمودار (۱۰)، روند مقادیر واقعی تقاضای برق برای ۱۰ روز آتی بیانگر این مطلب است که تقاضا در روزهای جمعه (روزها ۲ و ۹) به پایین‌ترین مقدار خود می‌رسد که مهم‌ترین دلیل آن تعطیلی بسیاری از سازمان‌های دولتی و غیردولتی و در نتیجه کاهش مصرف است. با آغاز هفته تقاضا افزایش یافته و در بقیه‌ی روزها نیز از یک روند نسبتاً پایداری برخوردار است. با نزدیک شدن به روزهای آخر هفته و به‌ویژه پنجشنبه مصرف تا حدودی کاهش می‌یابد که تعطیلی برخی سازمان‌ها و فعالیت پاره‌وقت برخی دیگر از سازمان‌ها در این روز می‌تواند دلیل کاهش مصرف باشد. این روند در روزهای بعد نیز ادامه دارد.

به منظور مقایسه‌ی قدرت پیش‌بینی مدل‌های پیش‌بینی، از معیارهای میانگین مربع خطای استاندارد (MSE)، مجذور میانگین مربع خطا استاندارد (RMSE)، میانگین قدر مطلق خطا (MAE) و میانگین درصد قدر مطلق خطا (MAPE) به صورت گام‌به‌گام (روزیکه تا روز دهم) استفاده شده، که نتایج آن در جدول (۴) آمده است.

دلیل استفاده از پیش‌بینی نوع گام‌به‌گام (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 مدل‌های 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 دوره‌ی ۱۳۸۷/۱۲/۵ - ۱۳۸۷/۱۲/۱۴ محاسبه شده‌اند.

جدول ۴ - مقایسه‌ی قدرت پیش‌بینی مدل‌های شبکه‌ی عصبی و ARIMA

ARIMA A	RBF	عصبی - موجک	NEW	گام	معیار	ARIMA	RBF	عصبی - موجک	NEW	گام	معیار
۱۷۱۰۲	۵۵۷۴	۵۳۸۷	۴۰۹۸	۱	MAE	۲۹۲۴۷۷۲۰۹	۳۱۰۷۴۸۳۷	۲۹۰۲۰۱۶۰	۱۶۷۹۸۰۳۸	۱	MSE
۹۱۹۸	۱۶۲۲۸	۱۶۰۷۴	۳۲۲۶	۲		۱۴۷۰۷۶۱۶۴	۳۷۶۸۵۰۶۴۹	۳۷۲۵۷۷۴۴۸	۱۱۲۱۶۴۳۹	۲	
۴۵۹۹۱	۱۳۲۵۰	۱۳۳۳	۳۵۲۵	۳		۴۸۶۴۱۹۱۱۸۷	۲۶۸۹۶۵۹۵۳	۲۶۸۹۳۵۲۹۸	۱۳۰۹۳۴۳۸	۳	
۴۰۶۸۲	۱۱۷۰۹	۱۲۰۵۵	۲۶۴۴	۴		۳۸۰۱۳۴۹۱۸۲	۲۱۴۲۷۹۱۶۳	۲۱۸۶۰۰۱۴۰	۹۸۲۰۰۸۰	۴	
۳۴۵۶۰	۹۵۳۶	۹۸۴۸	۲۵۷۹	۵		۳۰۶۱۳۶۸۸۵۸	۱۷۱۵۶۶۰۱۸	۱۷۵۰۸۷۵۷۵	۸۹۳۱۵۴۴	۵	
۳۱۲۷۴	۸۱۵۸	۸۴۵۴	۳۰۲۵	۶		۲۵۸۷۸۸۲۴۴۶	۱۴۳۲۴۰۲۹۹	۱۴۶۲۷۳۹۱۷	۱۲۰۴۲۷۴۷	۶	
۳۱۹۹۵	۷۰۶۷	۷۸۶۷	۲۷۷۶	۷		۲۴۰۶۶۳۴۲۷۹	۱۲۲۸۱۶۳۷۹	۱۲۸۰۷۴۷۰۹	۱۰۵۵۶۵۷۱	۷	
۳۰۲۲۴	۷۲۳۲	۷۲۹۶	۲۴۵۴	۸		۲۱۴۵۵۱۶۶۷۸	۱۱۶۲۴۵۵۸۱	۱۱۳۴۲۶۹۵۵	۹۲۴۲۰۴۱	۸	
۲۷۰۷۴	۱۰۰۹۳	۹۴۲۳	۲۳۵۵	۹		۱۹۰۷۵۱۶۷۴۰	۲۲۴۲۲۵۱۶۳	۱۷۸۵۰۴۵۷۰	۸۴۸۵۵۸۴	۹	
۲۹۷۲۴	۹۹۲۲	۸۴۹۶	۲۱۲۱	۱۰		۲۰۰۹۱۳۷۸۴۸	۲۰۸۸۲۰۲۴۵	۱۶۰۶۵۶۲۸۹	۷۶۳۸۲۹۵	۱۰	
۳۰۲۳	۱۰۰۵۴	۱۰۰۲	۰۰۷۷	۱	MAPE	۱۷۱۰۲	۵۵۷۴	۵۳۸۷	۴۰۹۸	۱	RMSE
۱۰۷۴	۳۰۲۳	۳۰۲	۰۰۶۲	۲		۱۲۱۲۷	۱۹۴۱۲	۱۹۳۰۲	۳۳۴۹	۲	
۸۶۴	۲۶۱	۲۶۲	۰۰۶۷	۳		۶۹۷۴۴	۱۶۴۰۰	۱۶۳۹۹	۳۶۱۸	۳	
۷۶۴	۲۰۲۹	۲۰۳۵	۰۰۵۱	۴		۶۱۶۵۵	۱۴۶۳۸	۱۴۷۸۵	۳۱۳۳	۴	
۶۰۴۹	۱۰۸۶	۱۰۹۲	۰۰۴۹	۵		۵۵۳۲۹	۱۳۰۹۸	۱۳۲۳۲	۲۹۸۸	۵	
۵۸۸	۱۰۵۹	۱۰۶۵	۰۰۵۷	۶		۵۰۸۷۱	۱۱۹۶۸	۱۲۰۹۴	۳۴۷۰	۶	
۶۰۰۲	۱۰۳۸	۱۰۵۳	۰۰۵۲	۷		۴۹۰۵۷	۱۱۰۸۲	۱۱۳۱۷	۳۳۴۹	۷	
۵۶۹	۱۰۴۱	۱۰۴۲	۰۰۴۶	۸		۴۶۳۱۹	۱۰۷۸۱	۱۰۶۵۰	۳۰۴۰	۸	
۵۱۰	۱۰۹۸	۱۰۸۵	۰۰۴۵	۹		۴۳۶۷۵	۱۴۹۷۴	۱۳۳۶۰	۲۹۱۳	۹	
۵۶۱	۱۰۹۴	۱۰۶۶	۰۰۴۱	۱۰		۴۴۸۲۳	۱۴۴۵۰	۱۲۶۷۵	۲۷۶۳	۱۰	

ماخذ: یافته‌های تحقیق



با توجه به جدول (۴) بر اساس هر ۴ معیار ارزیابی، مدل پیشنهادی (NEW) در تمام گام‌ها دارای کم‌ترین خطای پیش‌بینی و نسبت به بقیه‌ی مدل‌ها از دقت بالایی در پیش‌بینی برخوردار می‌باشد. پس از مدل پیشنهادی (NEW)، شبکه‌ی عصبی RBF - تبدیل موجک بر اساس معیارها MSE و RMSE در گام‌های ۱ تا ۳ و گام‌های ۸ تا ۱۰ نسبت به شبکه‌ی عصبی RBF دارای خطای پیش‌بینی کم‌تری می‌باشد و در بقیه‌ی گام‌ها (۴ تا ۷) شبکه‌ی عصبی RBF نسبت به شبکه‌ی عصبی RBF - تبدیل موجک دارای دقت بالای پیش‌بینی است. براساس معیارهای MAE و MAPE، پس از مدل پیشنهادی (NEW)، شبکه‌ی عصبی RBF - تبدیل موجک در گام‌های ۱، ۲، ۹ و ۱۰ نسبت به شبکه‌ی عصبی RBF دارای خطای پیش‌بینی کم‌تری می‌باشد و در بقیه‌ی گام‌ها (۳ تا ۸) شبکه‌ی عصبی RBF نسبت به شبکه‌ی عصبی RBF - تبدیل موجک دارای دقت پیش‌بینی بالایی است. مدل ARIMA نیز از نظر پیش‌بینی بر اساس هر چهار معیار و در همه‌ی گام‌ها در اولویت آخر قرار دارد. در مجموع مدل پیشنهادی (NEW) با در نظر گرفتن عوامل مؤثر بر تقاضای برق به‌ویژه با پیاده‌سازی یک الگوی تلفیقی از مدل‌های خطی و غیرخطی، دارای قدرت بالایی در پیش‌بینی تقاضای روزانه‌ی برق می‌باشد.

## ۶- نتیجه‌گیری

امروزه انرژی الکتریکی به‌دلیل ارتباط با بخش‌های مختلف اقتصادی (در قالب نهاده یا کالای نهایی)، نقش قابل توجهی در فرایند اتخاذ تصمیمات اقتصادی و پیشبرد اهداف توسعه‌ی کشورها ایفا می‌کند. آگاهی از رفتار مصرف‌کنندگان نسبت به تقاضای آن‌ها برای انرژی برق در آینده عاملی مهم در سیاست‌گذاری‌ها می‌باشد، به‌طوری‌که با آگاهی و اطلاعات درست در این مورد می‌توان تعادل بین عرضه و تقاضا را در آینده ایجاد کرد. از این‌رو پیش‌بینی میزان تقاضای برق در هر دوره، به‌ویژه در دوره‌های کوتاه‌مدت - امری مهم می‌باشد.

در این مطالعه با ارائه‌ی مدل پیشنهادی که تلفیقی از مدل‌های خطی و غیرخطی ARIMA، شبکه‌ی عصبی RBF و تبدیل موجک می‌باشد، به پیش‌بینی کوتاه‌مدت تقاضای برق پرداخته شده است. در مدل پیشنهادی با در نظر گرفتن مؤلفه‌های شرایط آب و هوایی و سیستم اقلیمی کشور، متغیرهای مؤثر بر میزان مصرف روزانه‌ی برق

در نظر گرفته شده است. در ادامه برای بررسی دقت پیش‌بینی مدل مذکور به مقایسه‌ی آن با مدل خطی ARIMA و مدل‌های غیرخطی شبکه‌ی عصبی RBF و شبکه‌ی عصبی RBF - تبدیل موجک براساس معیارهای ارزیابی RMSE، MAE، MAPE برای بازه‌ی زمانی "یک گام تا ده گام به جلو" پرداخته شده است. نتایج تحقیق نشان می‌دهد که براساس همه‌ی معیارهای ارزیابی و در تمام گام‌ها، مدل پیشنهادی از دقت بالایی در پیش‌بینی روزانه‌ی برق نسبت به سایر مدل‌های پیش‌بینی برخوردار می‌باشد. پس از مدل پیشنهادی، شبکه‌ی عصبی RBF - تبدیل موجک، شبکه‌ی عصبی RBF و فرآیند ARIMA در اولویت‌های بعدی با خطای پیش‌بینی کم‌تر قرار گرفته‌اند.

### فهرست منابع

- ابریشمی، حمید و مهرآرا، محسن (۱۳۸۱)، اقتصادسنجی کاربردی (رویکردهای نوین)، انتشارات دانشگاه تهران، تهران، مؤسسه‌ی انتشارات و چاپ دانشگاه تهران، چاپ اول.
- پیکتن، فلیپ، ترجمه‌ی مهدی غضنفری و جمال ارکات (۱۳۸۳)، شبکه‌های عصبی، اصول و کاربردها، تهران، مؤسسه‌ی انتشارات علمی دانشگاه صنعتی علم و صنعت ایران.
- صادقی، حسین و ذوالفقاری، مهدی (۱۳۸۹)، مبانی مدل‌های پیش‌بینی در علوم اقتصادی، تهران، انتشارات نور علم، چاپ اول.
- اصغری اسکویی، محمدرضا (۱۳۸۱)، کاربرد شبکه‌های عصبی در پیش‌بینی سری‌های زمانی، فصل‌نامه‌ی پژوهش‌های اقتصادی ایران، شماره‌ی ۱۲، پاییز، صص ۶۹-۹۵.
- احمدی، علی محمد، ذوالفقاری، مهدی و غفارنژاد، آیدین (۱۳۸۸)، مطالعه‌ی تطبیقی شبکه‌های عصبی و مدل ARIMA در پیش‌بینی نیاز داخلی برق کشور، پژوهش‌های اقتصادی ایران، شماره‌ی ۴۱، صص ۱۰۲-۷۹.
- بهرادمهر، 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.

ذوالفقاری، مهدی (۱۳۸۸)، طراحی مدلی نوین جهت پیش‌بینی کوتاه‌مدت برق کشور، پایان‌نامه‌ی کارشناسی ارشد، دانشکده‌ی اقتصاد و مدیریت، دانشگاه صنعت آب و برق (شهید عباسپور).

صادقی، حسین و ذوالفقاری، مهدی (۱۳۸۸)، طراحی مدلی نوین جهت پیش‌بینی تقاضای کوتاه‌مدت گاز طبیعی در بخش خانگی، فصل‌نامه‌ی مطالعات اقتصاد انرژی، شماره‌ی ۲۳، صص ۴۱-۷۸.

کمانکش، سیما، برقی نیا سعید و غفاری، آزاد (۱۳۸۶)، پیش‌بینی بار کوتاه‌مدت شبکه‌ی برق ایران با در نظر گرفتن شرایط خاص نظیر روزهای قبل و بعد و بین تعطیلی و سال‌های کبیسه و تهیه‌ی قوانین خبره‌ی فازی، بیست و دومین کنفرانس بین‌المللی صنعت برق.

قاسمی، عبدالرسول، اسدپور، حسن و شاه‌صادقی، مختار (۱۳۷۹)، کاربرد شبکه‌ی عصبی در پیش‌بینی سری‌های زمانی و مقایسه‌ی آن با مدل ARIMA، فصل‌نامه‌ی پژوهشنامه‌ی بازرگانی، سال چهارم، شماره‌ی ۱۴، صفحات ۱۲۰-۸۷.

عباسی‌نژاد، حسین، محمدی، احمد (۱۳۸۶)، پیش‌بینی نرخ ارز با استفاده از شبکه‌های عصبی و تبدیل موجک، نامه‌ی مفید، ج ۳، شماره‌ی ۱، صص ۱۹-۴۲.

غفاری نژاد، آیدین (۱۳۸۸)، پیش‌بینی بار کوتاه‌مدت با استفاده از مدل‌های خبره و هوش مصنوعی، پایان‌نامه‌ی کارشناسی ارشد، دانشکده‌ی مکانیک، دانشگاه صنعت آب و برق (شهید عباسپور).

صیادی، حبیب، ابوالفتح اولاد غفاری، احد فعالیان و علی اشرف صدرالدینی (۱۳۸۸)، مقایسه‌ی عملکرد شبکه‌های عصبی RBF و MLP در برآورد تبخیر و تعرق گیاه مرجع، مجله‌ی دانش آب و خاک، جلد ۱۹، شماره ۱، صص ۱۲-۱.

علی اشرف صدرالدینی (۱۳۸۸)، مقایسه‌ی عملکرد شبکه‌های عصبی RBF و MLP در برآورد تبخیر و تعرق گیاه مرجع، مجله‌ی دانش آب و خاک، جلد ۱۹، شماره‌ی ۱، صص ۱۲-۱.

Azadeh, S.F. Ghaderi and S. Sohrabkhani(2008), A Simulated-Based Neural Network Algorithm for Forecasting Electrical Energy Consumption in Iran, International Journal of Energy Policy, 36, Issue 7, 2637-2644. [www.SID.ir](http://www.SID.ir)

Bai-LingZhang, Zhao-Yang Dong (2001), Anadaptive Neural-Wavelet Model for Short term Load Forecasting, Electric Power Systems Research, 59, 2001, 121–129.

Beccali, 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, 12, 2040-2065.

Benaouda,F. Murtagh, J.-L. Starck and O. Renaud (2008), Short-Run Load Forecasting by Wavelet-Based Nonlinear Multiscale Decomposition Model, journal of forecasting, 30, 1984-1998.

Conejoa, Antonio J., Javier Contrerasa, Rosa Espínola, Miguel A. Plazas(2005), Forecasting Electricity Prices for a Day-Ahead Pool-Based Electric Energy Market, International Journal of Forecasting, 21 435– 462.

Darbellay, Marek Slama. (2000), Forecasting the Short- Term for Electricity: Do Neural Networks Stand a Better Chance?, Forecasting, 16, 71-83.

Frank, O., louse, K. and K. James, (2008), Forecasting the electricity energy consumption of Spanish by Fourier Series and Neural Network Models, forecasting, Volume 23, pages 137-151.

Hamzaçebi, Coşkun (2007), Forecasting of Turkey's Net Electricity Energy Consumption on Sectoral Bases, Energy Policy 35, Issue 3, 2009-2016.

Hsiao-Tien Pao (2006), Comparing Linear and Nonlinear Forecasts for Taiwan's Electricity Consumption, Energy, Energy Policy, 31, Issue 12, 2129-2141.

James, K., louse, K. and F. Oliviera (2006), Short Term Load Forecasting Using Double Seasonal ARIMA and neural network Model, Mathematics and Computation, 183(1): 1732-1751.

Leonard, J. A. and Kremer, M. A. and Ungar, L. A.(1992), Using Radial Basis Function to Approximate a Function and its Error Bounds, IEEE Transactions on Neural Networks, 3(4), 624-7

Leonard, J. A. and Kremer, M. A.(1991), Radial Basis Function Networks for Classifying Process Faults, IEEE Control Systems Magazine, April 1991, 31-38.

Mandal, Paras, Tomonobu Senjyu, and Toshihisa Funabashi (2006), Neural Networks Approach to Forecast Several Hour Ahead Electricity Prices and Loads in Deregulated Market, journal of Energy Conversion and Management 47., 2128-2142.

Mitra, Gh. (2005), Application of wavelet transform in Econometrics, Oxford University Press, London.

Ramsey, k., and F. Anderson (2002), an introduction to wavelet transform, Fifth Conference on Artificial Intelligence, University of Liverpool.

Romera, Gonzalez, M.A. Jaramillo-Moran, D. Carmona-Fernandez (2008), Monthly Electric Energy Demand Forecasting with Neural Networks, Energy Conversion and Management, 49, 3135–3142.

Tabatabaei, N., S. Mortezaei, S. Alzakeriny, S. Ozen & A. Nayir .(2008). Short Term Load Forecasting by Neural Network in Mashhad (IRAN) Power Syastem. 4t International Conference on “Technical and Physical Problems of Power Engineering”, University of Pitesti, Pitesti, Romania

Tai Nengling , Jurgen Stenzel, Wu Hongxiao(2006), Techniques of Applying Wavelet Transform in to Combined Model for Short-Term Load Forecasting, Electric Power Systems Research, 76, 525–533.

Archive of SID