

پیش بینی بار کوتاه مدت با استفاده از تجزیه سری زمانی بار و شبکه عصبی

روح الله فیروزنیا ، دکتر نیما امجدی *

دانشکده مهندسی برق و کامپیوتر، پردیس فنی، دانشگاه سمنان

namjadi@semnan.ac.ir

(دریافت مقاله: اردیبهشت ۱۳۸۷، پذیرش مقاله: دی ۱۳۸۷)

چکیده

پیش بینی بار کوتاه مدت یک فرآیند پایه در بهره برداری سیستم‌های قدرت محسوب می‌شود. بسیاری از توابع بهره‌برداري نظیر آرایش تولید، پخش بار اقتصادی، ارزیابی ایمنی و هماهنگی آبی حرارتی به پیش‌بینی بار کوتاه‌مدت وابسته می‌باشند. در طی سه دهه اخیر روش‌های مختلفی برای پیش‌بینی بار کوتاه مدت ارائه شده و نرم‌افزارهای صنعتی متعددی نیز بر پایه این روش‌ها تهیه شده‌اند. از جمله این روش‌ها می‌توان به انواع سری‌های زمانی، هموارسازی نمایی، فیلتر کالمن، شبکه‌های عصبی و شبکه‌های فازی عصبی اشاره نمود. مشکلی که تمام روش‌های پیش‌بینی بار کوتاه مدت با آن مواجه می‌باشند، انتخاب ورودی‌های مناسب است. این امر وابسته به مشخصات سیستم قدرت بوده و با گذشت زمان و تغییر الگوی بار تغییر می‌کند. در این مقاله ابتدا سری زمانی بار از طریق یک تبدیل ریاضی مناسب (تبدیل موجک) تجزیه شده و سپس از سری‌های حاصل شده پارامترهای ورودی برای آموزش شبکه عصبی استخراج می‌شوند.

واژگان کلیدی: پیش‌بینی بار، شبکه عصبی، تبدیل موجک.

مقدمه

پیش‌بینی شد. نتایج به دست آمده از این پیش‌بینی با نتایج دیگر مقالات مورد مقایسه قرار گرفت. مقایسه نتایج، دقت بالای این روش را مشخص ساخت.

پیش‌بینی بار

سه روش کلی برای پیش‌بینی بار به صورت زیر می‌باشد.

- ۱- روش های پیش‌بینی بر اساس مسیریابی داده‌های موجود از گذشته و حال بار (روش های مبتنی بر تعمیم)
- ۲- روش های پیش‌بینی بر اساس مدل های اقتصادی و آماری (روش های مبتنی بر اقتصادسنجی)
- ۳- روش های پیش‌بینی بر اساس شناخت مصارف نهایی انرژی الکتریکی (روش های مبتنی بر مصرف نهایی) با توجه به در دسترس نبودن داده‌های مربوط به روش های اقتصادسنجی و مصرف نهایی معمولاً از روش های مبتنی بر تعمیم استفاده می‌گردد. جهت پیش‌بینی بار انتخاب مدل مناسب در اولویت قرار می‌گیرد لذا برحسب رفتار گذشته بار باید مدلی را یافت که حداکثر تطابق را داشته باشد. برای ارزیابی میزان تطابق داده‌ها با مدل انتخاب شده می‌توان از آزمون‌هایی استفاده نمود. یکی از این آزمون‌ها، تست R^2 می‌باشد که در واقع بیان‌کننده انحراف از میانگین برای داده‌های واقعی به انحراف از میانگین برای داده‌های حاصل از مدل می‌باشد.

$$R^2 = \frac{\sum (y(t) - \bar{y})^2}{\sum (\hat{y}(t) - \bar{y})^2} \quad (1)$$

در این رابطه:

$y(t)$: بار الکتریکی واقعی. \bar{y} : میانگین بار. $\hat{y}(t)$: بار پیش‌بینی شده.

هر چه مقدار R^2 به ۱ نزدیکتر باشد، نشان دهنده تطابق بیشتر مدل با داده‌های بار است. مدل‌هایی که برای پیش‌بینی بار مورد استفاده قرار می‌گیرند، به صورت زیر می‌باشند.

۱- روش رگرسیون خطی چندگانه (MLR)

در این روش، بار برحسب متغیرهایی نظیر آب و هوای محیط بیان می‌شود که بر روی مقدار بار الکتریکی تأثیر

متخصصان سیستم‌های قدرت سال‌هاست که بنا به دلایل و نیازهای مختلف، در تلاشند روشی دقیق جهت برآورد بار بیابند. پیش‌بینی یا برآورد آینده بار الکتریکی نه تنها به هنگام برنامه‌ریزی بلند مدت سیستم‌های قدرت جهت احداث نیروگاه‌های جدید و یا مدیریت تولید و توزیع انرژی مورد استفاده قرار می‌گیرد، بلکه پیش‌بینی کوتاه مدت بار الکتریکی موجب صرفه‌جویی اقتصادی در هزینه‌ها، زمان بندی مناسب برای بهره‌برداری اقتصادی از واحدهای قدرت، زمان بندی مناسب جهت برنامه‌ریزی تعمیرات و سرویس دوره‌ای نیروگاه‌ها و خطوط انتقال و نیز طراحی مناسب ظرفیت ترانس‌ها، آرایش فیدرها و گسترش پست‌ها می‌گردد. در سال‌های گذشته پیش‌بینی بار توسط چهار روش عمده انجام می‌گرفت.

۱- روش رگرسیون

۲- روش سری‌های زمانی

۳- روش‌های متوسط‌گیری

۴- روش‌های هموارسازی نمایی

با پیدایش شبکه‌های عصبی، دورجدیدی در پیش‌بینی بار پدیدار گشت به طوری که در دهه‌های اخیر با اعمال این شبکه‌ها در فرایند پیش‌بینی بار، این پیش‌بینی‌ها از دقت بهتری برخوردار می‌باشند [۴-۱]. همان طوری که می‌دانیم بار شبکه، تابعی غیرایستاتن است. بنابراین از اعمال تبدیلاتی مانند تبدیل فوریه بر روی بار الکتریکی باید اجتناب کنیم بدین علت که تبدیل فوریه و امثال آن بر روی سیگنال‌های ایستاتن اعمال می‌گردند و سیگنال را از فضای زمانی به فضای فرکانسی سوق می‌دهند. در چند دهه اخیر تبدیل دیگری به نام تبدیل موجک پدیدار شد. از خواص بسیار مفید این تبدیل اعمال آن بر روی سیگنال‌های غیر ایستاتن می‌باشد. به دلیل اینکه برخلاف تبدیل فوریه که تنها سیگنال را به حوزه فرکانسی برده و بعد زمان را از میان می‌برد، تبدیل موجک سیگنال را به حوزه فرکانسی می‌برد و اطلاعات زمانی سیگنال نیز در دسترس می‌باشد. به عنوان مثال ما می‌دانیم که سیگنال تبدیل شده از طریق تبدیل موجک مثلاً در چه زمانی اتفاق افتاده است. کاری که انجام شد این بود که بار شبکه با استفاده از تبدیل موجک تجزیه شد. سپس با استفاده از شبکه‌های عصبی که ساخته شد بار شبکه به صورت ساعتی و روزانه

۳-۱- روش میانگین ساده (SA)^۷

۳-۲- روش میانگین متحرک یک مرحله‌ای (SMA)^۸

۳-۳- روش میانگین متحرک دومرحله‌ای (DMA)^۹


۴- روش های هموارسازی نمایی

روش های هموارسازی نمایی نیز به انواع مختلف تقسیم می‌شوند. در این روش ها به داده‌های گذشته، وزن‌های نامساوی داده می‌شود. به دلیل این که وزن‌ها توسط یک الگوی نمایی به دست می‌آیند، به این روش ها نمایی گفته می‌شود. همه این روش ها نیاز به تعیین پارامترهای مهمی دارند که در واقع وزن‌های نامساوی را تعیین می‌کنند. مثلاً روش هموارسازی یک مرحله‌ای به یک پارامتر نیاز دارد. این پارامتر ابتدا دلخواه انتخاب می‌شود بعد با محاسبه مقدار خطا این پارامتر آن قدر تغییر داده می‌شود تا خطا حداقل گردد. هموارسازی نمایی دومرحله‌ای شامل دو معادله هموارسازی نمایی می‌باشد. در روش های نمایی وزن‌ها به صورت نمایی از داده‌های جدید به داده‌های قدیم کاهش می‌یابند. نقطه اشتراک این روش ها این است که داده‌های جدید وزن زیادتر و داده‌های قدیم وزن کمتر دارند.

بارشبهک غیرایستاد می‌باشد و در مدل هایی که مورد بررسی قرار گرفت ابتدا بارشبهک توسط توابع موجک تجزیه شد و سپس سری تجزیه شده بار مورد ارزیابی قرار گرفت.

تبدیل موجک^{۱۰}

تبدیل موجک مشکلات مطرح‌شده در تبدیل فوریه را ندارد. این تبدیل اجازه می‌دهد که جهت آنالیز فرکانس های پایین از پنجره‌های زمانی بزرگ استفاده شود و همچنین جهت آنالیز فرکانسهای بالا از پنجره‌های زمانی کوچک استفاده می‌شود. [۵]



شکل ۲، تبدیل موجک


می‌گذارند. مدل بار با استفاده از این روش به صورت زیر در می‌آید.

$$y(t) = a_0 + a_1x_1(t) + a_2x_2(t) + \dots + a_nx_n(t) + a(t) \quad (2)$$

متغیرهای توصیف کننده این مدل با استفاده از آنالیز همبستگی هر یک از این متغیرهای مستقل با متغیر بار بیان می‌شوند.

۲- روش سری های زمانی تصادفی (STS)^۲

عمومی‌ترین روشی که برای پیش‌بینی کوتاه مدت بار به کار می‌رود، روش سری های زمانی می‌باشد. در این روش سری بار به عنوان خروجی یک فیلتر خطی که ورودی آن یک سری زمانی تصادفی است، در نظر گرفته می‌شود.



شکل ۱، مدل سازی سری زمانی بار

برحسب این که فیلتر دارای چه مشخصاتی باشد، مدل های مختلفی به دست می‌آیند که عبارتند از:

۲-۱- روش رگرسیون خودکار (AR)^۳

۲-۲- روش میانگین متحرک (MA)^۴

۲-۳- روش میانگین متحرک رگرسیون خودکار

(ARMA)^۵

۲-۴- روش میانگین متحرک همراه بار رگرسیون خودکار

(ARIMA)^۶

۳- روش های متوسط گیری

در سری های زمانی، بار به عنوان خروجی فیلتر خطی است که ورودی آن یک سری داده‌های تصادفی است. برحسب این که فیلتر دارای چه مشخصاتی باشد، مدل های مختلفی به دست می‌آید. روش های متوسط گیری و هموارسازی نمایی از جمله این مدل ها هستند. روش های متوسط گیری به انواع مختلف تقسیم‌بندی می‌شوند.

7 -Simple Average

8 -Simple Moving Average

9 -Double Moving Average

10 - Wavelet


2 -Stochastic Time Series

3 -Auto Regressive

4 -Moving Average


5 -Auto Regressive Moving Average

6 -Auto Regressive Integrated Moving Average



شکل ۴، فیلترینگ سیگنال

سیگنال **S** از دو فیلتر مکمل پایین گذر و بالا گذر می گذرد و به دو جزء تبدیل می گردد. اگر این عمل بر روی سیگنال دیجیتال حقیقی انجام پذیرد، نمونه‌هایی بیش از نمونه اصلی سیگنال به دست می آید. به عنوان مثال اگر سیگنال اصلی شامل ۱۰۰۰ نمونه باشد، هر یک از سیگنالهای **A** و **D** به دست آمده از فیلترینگ بالا شامل ۱۰۰۰ نمونه خواهند بود و در مجموع ۲۰۰۰ نمونه به دست می آید.



شکل ۵، انجام فیلترینگ نمونه‌های سیگنال

با انجام این عمل، ۲۰۰۰ نمونه به جای ۱۰۰۰ نمونه حاصل می شود. ما یک نمونه از دو نمونه سیگنال های به دست آمده را نگه داشته، به طوریکه بتوان اطلاعات کاملی از سیگنال را توسط آن ها به دست آورد. این عمل را کم کردن نمونه‌ها^{۱۵} می نامند. دو توالی به دست می آورید که آن ها را ضرایب تقریب^{۱۶} و ضرایب جزئیات^{۱۷} می نامند. فرآیندی که مطرح شد و در آن عمل کم کردن نمونه‌ها انجام شد، ضرایب تبدیل موجک گسسته را می دهد. یک سیگنال صاف سینوسی با نویزهای فرکانس بالایی که به آن اضافه شده‌اند در نظر گرفته می شود و تبدیل موجک گسسته یک مرحله‌ای روی آن انجام می شود.


تبدیل موجک پیوسته (CWT)^{۱۱}

تبدیل موجک پیوسته یک سیگنال، به صورت حاصل ضرب سیگنال زمانی در تابع موجک شیفته یافته و مقیاس بندی شده می باشد.

$$C(\text{scale, position}) = \int_{-\infty}^{+\infty} f(t)\Psi(\text{scale, position, } t)dt$$

(۳)

نتیجه تبدیل موجک پیوسته، تعداد زیادی ضرایب **wavelet** می باشند که یک تابع مقیاس بندی شده و شیفته یافته است. حاصل ضرب این ضرایب در تابع موجک شیفته یافته و مقیاس بندی شده، موجک های سیگنال زمانی را می دهد.



شکل ۳، تبدیل موجک پیوسته

تبدیل موجک گسسته (DWT)^{۱۲}

محاسبه ضرایب موجک در تبدیل موجک پیوسته با تمام مقادیر مقیاس و شیفته، کاری وقت گیر و شاید غیر ضروری باشد. در تبدیل موجک گسسته، از یک مجموعه از مقیاس ها و شیفته ها استفاده می شود. البته این نحوه استفاده از مقیاس بندی و شیفته توابع موجک نباید باعث کم کردن دقت گردد.

تقریب ها^{۱۳} و جزئیات^{۱۴}

تقریب ها، اجزایی از سیگنال با فرکانس پایین یا مقیاس بالا هستند. در حالی که جزئیات، اجزایی از سیگنال با فرکانس بالا یا مقیاس پایین می باشند. این فرآیند تجزیه سیگنال توسط عمل فیلترینگ سیگنال صورت می پذیرد.

11 - Continuous Wavelet Transform

12 - Discrete Wavelet Transform

13 - Approximations

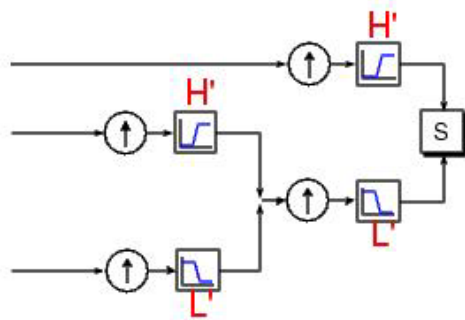
14 - Details

15 - Down sampling

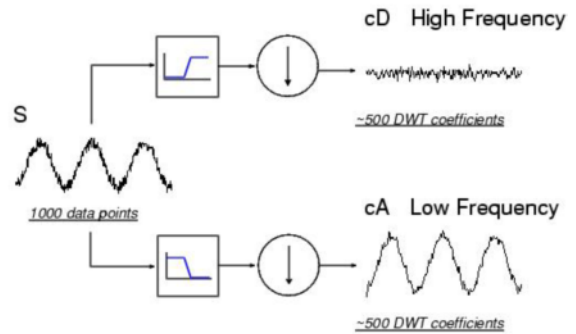
16 - CA: (Coefficient approximation)

17 - CD: (Coefficient detail)

ضرایب موجک برای انجام آن استفاده می‌کند در شکل ۸ نشان داده شده است.




شکل ۸، عمل بازیابی سیگنال




شکل ۶، تبدیل موجک بر روی سیگنال سینوسی حاوی نویز فرکانس بالا

سنتز یا بازیابی سیگنال، شامل عملیات فیلترینگ یا بالابردن نمونه‌ها^{۲۲} می‌باشد. افزودن نمونه‌ها فرآیندی است که در آن نمونه‌های یک سیگنال به وسیله انجام عملیات وارد کردن صفرها بین نمونه‌ها افزایش می‌یابد (شکل ۹).



شکل ۹، عمل Up sampling


تجزیه و ترکیب چندپله‌ای سیگنال^{۲۳} فرآیند تجزیه چند پله‌ای یک سیگنال به صورت زیر صورت می‌پذیرد (شکل ۱۰).



شکل ۱۰، تجزیه چند پله‌ای سیگنال s

تجزیه چند مرحله‌ای سیگنال^{۱۸}

فرآیند تجزیه سیگنال می‌تواند تکرار شود. تجزیه مراحل بالاتر سیگنال از طریق تجزیه تقریبی‌ها یا اجزای فرکانس پایین سیگنال صورت می‌پذیرد. این روش به صورت درخت تجزیه موجک بیان می‌گردد.



شکل ۷، نمایش درختی تجزیه موجک گسسته

بازیابی^{۱۹} سیگنال

از تبدیل موجک گسسته برای آنالیز یا تجزیه سیگنال استفاده شد. نیمه دیگر این تبدیل بدین صورت خواهد بود که چگونه اجزای سیگنال تجزیه شده توسط موجک را با هم ترکیب کرده و سیگنال اصلی را به دست آورد. این فرآیند بازیابی یا سنتز^{۲۰} نامیده می‌شود. توابع ریاضی که جهت این فرآیند به کار می‌روند، تبدیل موجک گسسته معکوس^{۲۱} را بیان می‌کنند. سنتز یک سیگنال که از

22 - Up Sampling

23 - Multi step decomposition and reconstruction


18 -Multiple Level Decomposition

19-Reconstruction

20 - Synthesis

21 - IDWT: Inverse discrete wavelet transform

فرآیند سنتز یا ترکیب سیگنال نیز توسط فرآیند فیلترینگ مشابه فرآیند تجزیه و در جهت مخالف انجام می‌شود (شکل ۱۱).




شکل ۱۱، فرآیند تجزیه و ترکیب چند لایه‌ای

در عملیات تجزیه و ترکیب موجک از توابع موجک استفاده می‌گردد. توابع موجک انواع مختلفی دارند که دو نمونه از آنها ذکر می‌شود.

تابع Haar

تابع Haar به صورت یک تابع پله‌ای می‌باشد.



شکل ۱۲، تابع موجک Haar

مدل‌های پیش بینی بار کوتاه مدت


چهار مدل پیش‌بینی بار را که از دقت بالاتری نسبت به روش‌های قبلی پیش‌بینی بار برخوردارند مورد بررسی قرار گرفت. برای مقایسه این روش‌ها با یکدیگر از داده‌های سال‌های ۱۹۸۵م. تا ۱۹۹۲م. شمال آمریکا^{۲۴} استفاده شد. برای این که این چهار مدل مورد ارزیابی قرار گیرد ابتدا باید سری زمانی بار بررسی شود. سری زمانی بار که در این چهار مدل به کار رفته‌اند نرمالیزه شده‌اند. یعنی این سری زمانی به صورت بازه‌ای بین $-0/5$ تا $+0/5$ می‌باشد. قبل از این که آنالیز موجک بر روی سری زمانی بار انجام شود، دو کار باید صورت پذیرد. ابتدا باید تابع موجک مناسب انتخاب و سپس تعداد لایه‌های تجزیه بار مشخص شود. توابع موجک زیادی برای تجزیه بار وجود دارند، در این مدل‌ها از تابع **Daubechies** استفاده شده است. تابع **Daubechies** که در این جا مورد استفاده قرار گرفت، نوع ۲ تا ۴ می‌باشد. تجزیه بار در سطح سه و چهار و پنج انجام شد. از شواهدی که در اثر تجزیه به دست آمد دیده شد که تجزیه سطح سه سری بار، دارای نتایج بهتری می‌باشد. تجزیه سطح سه، سری زمانی بار را به سری‌های **A3** و **D3** و **D2** و **D1** تبدیل می‌کند.

بررسی مدل اول

مدل اول پیش‌بینی بار، **benchmark** است [۱]. متغیرهای ورودی و خروجی ابتدا استاندارد^{۲۵} می‌شوند و سپس بین $-0/5$ و $+0/5$ نرمالیزه می‌شوند. شکل ۱۴، شبکه عصبی پرسپترون سه‌لایه را نشان می‌دهد. ساختار این مدل شامل ۱۱ داده ورودی، ۴ نرون پنهان و یک نرون خروجی است.

توابع Daubechies

یکی از پرکاربردترین توابع در گستره توابع **wavelet** توابع **Daubechies** می‌باشند. تابع **db1** همان تابع Haar است (شکل ۱۳).



شکل ۱۳، توابع Daubechies

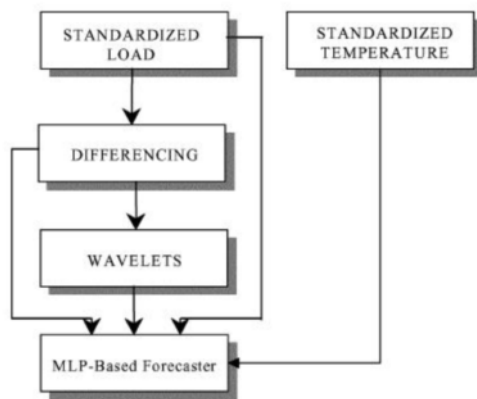
24- North American

25- منظور از استاندارد کردن داده، تغییر داده با میانگین صفر و انحراف معیار ۱ است.

چند تحلیل^{۲۶} ترکیب می‌کند. بنابراین چندین ترکیب از متغیرهای ورودی در این مدل مورد بررسی قرار می‌گیرند. با تحلیلی که صورت گرفت مشخص شد که اطلاعات به دست آمده از تجزیه سری زمانی تفاضلی بسیار مفیدتر از تجزیه سری اصلی بار می‌باشد. به عنوان متغیرهای ورودی از سری تفاضلی **A3** و **D3** استفاده شده است. سری های تفاضلی **D1** و **D2**، قسمت های نویزی سری زمانی می‌باشند زیرا این دو سری از قسمت های فرکانس بالای سیگنال اصلی هستند بنابراین اطلاعات به دست آمده از آن ها در مدل ۳ نادیده گرفته می‌شود. خروجی این مدل به صورت زیر به دست می‌آید.

$$D(t) = P(t) - P(t-1) \quad (5)$$


ساختار شبکه عصبی، شامل ۲۳ متغیر ورودی، ۴ نرون میانی و یک نرون خروجی است. جدول ۲، متغیرهای ورودی مدل سوم را نشان می‌دهد.



شکل ۱۵، ساختار مدل سوم

جدول ۲، متغیرهای ورودی مدل سوم

Input	Variable name	Lagged values (h)
1-4	Load (P)	1, 2, 24, 168
5-8	Differenced load (D)	1, 2, 24, 168
9-12	Differenced A ₃	1, 2, 24, 168
13-16	Differenced D ₃	1, 2, 24, 168
17	Forecasted temperature	0
18-21	Temperature (T)	1, 2, 24, 168
22	HS	0
23	HC	0



شکل ۱۴، ساختار MLP مدل اول

بررسی مدل دوم

دومین مدل پیش‌بینی متغیرهای تفاضلی را به مجموعه متغیرهای ورودی مدل اول اضافه می‌کند. بنابراین سه سری زمانی برای مجموعه متغیرهای ورودی به کار می‌روند. ۱- بار ساعتی استاندارد شده و نرمالیزه شده (**p**) ۲- متغیر دما (**T**) و ۳- اختلاف بار مرتبه اول (**D**). جدول ۱ متغیرهای ورودی مدل دوم را نشان می‌دهد [۵].

جدول ۱، مجموعه متغیرهای ورودی مدل دوم

Input	Variable name	Lagged values (h)
1-4	Load (P)	1, 2, 24, 168
5-8	Differenced load (D)	1, 2, 24, 168
9	Forecasted temperature	0*
10-13	Temperature (T)	1, 2, 24, 168
14	HS	0*
15	HC	0*

*Lag 0 represents the target instant.

خروجی مدل دوم بار تفاضلی نرمالیزه شده و استاندارد شده است. بنابراین خروجی این مدل به صورت زیر به دست می‌آید.

$$D(t) = P(t) - P(t-1) \quad (4)$$

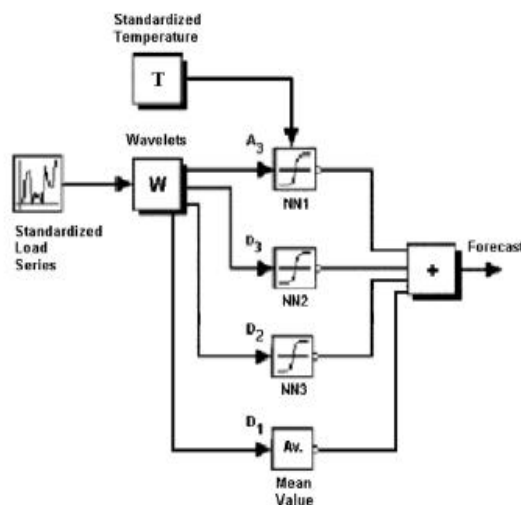
ساختار پرسپترون مدل دوم پیش‌بینی بار شامل ۱۵ متغیر ورودی، ۴ نرون پنهان و یک نرون خروجی می‌باشد.

بررسی مدل سوم

مدل سوم، شکل ۱۵ پیش‌بینی بار، بار استاندارد شده و نرمالیزه شده و همچنین بار تفاضلی مرتبه اول را با آنالیز

بررسی مدل چهارم

مدل چهارم تخمینی متفاوت نسبت به سه مدل قبلی می باشد. [۲-۴]. تجزیه بار توسط تابع موجک **Daub2** انجام می شود. اجزای سری زمانی که در این جا مدل می گردند به ترتیب **A3** و **D3** و **D2** و **D1** می باشند. پیش بینی نهایی از مجموع چهار پیش بینی به دست می آید. شکل ۱۶ دیاگرام مدل چهارم پیش بینی بار را نشان می دهد.



شکل ۱۶، ساختار مدل چهارم

متغیر های ورودی مدل چهارم در جدول ۳ نشان داده شده است.

جدول ۳، متغیرهای ورودی مدل چهارم

NN	Input	Variable name	Lags (h)	Output
1	1-4	Approximation (A ₃)	1, 2, 24, 168	A ₃ (h)
	5-8	Differenced A ₃	1, 2, 24, 168	
	9	Forecasted Temp.	0	
	10-13	Temperature (T)	1, 2, 24, 168	
	14	HS	0	
2	15	HC	0	D ₃ (h)
	1-5	Detail (D ₃)	1, 2, 12, 24, 168	
	6-10	Differenced D ₃	1, 2, 12, 24, 168	
3	11	HS	0	D ₂ (h)
	12	HC	0	
	1-5	Detail (D ₂)	1, 2, 12, 24, 168	
	6-10	Differenced D ₂	1, 2, 12, 24, 168	

زیرمدل A3

از آن جایی که تقریب **A3**، وجه هموار^{۲۷} سری زمانی بار می باشد متغیرهای ورودی آن مانند متغیرهای مدل ۲

می باشد. این شبکه شامل ۳ نرون پنهان و یک نرون خروجی است.

زیرمدل D2 و D3

آنالیز خودهمبستگی^{۲۸} برای انتخاب متغیرهای ورودی **D2** و **D3** استفاده شده است. جدول ۳ متغیرهای ورودی و خروجی زیر مدل های **D2** و **D3** را نشان می دهد. این جدول نشان می دهد که زیرمدلهای **D2** و **D3** ساختار مشابهی دارند. ساختار این زیر مدل کاملاً با زیر مدل قبلی متفاوت است. اختلافات اصلی به گونه زیر می باشد.

۱- با توجه به آنالیز خود همبستگی که انجام شد مشخص گردید که پنج متغیر ورودی بار باید به عنوان متغیرهای ورودی به کار روند در حالی که در مدل **A3** چهارمتغیر ورودی به کار رفت.

۲- در این زیرمدل ها، اطلاعات دمایی به عنوان متغیرهای ورودی انتخاب نشده اند. این نتیجه در اثر آنالیز همبستگی متقاطع حاصل شد.

زیرمدل های **D2** و **D3** شامل ۳ نرون مخفی و یک نرون خروجی می باشند.

زیرمدل D1

از آن جایی که سری زمانی **D1** بیشتر به قسمت نویزی سری بار وابسته می باشد، پیش بینی این سطح سری بار بر مقادیر میانگین استوار است. سری **D1** در واقع برابر مقدار میانگین داده های ۶ هفته قبل زمان پیش بینی است. داده های شمال آمریکا را بر روی این ۴ مدل تست شد. نتایج حاصل که پیش بینی بار ساعتی^{۲۹} و پیش بینی بار روزانه^{۳۰} (۲۴ ساعت آینده) می باشند در جداول ۴ و ۵ آورده شده است.

برای مقایسه این چهار مدل از مفاهیم **MAPE**^{۳۱} و **MSE**^{۳۲} و **ME**^{۳۳} استفاده می شود. **MAPE** به عنوان معیاری مناسب برای مقایسه این مدل ها می باشد.

- 28 - Auto Correlation
- 29 - Hourly load forecasting
- 30 - 1-24 hours ahead
- 31 - Mean absolute percentage error
- 32 - Mean square error
- 33 - Mean error

27- Smooth

بار (A3,D3,D2,D1) و همچنین انجام عملیات **Auto correlation** بین این سری های زمانی و داده های دما. ۳- به دست آوردن ورودی های شبکه عصبی **(input features)** توسط آنالیز **Correlation** برای هر یک از شبکه های عصبی که قرار است عملیات پیش بینی را بر روی داده های ورودی انجام دهند. ۴- انجام عملیات نرمالیزاسیون داده ها و همچنین استاندارد کردن داده ها

۵- انجام **Cross validation** بر روی شبکه برای به دست آوردن تعداد بهینه تکرار عملیات آموزش داده ها ۶- استفاده از الگوریتمی مناسب برای هر یک از چهار شبکه عصبی ساخته شده برای به دست آوردن تعداد نرون های مخفی هر یک از شبکه ها ۷- استفاده از چهار شبکه عصبی مجزا برای هر یک از سری های زمانی بار. (A3,D3,D2,D1) ۸- استفاده از الگوریتم تکاملی EA³⁴ در هر مرحله طراحی برای بهبود وزنه ها.

۹- استفاده از بار یک سال گذشته شبکه برای آموزش شبکه عصبی

۱۰- انجام عمل پیش بینی بار روزانه (**Day ahead forecasting**) و پیش بینی بار ساعتی (**Next hour forecasting**) برای داده های واشنگتن (شمال آمریکا) و داده های نیویورک و همچنین مقایسه نتایج بدست آمده از این پیش بینی بار با نتایج مقاله های به روز بین المللی **IEEE** و **IEE**.

۱۱- به دست آوردن **MAPE** بعنوان معیاری مناسب برای مقایسه نتایج با همدیگر.

نتیجه ای که از این طراحی برای پیش بینی بار ساعتی و روزانه به دست آمد، بهبود عمل پیش بینی را به وضوح در این مدل آشکار می سازد.

جدول ۶ و ۷ مقادیر **mape** مدل طراحی شده پیشنهادی را نشان می دهد.

$$MAPE = \frac{(p(t) - \hat{p}(t))}{p(t)} \times 100\% \quad (6)$$

جدول ۴، پیش بینی بار ساعتی (**next hour forecasting**)

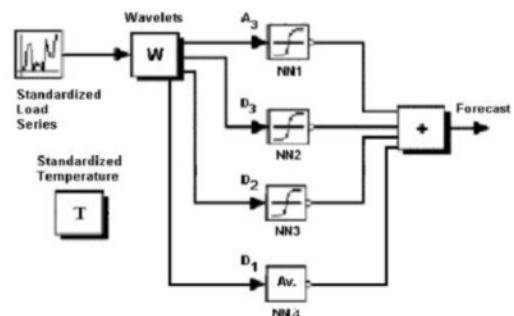
Index	M1	M2	M3	M4
MAPE (%)	2.15	1.11	1.14	2.04
MSE (MW ²)	3,841	1,207	1,291	4,116
ME (MW)	-4.52	0.13	-1.50	-3.99

جدول ۵، پیش بینی بار روزانه (پیش بینی بار ۲۴ ساعت بعد)

Index	M1	M2	M3	M4
MAPE (%)	3.58	3.41	3.16	2.64
MSE (MW ²)	11,754	12,011	10,522	6,599
ME (MW)	-12.42	-6.73	-9.48	-6.39

نتیجه گیری

مدل هایی که جهت پیش بینی بار به کار گرفته شده اند مورد مطالعه قرار گرفت. نتایجی که بر روی داده های شمال آمریکا حاصل شد و در آن بار شبکه برای یک ساعت آینده و همچنین یکروز آینده توسط چهار مدل ذکر شده پیش بینی شد مورد ملاحظه قرار گرفت. مدلی برای پیش بینی بار طراحی شد که نتایج به مراتب بهتری نسبت به مدل های گذشته را ارائه کرده است. ساختار این مدل پیشنهادی در شکل ۱۷ دیده می شود.



شکل ۱۷، ساختار مدل پیشنهادی

برای مدل ارائه شده عملیات زیر انجام شد.

۱- انجام عمل تجزیه بار شبکه برق توسط تابع **db4** که از توابع تجزیه **wavelet** می باشد.

۲- انجام عملیات **Auto correlation** و **Cross correlation** بر روی هر یک از سری های زمانی

جدول ۶، پیش بینی بار روزانه

Index	مدل پیشنهادی
MAPE(%)	2.04

از مزایای این مدل پیشنهادی پیش بینی، نسبت به مدل چهارم یاد شده در بالا، بهبود ۲۲ درصدی در پیش بینی بار کوتاه مدت روزانه و بهبود ۵۱/۵ درصدی در پیش بینی بار کوتاه مدت ساعتی است.

جدول ۷، پیش بینی بار ساعتی

Index	مدل پیشنهادی
MAPE(%)	0.99

مراجع

- 1 D. C. Park and M. A. El-sharkawi and R. J. Marks; "Electric Load Forecasting Using an Artificial Neural Network"; IEEE Trans. Power Syst. Vol.6, no.2, pp.442-449, May 1991.
- 2 M. Ning and C. Yunping; "An ANN and wavelet transformation based method for short term load forecasting"; in Proc. Int. Conf. energy manage power Del. Vol.2, Singapore, Mar.1998, pp.405-410.
- 3 B. L. Zhang and Z. Y. Dong; "An adaptive neural network model for shrt term load forecasting"; Elect. Power Syst. Res. Vol.59, no.2, pp.121-129, sep.2001.
- 4 C. I. Kim and L. K. Yu and Y. H. Song; "Kohonen neural network and wavelet transformation based approach to short term load forecasting"; Elect Power Syst. Res. Vol.63, no.3, pp.169-176, Oct.2002.
- 5 Agnaldo. J. Rocha Reis and Alexandre. P. Alves da silva; "Feayure Extraction Via Multiresolution Analysis for short term load forecasting"; IEEE Trans, power syst, vol.20, no.1, Feb 2005.