

پیش‌بینی کوتاه مدت تقاضای برق کشور با استفاده از شبکه‌های عصبی و تبدیل موجک

دکتر حسین صادقی، مهدی ذوالفقاری *

تاریخ وصول: 1388/12/10 تاریخ پذیرش: 1389/6/29

چکیده:

آگاهی از میزان تقاضای انرژی برق در هر دوره، به منظور برنامه‌ریزی دقیق و اعمال سیاست‌گذاری‌های لازم، امری ضروری است. از این رو، پیش‌بینی تقاضای آن، برای بخش‌های مختلف اقتصادی حائز اهمیت است. در این مقاله به مطالعه تطبیقی روش‌های غیرخطی شبکه‌های عصبی مصنوعی و تبدیل موجک - شبکه‌ی عصبی و فرایند خطی ARMA در پیش‌بینی تقاضای روزانه برق در بازه‌ی زمانی یک تا ده‌گام به جلو پرداخته شده است. نتایج حاصل از به کارگیری معیارهای سنجش RMSE و MAPE نشان داد که مدل‌های غیرخطی تبدیل موجک و شبکه‌ی عصبی پیشخور، نسبت به مدل ARMA در پیش‌بینی روزانه تقاضای برق کشور از دقت بالایی برخوردار است.

طبقه‌بندی JEL: C53, C22, C61, Q41

واژه‌های کلیدی: پیش‌بینی، تقاضای برق، تبدیل موجک، شبکه عصبی مصنوعی، ARCH

* به ترتیب، عضو هیئت علمی و دانشجوی دکتری گروه اقتصاد دانشگاه تربیت مدرس

(Sadeghih@modares.ac.ir)

1- مقدمه

حامل‌های انرژی بعد از انقلاب صنعتی به عنوان یکی از نهاده‌های مهم در راستای تحقق توسعه‌ی اقتصادی جوامع صنعتی، نقش به‌سزایی ایفا کرده‌اند. امروزه انرژی الکتریسیته به دلیل ارتباط با سایر بخش‌ها و نهاده‌های اقتصادی (در غالب نهاده یا کالای نهایی)، نقش قابل توجه‌ای در فرایند تصمیم‌گیری‌های اقتصادی و پیشبرد اهداف توسعه‌ی کشورها ایفا می‌کند. از این رو، پیش‌بینی تقاضای برق، با توجه به نقش مختلفی که در اقتصاد یک کشور ایفا می‌کند، از اهمیت ویژه‌ای برخوردار است. در صنعت برق پیش‌بینی تقاضای برق، برای تنظیم میزان تولید نیروگاه‌ها، همچنین بهبود عملکرد بازار برق و شفافیت قیمت‌گذاری مزیت قابل توجه‌ای دارد که آثار آن را می‌توان در کاهش خاموشی و افزایش کیفیت برق مشاهده نمود. روش‌های مختلفی برای پیش‌بینی متغیرهای سری زمانی وجود دارد. یکی از مدل‌های غیرخطی که توانایی بالقوه‌ی خوبی برای پیش‌بینی سری‌های زمانی از خود نشان داده‌است، شبکه‌های عصبی مصنوعی¹ است. شبکه‌های عصبی تکنیک‌هایی هستند که به تقلید از سیستم عصبی بیولوژیکی انسان می‌پردازند که تاکنون در بسیاری از زمینه‌ها نظیر تجارت، صنعت و علوم تجربی مورد استفاده قرار گرفته و نتایج بسیار خوبی به دست آمده است. مدل‌های شبکه‌ی عصبی نشان داده‌اند که در پیش‌بینی خارج از نمونه، توانایی بهتری نسبت به مدل‌های آماری متعارف دارند.

از طرف دیگر، اخیراً علاقه مجددی به گسترش‌های خطی سیگنال‌ها بویژه، استفاده از موجک‌ها² و تعمیمات آنها پدیدار گردیده است (عباسی‌نژاد و محمدی، 1386، ص 21). تئوری موجک یک ابزار ریاضی برای تجزیه سیگنال‌ها و تکنیکی مفید برای نمایش سیگنال‌ها در سطوح مختلف ارائه می‌دهد. لیانگ و پیچ³ (1997) نشان داده‌اند که چند نمایشی سیگنال‌ها، قدرت تعمیم‌دهی و توانایی شبکه‌ی عصبی در پیش‌بینی را تقویت می‌کند.

در این مقاله سعی می‌شود که روشی مناسب برای ساخت مدل‌های پیش‌بینی تقاضای برق⁴ ارائه شود. بر اساس این روش، داده‌های اولیه قبل از ورود

¹ ANN: Artificial Neural Networks

² Wavelet

³ Liang and Peich

⁴ مقادیر خاموشی را نیز در بر دارد.

به لایه‌ی ورودی شبکه‌ی عصبی با استفاده از تبدیل ناپیوسته موجک DWT ⁵ به مولفه‌هایی براساس مقیاس یا فرکانس متفاوت تجزیه می‌شوند. سپس برای هر کدام از مولفه‌ها، مدل شبکه‌ی عصبی طراحی می‌شود. پیش‌بینی نهایی با ترکیب کردن پیش‌بینی‌های سری زمانی مولفه‌ها انجام می‌گیرد. در نهایت این روش پیشنهادی برای پیش‌بینی یک گام تا ده گام به جلو (روز یکم تا روز دهم) تقاضای برق کشور به کار گرفته می‌شود. از طرفی، برای بررسی کارایی مدل پیشنهادی (تبدیل موجک)، این مدل با مدل غیرخطی شبکه‌ی عصبی و مدل خطی $ARIMA$ مقایسه می‌شود. دلیل استفاده از پیش‌بینی نوع گام به گام بیان این نکته است که - برای مثال - یک مدل در طول 10 روز پیش‌بینی، ممکن است در چند روز اول نسبت به مدل دیگری از قدرت پیش‌بینی بالاتری برخوردار باشد، اما در ارزیابی مجموع 10 روز این گونه نباشد، که توانایی پیش‌بینی این مدل در نوع دوم نادیده گرفته می‌شود. هر گام معرف یک روز است.

در بخش اول شبکه‌های عصبی و تبدیل موجک همراه با فرایند $ARIMA$ معرفی می‌گردد. در ادامه به مدل‌سازی و تخمین مدل‌های مذکور با استفاده از داده‌های روزانه تقاضای برق کشور، برای دوره‌ی 1384/6/27 تا 1388/9/3 پرداخته می‌شود. در مرحله‌ی بعد، تقاضای روزانه برق کشور در بازه‌ی زمانی یک تا ده گام به جلو پیش‌بینی می‌شود. در نهایت با به کارگیری معیارهای سنجش $RMSE$ و $MAPE$ به ارزیابی مدل‌های ارائه شده در زمینه‌ی پیش‌بینی تقاضای روزانه‌ی برق پرداخته و در پایان نتایج ارائه می‌گردد. داده‌های مورد استفاده در این تحقیق آمار روزانه تقاضای برق کشور است که از مدیریت شبکه‌ی برق ایران استحصال شده است.

2- پیشینه‌ی تحقیق

کاربرد شبکه‌های عصبی در مباحث اقتصادی از اواخر دهه‌ی نود با مطالعه‌ی وایت⁶ (1998) در بازارهای مالی و پیش‌بینی قیمت سهام شرکت IBM آغاز شد. موفقیت شبکه‌های عصبی در مطالعات مربوط به حوزه‌های مالی، نظر متخصصان اقتصاد

⁵ Discrete Wavelet Transformation

⁶ White

کلان و اقتصاد سنجی را به خود جلب کرد و مطالعات متعددی در زمینه‌ی استفاده از شبکه‌های عصبی مصنوعی در پیش‌بینی متغیرهای مختلف اقتصاد صورت گرفت. به طور عمده، کاربرد شبکه‌های عصبی در مطالعات داخلی، مربوط به پیش‌بینی داده‌های مالی بوده است. آذر و افسر (1385) با ترکیب تئوری استدلال فازی و شبکه‌های عصبی مصنوعی به پیش‌بینی قیمت سهام در بورس اوراق بهادار پرداخته‌اند. در این تحقیق مدل شبکه‌ی عصبی فازی با روش *ARIMA* مورد مقایسه قرار گرفته که نتایج آن بیانگر برتری شبکه‌های عصبی فازی بر مدل رقیب بود. از طرف دیگر متوسلی و طالب کاشفی (1385) در پیش‌بینی قیمت سهام ده روز آینده چهل شرکت فعال در بورس اوراق بهادار تهران نشان دادند که مدل‌های خطی *ARIMA* به طور معنی‌داری نسبت به مدل‌های شبکه عصبی نتایج بهتری ارائه نموده است.

به طور کلی، مطالعاتی که در این زمینه صورت گرفته است، برخی عملکرد بهتر مدل *ARIMA* را نسبت به شبکه‌ی عصبی نشان داده‌اند. از جمله این مطالعات، می‌توان به تحقیق طلوعی اشلقی و حق دوست (1386)، متوسلی و طالب کاشفی (1385) اشاره کرد. برخی از تحقیقات نیز مانند مشیری و مروت (1385)، خالوزاده و خاکی صدیق (1382)، سینایی، مرتضوی و تیموری اصل (1384) به نتایج معکوس دست یافته‌اند. همچنین مطالعه‌ی کمیجانی و سعادت‌فر (1385) در پیش‌بینی ورشکستگی اقتصادی شرکت‌های بازار بورس با استفاده از شبکه‌های عصبی قابل توجه است. در زمینه‌ی به کارگیری شبکه‌های عصبی مصنوعی در پیش‌بینی متغیرهای کلان نیز می‌توان به مطالعات قدیمی، مشیری (1381) در پیش‌بینی رشد اقتصادی در ایران، مشیری (1380) در پیش‌بینی تورم در ایران، مرزبان، اکبری‌ان و جواهری (1384)، زراء‌نژاد و دیگران (1387) در پیش‌بینی نرخ ارز اشاره نمود. در زمینه‌ی استفاده از تکنیک تبدیل موجک در حوزه‌ی اقتصاد تنها مطالعه‌ای که صورت گرفته است، مطالعات عباسی نژاد، محمدی (1386) در زمینه‌ی پیش‌بینی نرخ‌های ارز (دلار، پوند، یورو، ین) بوده است. در این مطالعه 4 نرخ ارز بر اساس مدل‌های شبکه‌ی عصبی مصنوعی، تبدیل موجک و مدل *ARIMA* برای ده روز آینده پیش‌بینی شد و قابلیت مدل تبدیل موجک در پیش‌بینی سری‌های زمانی تایید گردید.

در حوزه‌ی پیش‌بینی تقاضای برق با استفاده از مدل‌های مذکور، در مطالعه‌ای سلاما و جرج⁷ (2000) به پیش‌بینی تقاضای برق کوتاه مدت جمهوری چک پرداخته‌اند و با مقایسه‌ی مدل شبکه‌ی عصبی مصنوعی و مدل *ARIMA* نشان داده‌اند که شبکه‌های عصبی به لحاظ غیر خطی بودن روند تقاضای برق، پیش‌بینی بهتری نسبت به مدل *ARIMA* ارائه می‌کند.

یاو و دیگران⁸ (2000) شبکه‌های عصبی و تبدیل موجک را در پیش‌بینی کوتاه‌مدت تقاضای برق مورد ارزیابی قرار داده و نشان داده‌اند که تبدیل موجک می‌تواند به عنوان یک ابزار مفید جهت پیش‌بینی مورد استفاده قرار گیرد.

استینرز و دیگران⁹ (2000) به بررسی کاربرد شبکه‌های عصبی مصنوعی در پیش‌بینی تقاضای برق پرداخته‌اند. این تحقیق در واقع یک مرور و ارزیابی کلی نسبت به تحقیقات انجام شده در مورد پیش‌بینی تقاضای برق از سال 1991 تا 1999 است که به مشکلات، نقاط ضعف و قوت شبکه‌های عصبی مصنوعی نسبت به مدل‌های دیگر نیز اشاره می‌نماید.

ژانگ و دونگ¹⁰ (2001) با به کارگیری مدل تبدیل موجک، در پیش‌بینی کوتاه‌مدت بار کویزلند استرالیا، نشان داده است که این مدل نسبت به مدل‌های خطی نتایج بهتری ارائه می‌کند.

کیم و دیگران¹¹ (2002) با استفاده از شبکه‌های عصبی و تبدیل موجک به پیش‌بینی کوتاه‌مدت تقاضای برق کره جنوبی پرداخته‌اند. نتایج این مطالعه نشان می‌دهد که مدل‌های مذکور در پیش‌بینی کوتاه مدت ابزار کارا و موثری است.

هیپرت و همکارانش¹² (2005) با به کارگیری شبکه‌ی عصبی به پیش‌بینی مصرف روزانه برق برزیل پرداخته‌اند. این مطالعه با استفاده از متدهای مختلف، مصرف ساعتی برق را پیش‌بینی نمود و عملکرد مناسب شبکه‌ی عصبی در پیش‌بینی 24 ساعته نسبت به مدل‌های رقیب، مفید ارزیابی شد.

⁷ Slama and Georges

⁸ Yao

⁹ Steinherz

¹⁰ Zhang and Dong

¹¹ Kim

¹² Hippert

ننگ لاینگ و دیگران¹³ (2006) با استفاده از مدل تبدیل موجک، بار کوتاه مدت چین را مورد بررسی قرار داده‌اند. ایشان نشان داده‌اند که تبدیل موجک نتایج خوبی را در انطباق تجزیه‌ی اجزا فرکانس و محدوده‌ی زمانی دارد.

رومرا و دیگران¹⁴ (2007) با استفاده از شبکه‌های عصبی مصنوعی، تقاضای ماهیانه‌ی برق برای کشور اسپانیا را پیش‌بینی نموده‌اند. این دو در مطالعه‌ی دیگری (2008) با به کارگیری شبکه‌ی عصبی مصنوعی و سری‌های فوریه، تقاضای ماهیانه برق اسپانیا را پیش‌بینی نموده‌اند. در این مطالعه سری فوریه نتایج مناسب‌تری نسبت به مدل‌های شبکه‌ی عصبی مصنوعی و *ARIMA* ارائه نمود.

در زمینه‌ی پیش‌بینی مصرف برق در ایران نیز می‌توان به مطالعات آزاده و دیگران¹⁵ (2008) اشاره نمود که با استفاه از شبکه‌ی عصبی پیشخور مصرف ماهیانه برق صنعتی در ایران را طی یک دوره‌ی 20 ساله 1979-2003 مورد بررسی قرار داده و برتری مدل شبکه‌ی عصبی پیشخور در مقایسه با مدل رگرسیون را نشان داده‌اند. در مطالعه‌ی دیگر، طباطبایی و دیگران¹⁶ (2008) تقاضای کوتاه مدت برق (24 ساعته) را بر اساس شبکه‌ی عصبی پیشخور دو لایه پیش‌بینی نموده‌اند.

3- تحولات مصرف برق

جدول (1) مصرف برق بخش‌های مختلف را طی سال‌های 85-1377 نشان می‌دهد.

¹³ Nengling

¹⁴ Romera

¹⁵ Azadeh

¹⁶ Tabatabaei

جدول 1: مصرف برق بخش‌های مختلف در 85-1377 (میلیون مگاوات ساعت)

سال	خانگی	عمومی	تجاری	صنعتی	حمل و نقل	کشاورزی	سایر مصارف	جمع
1377	28686	7077	8484	24140	-	6782	2474	77646
1378	29754	10622	5567	26493	11	8019	4190	84656
1379	31266	11271	5991	28924	13	9147	3754	90366
1380	32891	11951	6394	30721	18	11079	4117	97171
1381	34946	12630	6925	33456	13	12435	4671	105076
1382	37967	13714	7461	36937	14	13859	4672	114909,5
1383	40564	15021	7863	40248	90	15489	5188	124462
1384	44108	16350	8542	43015	108	16469	4305	132897
1385	48085	18329	9320	46431	143	17666	4608	144582


مأخذ: ترازنامه انرژی سال ۱۳۸۷

مصرف برق کشور طی سال‌های 1377 تا 1385 به طور متوسط با رشد سالیانه 8 درصد در حال افزایش بوده است که عموماً به دلیل توسعه‌ی شهرنشینی، افزایش سطح زندگی و رفاه، واقعی نبودن تعرفه‌ها، تغییرات آب و هوا، توسعه صنعتی و تجاری بوده است (ترازنامه انرژی سال 1387). در این بین متوسط رشد مصرف برق در بخش‌های خانگی، صنعتی، عمومی، تجاری، کشاورزی و حمل و نقل به ترتیب برابر با 0/133، 0/085، 0/066، 0/128 و 0/9 است. میزان رشد سالیانه‌ی مصرف برق در بین بخش‌های مختلف در این دوره متفاوت است، به گونه‌ای که میزان رشد برق در بخش خانگی از 3 درصد در سال 1378 به 9 درصد در سال 1387 افزایش یافته و در طرف مقابل این نرخ برای بخش کشاورزی از 18 درصد در سال 1378 به 7 درصد در سال آخر کاهش یافته است. نرخ رشد مصرف برق در بخش صنعتی نوسانات کمتری داشته است. همچنین، نرخ رشد مصرف برق در بخش عمومی از 6 درصد در سال 1379 به 12 درصد در سال آخر رسیده است.

طی این دوره، متوسط سهم بخش‌های خانگی، صنعتی، عمومی، کشاورزی، تجاری و حمل و نقل از مصرف کل برق به ترتیب برابر با 0/119، 0/318، 0/339، 0/069 و 0/001 است. سهم هر یک از بخش‌ها نیز طی دوره نوسان داشته است، به گونه‌ای که سهم بخش خانگی از 36 درصد در سال 1377 به 33 درصد در سال 1385 کاهش یافته و سهم بخش صنعتی و کشاورزی از سال 1377 با نرخ‌های 31 درصد و 8 درصد به 32 درصد و 12 درصد افزایش یافته است.

داده‌های مورد استفاده در این تحقیق آمار روزانه تقاضای برق کشور برای دوره‌ی 1384/6/27 تا 1388/9/12 است که در مجموع 1500 مشاهده را دربرمی‌گیرد. نمودار (1) روند خطی تقاضای روزانه برق کشور را برای دوره‌ی 1384/6/27 تا 1388/9/12 نشان می‌دهد. در حالت کلی، تقاضای برق با توجه به روند سالیانه آن در حال افزایش است. نکته‌ی قابل توجه در تقاضای برق، نوسانات فصلی آن است، به گونه‌ای 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 ساعت‌های روشنایی با توجه به دما بالای هوا، زمان استفاده از این وسایل را افزایش می‌دهد. نکته‌ی دیگر در مورد تقاضای برق، نوسانات روزانه آن است. در ایام تعطیلات مصرف روزانه کاهش می‌یابد. به معمول در روزهای اول هفته مصرف برق افزایش می‌یابد و در اواخر هفته بویژه 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.

نمودار 1: تقاضای روزانه برق کشور (1384/6/27 تا 1388/9/12)



مأخذ: مدیریت شبکه برق ایران

4- شبکه‌های عصبی، تبدیل موجک، مدل پیشنهادی و *ARIMA*


4-1- شبکه‌های عصبی

در سال‌های اخیر روش‌های قابل توجهی در آزمایش و مدل‌سازی سری‌های زمانی رشد پیدا کرده است. در این سال‌ها بیشترین نظرات، در مدل‌های شبکه‌ی عصبی

متمرکز شده است (پور کاظمی، افسر و نهاوندی، 1384، ص 147) شبکه‌های عصبی مصنوعی در واقع از ساختار درهم و توده‌ای مغز پستانداران الهام گرفته شده است که در آن میلیون‌ها سلول عصبی (نرون) با یکدیگر در ارتباط هستند. شبکه‌های عصبی از دهه‌ی پنجاه شناخته شده بودند؛ اما تنها در اواسط دهه‌ی هشتاد بود که الگوریتم‌ها و روش‌های مربوط به شبکه‌های عصبی مصنوعی به درجه‌ای از پیشرفت رسید که در حل مسائل واقعی از آنها استفاده شد.

انواع مختلفی از شبکه‌های عصبی مصنوعی با توجه به اهداف تحقیق می‌توان استفاده شود. در این تحقیق شبکه‌ی عصبی چند لایه پیشخور ($MFNN$)¹⁷ به کار گرفته شده است. یک شبکه‌ی عصبی مصنوعی مجموعه‌ای از نرون‌های به هم متصل در لایه‌های مختلف هستند که اطلاعاتی را برای یکدیگر ارسال می‌کنند. یک پردازش زمانی آغاز می‌شود که محرکی از محیط دریافت شود. رسپتورها اطلاعات را به پالس‌های الکترونیکی تبدیل می‌کنند و آنها را به شبکه‌ی عصبی انتقال می‌دهند. بعد از ارزیابی داخل شبکه، اعمال لازم تصمیم‌گیری می‌شود و پالس‌ها به افکتورها فرستاده می‌شوند.

نرون‌های مصنوعی واحدهای ساده پردازش اطلاعات هستند. بنابراین، تعداد زیادی از این نرون‌ها یک شبکه‌ی عصبی را می‌سازند. در نمودار (2) تصویری از یک نرون مصنوعی نشان داده شده است.



همان گونه که ملاحظه می‌شود، ارتباطها، سیناپس‌ها (W_i)، سیگنال‌ها یا محرک‌ها U_i را به نرون انتقال می‌دهند. W_i می‌تواند به عنوان یک وزن، که میزان اهمیت ورودی U_i را نمایش می‌دهد، تفسیر شود. در داخل نرون مجموعه‌ی ورودی‌های وزن‌دار $w_i u_i$ در نظر گرفته می‌شود.

¹⁷ Multilayered Feedforward Neural Network

این مجموع u ، بزرگتر از حد آستانه‌ی خارجی q در نظر گرفته شده است و نرون خروجی Z را تولید می‌کند. Z یک مقدار پیوسته است که وابسته به تابع فعالیت است. در اکثر موارد، انتخاب یک تابع فعالیت خروجی، نرون را به برد $(0/1)$ یا $(-1/1)$ محدود می‌سازد.

از دید ریاضی تساوی‌های زیر یک شرح جامع از نرون‌ها را می‌دهد:

$$y = \sum_{i=1}^n w_i u_i - q \quad \& \quad z = y(y) \quad (1)$$

که در آن y ورودی خالص، q حد آستانه خارجی و $y(t)$ تابع فعالیت است. به طور 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 یا غیر خطی باشد که بر اساس نیاز خاص مسأله که قرار است به وسیله‌ی شبکه‌ی عصبی حل شود، از سوی طراح انتخاب می‌شود. برای بهره برداری واقعی از توانایی شبکه‌ی عصبی باید از توابع فعال‌سازی غیر خطی استفاده شود. این مسأله اجازه می‌دهد که شبکه‌ی الگوهای غیر خطی مناسبی از مجموعه‌ی داده‌های پیچیده تولید کند. رایج‌ترین تابع فعال‌سازی مورد استفاده در ادبیات شبکه‌ی عصبی، تابع توزیع تجمعی لجستیک یا تابع سیگموئید است:

$$j(x) = \frac{1}{1 + e^{-a(x)}} \quad (2)$$

این تابع پیوسته و مشتق پذیر است.


مقدار تابع لجستیک در محدوده $(1/0)$ قرار دارد، به گونه‌ای 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 علائم دریافتی واکنش نشان می‌دهد.

اهمیت طراحی شبکه (تنظیم بین نرون‌ها و سیناپس‌ها) غیر قابل انکار است. یک ارتباط محکم بین الگوریتم یادگیری و ساختار شبکه وجود دارد که طراحی را در مرکزیت قرار می‌دهد.

دو نوع متفاوت از شبکه‌های عصبی تشخیص داده شده است: شبکه‌ی عصبی پیشخور¹⁸ و شبکه‌ی عصبی پسخور¹⁹.

با توجه به اینکه در مقاله‌ی حاضر، از شبکه‌ی عصبی پیشخور استفاده می‌شود، به توضیح در مورد آن بسند می‌کنیم. یک شبکه‌ی عصبی نوعی، از لایه‌هایی تشکیل شده است. در یک شبکه‌ی تک لایه‌ای 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 آن دارد. نمودار (3) نمایشی از شبکه‌ی عصبی استاندارد پیشخور را نشان می‌دهد. 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 لایه شبکه به هر نرون دیگر در لایه‌ی همسایه جلویی متصل شده باشد. یک شبکه دارای اتصال کامل است.

نمودار 3: نمایش شبکه‌ی عصبی استاندارد پیشخور



مأخذ: پیکتن و فلیپ

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 نظارت²⁰ و

¹⁸ Feed forward

¹⁹ Recurrent

²⁰ Supervised Learning

یادگیری بدن نظارت²¹ یادگیری با نظارت 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 خطا²² است، وزن‌های شبکه تعدیل می‌شود (اصطلاحاً شبکه آموزش داده می‌شود)، به گونه‌ای که خطای پیش‌بینی داخل نمونه که به وسیله‌ی مجموع مربعات خطا یا 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 نشده قبلی، ایجاد می‌کند. اهمیت این موضوع در پیش‌بینی بسیار زیاد است. ارزش دیگر این شبکه، طبیعت غیر خطی بودن آن است. به این ترتیب، تعداد زیادی از مسائل قابلیت حل پیدا می‌کنند. 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، قادرند هر تابعی را با دقت دلخواه تقریب بزنند (کان و وایت،²³ 1994). به همین علت به این نوع شبکه‌ی عصبی با ساختار فوق، تقریب زنده جامع گفته می‌شود.²⁴

4-1-2- طراحی شبکه‌ی عصبی

از آنجا که یکی از اهداف اصلی این مطالعه، بررسی کارایی تبدیل موجک در بالا بردن توانایی شبکه‌ی عصبی است، ساختار شبکه‌ی عصبی در دو مدل شبکه‌ی عصبی و شبکه‌ی عصبی همراه با تبدیل موجک، یکسان است. شبکه‌ی عصبی از

²¹ Unsupervised Learning

²² Error Back Propagation

²³ Kuan and White

²⁴ Universal Approximator

نوع پیشخور با یک لایه‌ی پنهان، حداکثر 20 نرون در لایه‌ی پنهان و 9 نرون در لایه‌ی ورودی است که شامل روزهای هفته، متوسط دمای هوا، ایام تعطیلات و روزهای خاص (مانند ماه رمضان) است.

برای لایه‌ی پنهان از تابع سیگموئید (تانژانت هایپربولیک) و برای لایه‌ی خروجی از تابع خطی استفاده شده است. برای بررسی عملکرد بهتر مدل شبکه‌ی عصبی و مدل شبکه‌ی عصبی - تبدیل موجک، از نسبت‌های آموزش و آزمایش 10-90 و 5-95 درصد و نرخ یادگیری 1 درصد و 2 درصد استفاده می‌شود؛ هر کدام که عملکرد بهتری داشته باشد، به عنوان نسبت و نرخ یادگیری نهایی انتخاب می‌شود. معیار عملکرد شبکه، MSE^{25} است؛ یعنی هر شبکه که کمترین مقدار MSE را داشته باشد، به عنوان مدل بهینه انتخاب و از روی آن تعداد لایه‌ها و نرون‌های شبکه تعیین می‌گردد.

4-2-1- تبدیل موجک


ویولت (*Wavelet*) در لغت به معنی یک موج کوچک است. یک تبدیل موجک دارای ویژگی‌های زیر است.

- تبدیل یک سیگنال به مجموعه‌ای از موجک‌ها است.
 - ایجاد و ارائه‌ی یک مسیر برای آنالیز نمودن شکل موج‌های مختلف در دو حوزه‌ی زمان و فرکانس.
 - امکان ذخیره نمودن سیگنال‌ها با بازدهی بسیار بهتر نسبت به تبدیل فوریه.
 - توانایی تقریب سیگنال‌ها با کیفیتی بسیار بهتر
- موجک‌ها توابعی هستند که مقدار محدودی دارند و مقدار متوسط آنها صفر است. این موجک‌ها دارای انواع متعددی است. در نمودار (4) یک موجک از خانواده دابیشز²⁶ نشان داده شده است.

²⁵ Mean Squar Error

²⁶ Dubochis

نمودار 4: یک موجک از خانواده دابیشز



مأخذ: جعبه ابزار متلب²⁷

تبدیل موجک پیوسته را می‌توان به صورت مجموع حاصل ضرب سیگنال اصلی در موجک‌های تغییر مقیاس یافته وانتقال داده شده در زمان نمایش داد.

$$C(s, \tau) = \int_{-\infty}^{\infty} f(t) \cdot \psi_{s, \tau}(t) dt \quad (3)$$

در رابطه‌ی بالا $\psi_{s, \tau}(t)$ موجک مادر تغییر مقیاس یافته به اندازه‌ی s و انتقال یافته در زمان به اندازه‌ی τ است. نتیجه‌ی تبدیل موجک پیوسته، ضرایب موجک C است که توابعی از مقیاس و ضریب جابه‌جایی است. با ضرب کردن هر کدام از این ضرایب در موجک‌های مادر تغییر مقیاس یافته و جابه‌جا شده در زمان می‌توان موجک‌های تشکیل دهنده‌ی سیگنال اصلی را به دست آورد. سیگنال اصلی در طول زمان توسط توابع موجک تغییر مقیاس یافته که در طول زمان جابه‌جا می‌شوند، ضرب می‌شود و سپس از آنها انتگرال‌گیری می‌شود. بنابراین، با استفاده از تبدیل موجک می‌توان یک سیگنال را با استفاده از مجموعه‌ای از توابع که از تغییر مقیاس و انتقال دادن یک تابع اصلی به نام موجک مادر به دست می‌آیند به زیر سیگنال‌هایی تجزیه نمود.

در صورت استفاده از تبدیل موجک پیوسته، حجم اطلاعات بسیار زیاد می‌شود؛ زیرا باید برای مقیاس‌های مختلف (s مختلف) در طول زمان از سیگنال اصلی و تابع موجک، انتگرال‌گیری نمود. بنابراین، حجم اطلاعات و محاسبات بسیار زیاد می‌شود، چون s به صورت پیوسته تغییر می‌کند. ضمناً، در برخی از موارد ممکن است به یک تابع غیر تحلیلی برخورد کنیم که امکان انتگرال‌گیری از آن وجود نداشته باشد یا اینکه انتگرال جواب خاصی نداشته باشد. از این رو بهتر است

²⁷ Matlab Toolbox

که از تبدیل موجک گسسته استفاده گردد. این تبدیل ویژگی‌های بسیار مناسبی را ارائه می‌دهد که از جمله آنها می‌توان به موارد زیر اشاره نمود.

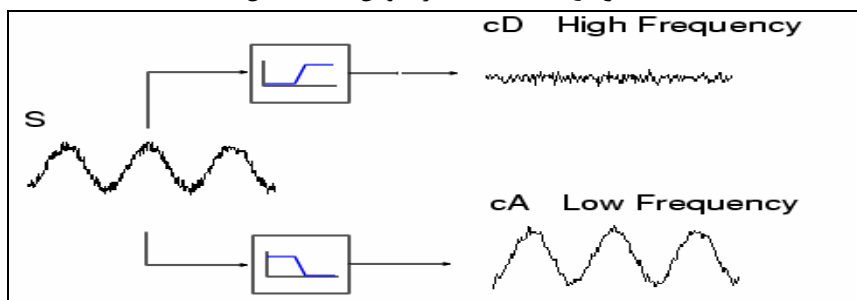
- به اندازه‌ی کافی اطلاعات مورد نیاز را برای تحلیل و بررسی موج اصلی ارائه می‌دهد.
- مقدار محاسبات مورد نیاز را به مقدار بسیار مناسبی کاهش می‌دهد.
- می‌توان توسط آن سیگنال اصلی را در فرکانس‌های مختلف و با وضوح‌های کاملاً متفاوت بررسی و تحلیل نمود.
- می‌توان سیگنال اصلی را به سیگنال‌هایی با تقریب نه چندان خوب ولی با اطلاعات بسیار خوب و مفیدی از آن تجزیه نمود.

در تبدیل موجک گسسته متغیرهای k و τ که در حالت پیوسته، مقادیر پیوسته‌ای داشتند، در حالت گسسته مقادیر گسسته‌ای به خود می‌گیرند و پیاده‌سازی تبدیل به صورت ساده‌تری صورت می‌گیرد.

برای اکثر سیگنال‌ها، مولفه‌های فرکانس پایین اهمیت بسیار زیادی دارند. این مولفه‌ها، مشخصات کلی سیگنال را مشخص می‌کنند. از سوی دیگر، مولفه‌های فرکانس بالا، جزئیات ریز سیگنال را بیان می‌کنند.

در آنالیز موجک، معمولاً از تقریب سیگنال و جزئیات آن بحث می‌شود. تقریب سیگنال معمولاً از مقیاس‌های بزرگ یا از مولفه‌های فرکانس پایین تشکیل می‌شود؛ ولی جزئیات سیگنال از مقیاس‌های کوچک یا مولفه‌های فرکانس بالا تشکیل می‌گردد. عملیات فیلتر نمودن به صورت کلی و ساده می‌توان به صورت نمودار (5) نمایش داد.

نمودار 5: عملیات فیلتر نمودن یک سیگنال

مأخذ: جعبه ابزار متلب²⁸

به همین ترتیب، می‌توان عملیات فیلترسازی را طی مراحل مختلفی انجام داد. مطابق آنچه که در نمودار (5) نشان داده شده است، می‌توان مولفه‌های فرکانس پائین را دوباره 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.

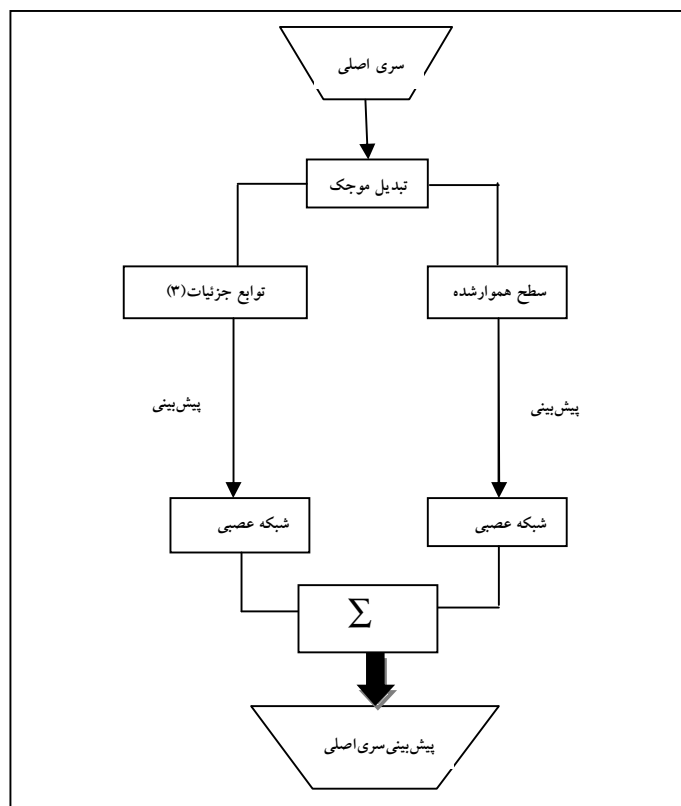
4-2-2- طراحی تبدیل موجک

در این روش ابتدا سری زمانی تقاضای برق، به صورت ترکیبی از مولفه‌های 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 مولفه (تابع جزئیات) تجزیه شده سری اولیه، یک مدل شبکه‌ی عصبی پیش‌بینی‌کننده خواهیم ساخت. آنچه باقی می‌ماند یک سری تقریبی (همراه شده) است که آن را نیز با شبکه‌ی عصبی مدل‌سازی می‌نماییم. این مدل را مدل شبکه‌ی عصبی - تبدیل موجک²⁹ (WDNN) می‌نامیم. پیش‌بینی سری اصلی از مجموع پیش‌بینی سری هموار شده و مولفه‌ها به دست می‌آید. نوع پیش‌بینی به صورت یک گام تا ده گام به جلو است. تعداد داده‌های مربوط به تقاضای روزانه برق کشور 1500 است که برای دوره‌ی تقریباً 4 ساله از تاریخ 1384/6/27 تا 1388/9/13 از سازمان مدیریت شبکه‌ی برق ایران استخراج شده است.

برای بررسی عملکرد سطح تجزیه، داده‌ها را با استفاده از موجک دابیشز 5 تا سه سطح مرحله شکافته‌ایم و سطح هموار شده را با جزئیات سطوح یک، دو و سه به دست آورده و با استفاده از شبکه‌ی عصبی آنها را مدل‌سازی می‌نماییم. لازم به ذکر است که با در نظر گرفتن عوامل تاثیرگذار بر تقاضای روزانه برق که شامل روزهای هفته، متوسط دمای هوا و روزهای تعطیل و خاص است، در هر سه سطح، تعداد 9 نرون در لایه‌ی ورودی شبکه‌ی عصبی لحاظ گردیده است. نتایج این کار در نمودارهای (2 تا 6) در پیوست الف نشان داده شده است. نمودار (6) ساختار استفاده از مدل شبکه‌ی عصبی - تبدیل موجک را نشان می‌دهد.

²⁹ Wavelet Decomposition Neural Network

نمودار 6: ساختار استفاده از تبدیل موجک



مأخذ: یافته‌های تحقیق

4-3- مدل خطی ARIMA

فرآیند $ARIMA(P,d,q)$ برای متغیر x را می‌توان به صورت رابطه‌ی (4) نشان داد:

$$y_t = f(x) + \sum_{i=1}^p j_i y_{t-i} + \sum_{j=1}^q \theta_j \epsilon_{t-j} + \epsilon_t \quad (4)$$

$$y_t = \Delta^d x_t = (1-l)^d x_t \quad (5)$$

که در آن $f(t)$ روند زمانی را (در صورت وجود) در y_t برآورد می‌کند. در اکثر متغیرهای اقتصادی، معمولاً $d=1$ بوده در نتیجه $f(t) = \mu$ یا $d=0$ است.

$$f(t) = a + dt \quad (6)$$

در فرآیند $ARIMA(p,d,q)$ متغیر p بیانگر تعداد جملات خود رگرسیو، d

مرتبه‌ی تفاضل‌گیری و q تعداد جملات میانگین متحرک است.

در صورتی که d برابر با صفر گردد، فرآیند $ARIMA$ تبدیل به فرآیند $ARMA$ می‌شود. معمولاً برای تخمین الگوی $ARIMA$ و $ARMA$ از روش باکس-جنکینز استفاده می‌شود که دارای سه مرحله شناسایی، تخمین و تشخیص دقت پردازش است. تعداد جملات خود رگرسیو و تعداد جملات میانگین متحرک را می‌توان با استفاده از توابع خودهمبستگی³⁰ (AC) و خودهمبستگی جزئی³¹ (PAC) به دست آورد و توسط ضابطه‌های آکائیک³² یا شوارتز-بیزین³³ مورد بازبینی قرار داد.

در این مطالعه برای پیش‌بینی داده‌های سری زمانی پس از تبدیل آن به صورت لگاریتمی، ابتدا مانایی سری زمانی را بررسی کرده، مرتبه‌ی انباشستگی (d) تعیین می‌شود. در مطالعه‌ی حاضر همان‌گونه که در نمودار 1 مشاهده می‌گردد، سری زمانی تقاضای برق دارای روند فصلی است. بنابراین، برای روند زدایی فصلی (روند این سری زمانی هر 365 روز به صورت تناوبی تکرار می‌گردد) از این سری تفاضل‌گیری سالیانه ($\Delta 365$) به عمل آمد.³⁴ در ادامه با استفاده از آزمون دیکی-فولر تعمیم یافته،³⁵ به بررسی مانایی متغیر تقاضای برق (پس از روند زدایی فصلی) پرداخته شد. نتایج این آزمون در جدول (2) ارائه شده است.

جدول 2: بررسی آزمون مانایی متغیر تقاضای برق

مرتبه‌ی ایستایی	مقدار آماره‌ی محاسباتی	مقدار آماره‌ی بحرانی		متغیر
		-3/43	در سطح 0/01 خطا	
$I(0)$	-6/33	-2/86	در سطح 0/05 خطا	تقاضای برق
		-2/56	در سطح 0/10 خطا	

مأخذ: یافته‌های تحقیق

با توجه به جدول فوق، مشاهده می‌شود که متغیر مورد نظر در سطح خطای 0/01 مانا است. با توجه به $I(0)$ بوده متغیرها مدل $ARIMA$ به مدل $ARMA$ تبدیل می‌شود.

³⁰ Aouto corolation

³¹ Partial Aouto corolation

³³ Akaike Information Criterion (AIC)

³⁴ Schwarts Bayesian Criterion (SBC)

³⁴ در مطالعات صادقی و ذوالفقاری (۱۳۸۸) تفاضل‌گیری سالیانه برای پیش‌بینی مصرف گاز نیز بدین صورت انجام گرفته است.

³⁵ Augmented Dickey-Fuller Test Statistic

سپس تعداد جملات خودرگرسیو³⁶ (p) و تعداد جملات میانگین متحرک³⁷ (p)، با استفاده از توابع خودهمبستگی³⁸ (AC) و خودهمبستگی جزئی³⁹ (PAC) بر اساس مراحل باکس- جنکینز محاسبه شد. اما از آنجا که ممکن است مدل‌های دیگری وجود داشته باشند که مقدار آکائیک یا شوارتز- بیزین کمتری داشته باشند و بر الگوی مذکور ترجیح داده شوند، مدل‌های دیگری نیز بررسی گردید. بر این اساس، کمترین مقدار آکائیک و شوارتز- بیزین مربوط به فرایند تعداد جملات خودرگرسیو و میانگین متحرک است که نتایج تفصیلی حاصل از برآورد آن در جدول (3) آورده شده است.

جدول 3: نتایج حاصل از برآورد دوره‌ی ۱۳۸۸/۹/۳ - ۱۳۸۴/۶/۲۷

z-Statistic	ضریب	نام متغیر	z-Statistic	ضریب	نام متغیر
-۱۰/۹۰	-۰/۲۴	$AR(۵)$	۲/۳۸	۰/۰۰۱۱	C
-۱۳/۲۳	-۰/۲۵	$AR(۶)$	-۱۱/۶۱	-۰/۳۲	$AR(۱)$
-۲۴/۱۸	۰/۵۵	$AR(۷)$	-۱۱/۹۲	-۰/۲۷	$AR(۲)$
۴/۱۵	۰/۱۳	$MA(۱)$	-۱۰/۵۰	-۰/۲۳	$AR(۳)$
			-۱۲/۵۴	-۰/۲۴	$AR(۴)$
$\bar{R}^2 = ۰/۶۲$			$F = ۱۳۶$		

مأخذ: یافته‌های تحقیق

همان‌گونه که در جدول فوق مشاهده می‌گردد، کلیه ضرایب جملات خودرگرسیو و میانگین متحرک در سطح خطای 0/01 به لحاظ آماری معنی‌دار دارند. در ادامه به بررسی اثر $ARCH$ در مدل تخمین زده فوق می‌پردازیم.

4-3-1- مدل‌های $ARCH$ و $GARCH$ ⁴¹

در مدل‌های اقتصادسنجی سنتی، ثابت بودن واریانس جملات اخلال همواره یکی از فروض اصلی و کلاسیک اقتصادسنجی به حساب می‌آید. اما افرادی مثل انگل⁴² (1982) در مطالعات خود به شواهدی مبنی بر اینکه واریانس جملات اخلال در

³⁶ Auto-Regressive

³⁷ Moving Average

³⁸ Auto correlation

³⁹ Partial Auto correlation

⁴⁰ Auto-Regressive Conditional Heteroscedasticity

⁴¹ Generalized Auto-Regressive Conditional Heteroscedasticity.

⁴² Engle

مدل‌های سری زمانی از آنچه غالباً فرض می‌شود، بی‌ثبات است، دست یافتند (تشکینی، 1385). برای رهایی از این فرض محدودکننده‌ی روش جدیدی موسوم به مدل خودتوضیح با واریانس ناهمسانی شرطی (ARCH) پایه‌گذاری شده است (انگل، 1982). در این مدل هر چند خطای پیش‌بینی قابل برآورد است، اما نمی‌توان علامت جمله اخلاص را پیش‌بینی نمود. در این روش واریانس غیرشرطی همسان است، در حالی که واریانس در هر زمانی مشروط به اطلاعات گذشته ناهمسان است (طیبی و همکاران، 1388).

اگر متغیر y_t به صورت رابطه‌ی زیر باشد:

$$y_t = \beta'x_t + e_t \quad t = 1, 2, \dots, T \quad (7)$$

که در آن x_t شامل $K \times 1$ بردار متغیر مستقل با وقفه می‌باشد و β' شامل $K \times 1$ پارامتر است، آنگاه مدل ARCH توزیعی از جمله پسماند تصادفی (e_t) به شرط مجموعه اطلاعات متغیرهای با وقفه $\Omega_{t-1} = \{y_{t-1}, x_{t-1}, y_{t-2}, x_{t-2}, \dots\}$ است. در حالت کلی، انگل فرض می‌کند که جمله خطای شرطی دارای توزیع نرمال است (ساباتینی و لینتون، 1998)⁴³.

$$e_t | \Omega_{t-1} \approx N(0, h_t) \quad (8)$$

$$V(e_t | \Omega_{t-1}) = h_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i e_{t-i}^2 + \delta W_t \quad (9)$$

در رابطه‌ی فوق h_t^2 واریانس شرطی e مشروط به مجموعه‌ی اطلاعات Ω_{t-1} و W برداری از متغیرهای از پیش تعیین شده است که واریانس خطای شرطی را تحت تأثیر قرار می‌دهد. البته در صورتی می‌توان از این مدل استفاده نمود که وجود اثر ARCH در مدل قطعی شده باشد.

کاربرد تجربی مدل ARCH اغلب فرایندهای با طول وقفه‌ی زیاد را برای مجذور پسماندها در نظر می‌گیرد. بولرسلو⁴⁴ (1986) رویکرد دیگری برای مدلسازی پایداری ارائه کرده است. در مدل خودتوضیح با واریانس ناهمسانی شرطی تعمیم یافته (GARCH)، واریانس شرطی هم تابعی از مقادیر با وقفه هر

⁴³ Sabbatini and Linton

⁴⁴ Bollerslev

دوی واریانس شرطی و هم خطای پیش بینی است. مدل $GARCH(p,q)$ خطی به صورت رابطه‌ی (8) قابل بیان است.

$$V(e_t | \Omega_{t-1}) = h_t = \alpha_0 + \sum_{i=1}^q \alpha_i e_{t-i}^2 + \sum_{i=1}^p \phi_i h_{t-i}^2 + \delta W_t \quad (10)$$

در این مطالعه در صورتی می‌توان از مدل $ARCH$ استفاده نمود که وجود اثر $ARCH$ در مدل تخمین زده شده فوق قطعاً باشد. نتایج بررسی وجود اثر $ARCH$ با استفاده از آزمون ناهمسانی واریانس LM طبق پیشنهاد انگل (1982) در جدول (4) نشان داده شده است:

جدول 4: نتایج آزمون اثر $ARCH$

ARCH Test	مقدار	
F-statistic	136/6713	0/0
Obs*R-squared	121/9567	0/0

مأخذ: یافته‌های تحقیق

براساس نتایج به دست آمده، فرضیه‌ی صفر مبنی بر نبود آثار $ARCH$ رد و فرضیه‌ی مقابل مبنی بر وجود آثار $ARCH$ پذیرفته می‌شود. با توجه به بحث مطرح شده در قسمت قبل، از بین مدل‌های $GARCH(p,q)$ نهایتاً مدل $GARCH(1,0)$ که همان مدل $ARCH$ است، براساس معیار شوارتز-بیزین⁴⁵ انتخاب گردیده است. نتایج با فرض وجود توزیع نرمال برای جملات اخلال شرطی به صورت زیر خواهد بود.⁴⁶

$$V(e_t | \Omega_{t-1}) = h_t^2 = 0/00043 + 080e_{t-1}^2 \quad (11)$$

5- مقایسه مدل‌ها بر اساس معیار سنجش

داده‌های مورد استفاده در این پژوهش، تقاضای روزانه برق کشور (مگاوات ساعت) برای دوره‌ی 1384/6/27 تا 1388/9/13 بوده است که در مجموع 1500 مشاهده را در بر می‌گیرد. این داده‌ها از دو بخش تشکیل شده‌اند. نخست از 1384/6/27 تا

⁴⁵ در اکثر مطالعات انجام‌شده از این معیار استفاده شده است.

⁴⁶ خروجی نرم‌افزار Eviews 5 در پیوست (ب) ارائه شده است.

1388/9/3 برای آموزش و مدل‌سازی و بخش دوم از 1388/9/4 تا 1388/9/13 برای مقایسه‌ی مدل‌های مذکور مورد استفاده قرار گرفته است.

لازم به ذکر است که برای مقایسه عملکرد مدل‌ها، معیارهای ریشه‌ی میانگین مربعات خطا ($RMSE$) و میانگین درصد قدر مطلق خطا ($MAPE$) به کار گرفته شده است:

$$RMSE = \sqrt{\sum_{t=1}^n \frac{(y_t - \hat{y}_t)^2}{n}} \quad (12)$$

$$MAPE = \frac{1}{n} \sum \left| \frac{e}{y} \right| \times 100 \quad (13)$$

در جداول (5) و (6) و نمودارهای (9) نتایج حاصل از معیارهای سنجش نشان داده شده است.

جدول 5: مقادیر $RMSE$ مدل‌های پیش‌بینی‌کننده

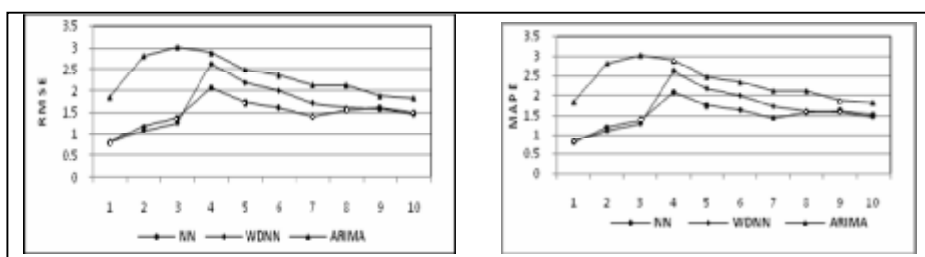
ARMA	WDNN	NN	پیش‌بینی / مدل
9133/6	4356	4232/1	یک گام به جلو
13780/3	5939,6	6505	دو گام به جلو
15901/55	6859,2	7436/9	سه گام به جلو
17202/5	17099	11853	چهار گام به جلو
16220/65	15323	10643	پنج گام به جلو
14811/2	14185	9976/7	شش گام به جلو
14041/95	13134	9242/3	هفت گام به جلو
13511/75	12373	9885/7	هشت گام به جلو
12490/95	11920	9970/8	نه گام به جلو
12886	11327	9502/4	ده گام به جلو

مأخذ: نتایج تحقیق

جدول 6: مقادیر $MAPE$ مدل‌های پیش‌بینی‌کننده

ARMA	WDNN	NN	پیش‌بینی / مدل
1/8412	0/8299	0/8063	یک گام به جلو
2/8109	1/1031	1/1858	دو گام به جلو
3/0165	1/2841	1/3794	سه گام به جلو
2/8832	2/6326	2/0706	چهار گام به جلو
2/4821	2/1864	1/7365	پنج گام به جلو
2/3456	2/0065	1/6243	شش گام به جلو
2/1234	1/7312	1/4152	هفت گام به جلو
2/1190	1/6140	1/5622	هشت گام به جلو
1/8723	1/5901	1/6131	نه گام به جلو
2/1234	1/4703	1/5069	ده گام به جلو

مأخذ: نتایج تحقیق

نمودار 6: مقادیر $RMSE$ و $MAPE$ مدل‌های پیش‌بینی‌کننده

مأخذ: نتایج تحقیق

قبل از مقایسه و نتیجه‌گیری در مورد خروجی مدل‌های پیش‌بینی، معنی‌داری تفاوت میانگین مقادیر $RMSE$ با استفاده از آزمون تجزیه واریانس F^{47} به صورت دوجه دو برای هر یک از مدل‌ها مورد بررسی قرار گرفت (پیوست ج)، با استفاده از نرم‌افزار (EViews). نتایج این آزمون مبین این مطلب است که فرضیه صفر مبنی بر عدم تفاوت معنی‌دار بین اختلاف پیش‌بینی‌ها در بین سه روش رد شده است.

همان‌گونه که در جداول و نمودارهای فوق مشاهده می‌شود، بر اساس معیارهای سنجش، فرآیند خطی $ARMA$ دارای بیشترین خطای در تمام گام‌ها (روزها) است. بر اساس هر دو معیار سنجش، تبدیل موجک برای گام‌های دوم و سوم (دو روز و سه روز اول) نسبت به بقیه‌ی مدل‌ها دارای خطای پیش‌بینی

⁴⁷ F-Test for Analyses of Variance (ANOVA).

کمتری است؛ اما در بقیه‌ی گام‌ها شبکه‌ی عصبی پیشخور، دارای کمترین خطای پیش‌بینی است. از این رو، تکنیک تبدیل موجک می‌تواند به عنوان یک ابزار کارا در پیش‌بینی سری‌های زمانی کوتاه مدت استفاده نمود.

6- نتیجه‌گیری و پیشنهاد

با توجه به اهمیت انرژی برق در توسعه‌ی اقتصادی جوامع، همچنین ارتباط با سایر بخش‌ها و نهادها، آگاهی از میزان تقاضای برق در هر دوره برای اعمال سیاست‌گذاری‌های لازم حائز اهمیت است. در این تحقیق به مطالعه‌ی تطبیقی روش‌های خطی $ARMA$ و غیر خطی شبکه‌ی عصبی مصنوعی و شبکه‌ی عصبی - تبدیل موجک برای پیش‌بینی روزانه تقاضای برق کشور پرداخته شد. در این روش، داده‌های مربوط به تقاضای روزانه برق برای دوره‌ی 1384/6/27 تا 1388/9/3، ابتدا با استفاده از تکنیک موجک به مولفه‌های مقیاسی متفاوتی تجزیه شده است. در مرحله‌ی بعد تکنیک شبکه‌های عصبی برای مدل‌بندی سری‌های زمانی به کار گرفته شد و پیش‌بینی نهایی سری‌های زمانی اصلی با ترکیب پیش‌بینی این مولفه‌ها با سری هموار شده به دست آمد. در کنار به کارگیری روش مذکور، از شبکه‌ی عصبی پیشخور و مدل $ARMA$ نیز برای پیش‌بینی یک تا ده گام به جلوی تقاضای روزانه برق به کار گرفته شد. نتایج حاصل شده از به کارگیری معیارهای سنجش $RMSE$ و $MAPE$ نشان داد که فرآیند خطی $ARMA$ دارای بیشترین خطای در تمامی گام‌ها (روزها) است. تبدیل موجک در گام‌های دوم و سوم نسبت به شبکه‌ی عصبی پیشخور دارای خطای پیش‌بینی کمتری است؛ اما در بقیه‌ی گام‌ها شبکه‌ی عصبی پیشخور، دارای کمترین خطای پیش‌بینی است. بر این اساس، به دستگاه‌های مسئول و سیاست‌گذاران ذیربط در زمینه‌ی سیاست‌گذاری برای آینده پیشنهاد می‌شود که علاوه بر مدل‌های رایج در زمینه‌ی پیش‌بینی، به مدل‌های غیرخطی به ویژه شبکه‌های عصبی و تبدیل موجک به عنوان ابزارهایی قدرتمند در تجزیه و تحلیل داده‌ها مورد توجه کنند. در پایان روش‌های غیرخطی مذکور برای پیش‌بینی ساعتی مصرف برق با توجه به روند تناوبی آن به ویژه برای پیش‌بینی ساعات پیک که یکی از مهمترین مشکلات مدیریت انرژی برق کشور است، توصیه می‌شود.

فهرست منابع:

- آذر، عادل و امیر افسر. (1385). مدل‌سازی پیش‌بینی قیمت سهام با رویکرد شبکه‌های عصبی فازی. پژوهشنامه بازرگانی، 40، 34-52.
- پورکاظمی، محمدحسین، امیر افسر و بیژن نهاوندی. (1384). مطالعه تطبیقی روش‌های خطی *ARIMA* و غیرخطی شبکه‌های عصبی فازی در پیش‌بینی تقاضای اشتراک گاز شهری. تحقیقات اقتصادی، 71: 133-146.
- پیکتن، فلیپ. (1383). شبکه‌های عصبی، اصول و کاربردها. ترجمه مهدی غضنفری و جمال ارکات، تهران: موسسه انتشارات علمی دانشگاه صنعتی علم و صنعت ایران.
- ترازنامه انرژی (1387). تهران: وزارت نیرو.
- تشکینی، احمد. (1385). آیا نااطمینانی با سطح تورم تغییر می‌کند؟. تحقیقات اقتصادی، 73: 193-210.
- خالوزاده حمید و صدیق علی خاکی. (1382). ارزیابی روش‌های پیش‌بینی قیمت سهام و ارایه مدلی غیر خطی بر اساس شبکه‌های عصبی، فصلنامه تحقیقات اقتصادی، 63: 85-43.
- زرانژاد، منصور، علی فقه مجیدی و روح ا... رضایی. (1387). پیش‌بینی نرخ ارز با استفاده از شبکه‌های عصبی مصنوعی و مدل *ARIMA*. اقتصاد مقداری، 5(4): 107-130.
- سینایی، حسن علی، سعیداله مرتضوی و یاسر تیموری اصل. (1384). پیش‌بینی شاخص بورس اوراق بهادار تهران با استفاده از شبکه‌های عصبی مصنوعی. بررسی‌های حسابداری و حسابرسی، 41: 59-83.
- صادقی، حسین و مهدی ذوالفقاری. (1388). طراحی روشی نوین برای پیش‌بینی تقاضای کوتاه‌مدت گاز طبیعی در بخش خانگی. فصلنامه مطالعات اقتصاد انرژی، 24: 52-78.
- طلوعی اشلقی عباس و شادی حق دوست. (1386). مدل‌سازی پیش‌بینی قیمت سهام با استفاده از شبکه عصبی و مقایسه آن با روش‌های پیش‌بینی ریاضی. پژوهشنامه اقتصادی، شماره 25: 237-251.
- عباسی نژاد، حسین و احمد محمدی. (1386). پیش‌بینی نرخ ارز با استفاده از شبکه‌های عصبی و تبدیل موجک. نامه اقتصادی، 3(1): 42-19.
- قدیمی، محمدرضا و سعید مشیری. (1381). مدل‌سازی و پیش‌بینی رشد اقتصادی در ایران با استفاده از شبکه‌های عصبی مصنوعی *ANN*. فصلنامه پژوهش‌های اقتصادی ایران، 12: 97-125.
- کمبجانی اکبر و جواد سعادت فر. (1385). کاربرد مدل‌های شبکه عصبی در پیش‌بینی ورشکستگی اقتصادی شرکت‌های بازار بورس، جستارهای اقتصادی، 6، 11-44.

متوسلی، محمود و بیژن طالب کاشفی. (1385). بررسی مقایسه‌ای توان شبکه‌های عصبی با ورودی شاخص‌های تحلیل تکنیکی برای پیش‌بینی قیمت سهام. نامه اقتصادی، 12(54): 57-82.

مرزبان حسین، رضا اکبریان و بهنام جواهری. (1384). یک مقایسه بین مدل‌های اقتصادسنجی ساختاری، سری زمانی و شبکه عصبی برای پیش‌بینی نرخ ارز. تحقیقات اقتصادی، 69: 181-216.

مشیری، سعید. (1380). پیش‌بینی تورم ایران با استفاده از مدل‌های ساختاری، سری‌های زمانی و شبکه‌های عصبی، تحقیقات اقتصادی، 58: 147-184.

مشیری، سعید و حبیب مروت. (1385). پیش‌بینی شاخص کل بازدهی سهام تهران با استفاده از مدل‌های خطی و غیر خطی. پژوهشنامه بازرگانی، 41: 246-276.

Azadeh, A. Ghaderi, S.F. & S. Sohrab khani. (2007). Forecasting Electricity by Integration of Neural Network, time Series and ANOVA. *Mathematics and Computation*, 186(2): 1753-1761.

Darbellay, A. & M. Slama. (2000). Forecasting the Short-term for Electricity: Do Neural Networks Stand a Better Chance?. *Forecasting*, 16: 71-83.

González-Romera, E., A. Miguel, M. Jaramillo & D. Carmona-Fernández. (2007). Forecasting of the Electric Energy Demand Trend. *Computer & Industrial Engineering*, 52(3): 336-343.

Hippert, H., D. Bunn & R. Souza. (2005). Large Neural Networks for Electricity Loads Forecasting: Are they overfitted?. *Forecasting*, 21(3): 425-434.

kim, C., Y. In-keun & Y. Song. (2002). Kohonen Neural Network Wavelet Transform Based Approach to Short-term Load Forecasting. *Electric and Power Systems Research*, 63: 169-176.

Liang, R. & M. Peich. (1997). The Demand Forecasting Services and the Quality of Supply. *Energy*, 4(2): 41-79.

Nengling, T., S. Jurgen & W. Hongxiao. (2006). Techniques of Applying Wavelet Transform in to Combined Model for Short-term Load Forecasting. *Electric Power Systems Research*, 76: 525-533.

Sabbatini, M. & O. Linton. (1998). A GARCH Model of the Implied Volatility of the Swiss Market Index from Option Price. *International Journal of Forecasting*, 14: 99-213.

Steinherz, M. (2000). Comparing Linear and Nonlinear Forecasts for Taiwan's Electricity Consumption. *Energy Policy*, 31(12): 2129-2141.

Tabatabaei, N., S. Mortezaeei, S. Alzakeriny, S. Ozen & A. Nayir. (2008). Short Term Load Forecasting by Neural Network in Mashhad (IRAN) Power System. 4th International Conference on "Technical and

Physical Problems of Power Engineering”, University of Pitesti, Pitesti, Romania.


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

Yao, S., Y. Song, L. Zhang & Y. Cheng. (2000). Wavelet Transform and Neural Networks for Short-Term Electrical Load Forecasting. Energy Conversion and Management, 41: 1975-1988.


Zhang, B.L. & Z.Y. Dong. (2001). An Adaptive Neural- Wavelet Model for Short Term Load Forecasting. Electric Power Systems Research, 59: 121-129.

پیوست (الف): مولفه‌های تجزیه شده سری زمانی تقاضای برق توسط موجک دابیشز 5



Original signal




Details level 1 for db5



Details level 2 for db5



Approx.level 3 for db5



مأخذ: خروجی Matlab

پیوست (ب): نتایج تخمین مدل $ARMA$ همراه با اثر $ARCH$

Dependent Variable: F
 Method: ML - ARCH (Marquardt) - Normal distribution
 Date: 12/09/10 Time: 05:48
 Sample (adjusted): 10/14/1384 11/04/1387
 Included observations: 1117 after adjustments
 Convergence achieved after 28 iterations
 MA backcast: 10/13/1384, Variance backcast: ON
 GARCH = C(10) + C(11)*RESID(-1)^2

	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000906	0.000381	2.379524	0.0173
AR(1)	-0.324020	0.027943	-11.59562	0.0000
AR(2)	-0.273481	0.022951	-11.91570	0.0000
AR(3)	-0.229360	0.021859	-10.49274	0.0000
AR(4)	-0.236298	0.018848	-12.53702	0.0000
AR(5)	-0.239113	0.021954	-10.89168	0.0000
AR(6)	-0.253374	0.019157	-13.22629	0.0000
AR(7)	0.552126	0.022830	24.18391	0.0000
MA(1)	0.131621	0.031738	4.147053	0.0000

Variance Equation				
C	0.000429	2.08E-05	20.65441	0.0000
RESID(-1)^2	0.801163	0.068786	11.64714	0.0000

R-squared	0.92398	Mean dependent var	0.000242
Adjusted R-squared	0.477718	S.D. dependent var	0.044598
S.E. of regression	0.032230	Akaike info criterion	-4.300309
Sum squared resid	1.148917	Schwarz criterion	-4.250889
Log likelihood	2412.723	F-statistic	103.0775
Durbin-Watson stat	2.061206	Prob(F-statistic)	0.000000

Inverted AR Roots	.68	.59-.74i	.59+.74i	-.22+.95i
	-.22-.95i	-.88+.42i	-.88-.42i	

مأخذ: خروجی‌های EViews

پیوست (ج): نتایج آزمون F برای معیار $RMSE$

Test for Equality of Means of ARIMA			
Categorized by values of NN			
Date: 12/09/10 Time: 23:29			
Sample: 1/01/2010 1/10/2010			
Included observations: 10			
Method	df	Value	Probability
Anova F-statistic	(3, 6)	13.32191	0.0046
Analysis of Variance			
Source of Variation	df	Sum of Sq.	Mean Sq.
Between	3	40821247	13607082
Within	6	6128438.	1021406.
Total	9	46949685	5216632.

Test for Equality of Means of ARIMA			
Categorized by values of WDNIN			
Date: 12/09/10 Time: 23:34			
Sample: 1/01/2010 1/10/2010			
Included observations: 10			
Method	df	Value	Probability
Anova F-statistic	(3, 6)	13.32191	0.0046
Analysis of Variance			
Source of Variation	df	Sum of Sq.	Mean Sq.
Between	3	40821247	13607082
Within	6	6128438.	1021406.
Total	9	46949685	5216632.

Test for Equality of Means of NN			
Categorized by values of WDNIN			
Date: 12/09/10 Time: 23:36			
Sample: 1/01/2010 1/10/2010			
Included observations: 10			
Method	df	Value	Probability
Anova F-statistic	(3, 6)	54.54129	0.0001
Analysis of Variance			
Source of Variation	df	Sum of Sq.	Mean Sq.
Between	3	43577674	14525891
Within	6	1597970.	266328.4
Total	9	45175645	5019516.

مأخذ: خروجی‌های EViews