



روشی ساده جهت بهبود پیش بینی کوتاه مدت بار با استفاده از شبکه های عصبی

علی کاشفی کاویانی، فاطمه جهانبانی اردکانی، علی جهانبانی اردکانی، سید حسین حسینیان
ali_kashefi@aut.ac.ir, jahanbani@aut.ac.ir, ali_jahanbani@aut.ac.ir, hosseinian@aut.ac.ir

۱- مقدمه

پیش بینی بار بر حسب بازه پیش بینی، به چند دسته تقسیم می شود. در یک نگاه کلی، پیش بینی بار سه دسته اصلی کوتاه مدت، میان مدت، و بلندمدت تقسیم می گردد [۲]. از آنجایی که پیش بینی بار کوتاه مدت نقشی حیاتی در برنامه ریزی بهینه واحدها، راه اندازی^۳ و خاموشی^۴ واحدهای حرارتی، کنترل ذخیره گردان^۵ و همچنین خرید و فروش توان در سیستمهای بهم پیوسته^۶، ایفا می نماید، عمده توجه بر روی پیش بینی کوتاه مدت متمرکز شده است.

شبکه های عصبی به علت توانایی یافتن نگاشت بین ورودی و خروجی در توابع پیچیده و غیر خطی یکی از مناسبترین ابزار جهت پیش بینی کوتاه مدت بار الکتریکی می باشند. برنامه مورد استفاده برای شبکه عصبی به کار گرفته شده در این مقاله، از ویژگی هایی چون انعطاف پذیری بالا (برای هر شبکه با هر تعداد لایه و نرون) و نیز قابلیت افزودن تابع انتقال دلخواه به برنامه با کمترین تغییر ممکن دارا می باشد.

بارزترین خصوصیت شبکه عصبی پیشنهاد شده استفاده از دو متغیر ورودی جدید است که متغیر اول نشان دهنده کاری یا غیر کاری بودن هر روز و متغیر دوم نشان دهنده کاری یا غیر کاری بودن هر ساعت می باشد. تأثیر این دو عامل را می توان با

چکیده- پیش بینی کوتاه مدت بار، نقشی کلیدی

در بهره برداری اقتصادی و ایمن^۱ از سیستمهای قدرت بازی می کند [۱]. پیش بینی دقیق بار، با کاهش دادن هزینه ها و بهبود ایمنی بهره برداری، به شرکت های برق^۲ این اجازه را می دهد که با قیمت بهینه به تولید و خرید و فروش انرژی بپردازند. جهت بررسی عوامل مؤثر بر پیش بینی کوتاه مدت بار می توان از شبکه های عصبی استفاده کرد. مهمترین قسمت جهت ساختن یک شبکه عصبی برای پیش بینی بار، انتخاب متغیرهای ورودی می باشد.

در این مقاله با استفاده از الگوریتم لوبنبرگ-مارکواردت که به عنوان سریعترین روش آموزش شبکه های عصبی چند لایه می باشد، برنامه ای در فضای برنامه نویسی نرم افزار MATLAB 7.1 نوشته شده است که به آموزش شبکه های عصبی می پردازد. در انتخاب ورودی ها از دو متغیر جدید استفاده شده است و سپس به بررسی تأثیر اضافه کردن این متغیرها به ورودی های شبکه، پرداخته شده است. الگوریتم پیشنهادی بر روی یک نمونه بار یکی از پست های تهران پیاده سازی شده است که نتایج نشان دهنده بهبود پیش بینی بار و کارایی روش پیشنهاد شده می باشد. از جمله محاسن بارز این روش علاوه بر بهبود کلی پیش بینی بار، بهبود چشمگیر پیش بینی بار در روزهای تعطیل میان هفته می باشد.

³ Start up

⁴ Shut Down

⁵ Spinning Reserve

⁶ Inter Connected

¹ Secure

² Utilities

یک نگاه به الگو و اندازه پروفیل بار روزانه ایام تعطیل و غیر تعطیل درک کرد. چنانکه در بخشهای بعدی مشاهده خواهد شد، اعمال این متغیرها، تاثیر چشمگیری در پیش‌بینی بار روزهای تعطیل میان هفته خواهد داشت.

۲- شبکه‌های عصبی

شبکه‌های عصبی مصنوعی، که کارکرد آنها بر پایه مشخصه‌های نرونهای بیولوژیکی می‌باشد، متشکل از عناصر پردازشگر بهم پیوسته زیادی هستند که می‌توانند به عنوان جانشینی برای روشهای محاسباتی متداول در نظر گرفته شوند. از ویژگی‌های این شبکه‌ها یافتن نگاشتهای پیچیده موجود بین ورودی-خروجی بدون نیاز به برنامه‌نویسیهای دشوار و استخراج ارتباطات (خطی و غیر خطی) بین داده‌های موجود از طریق فرایند آموزش می‌باشد. همچنین این شبکه‌ها به علت دارا بودن ساختار موازی، توانایی پردازش با سرعت بسیار بالایی را دارا می‌باشند [۱].

قابلیت اصلی شبکه‌های عصبی که باعث بکارگیری آنها در پیش‌بینی بار شده‌است، توانایی بالای این شبکه‌ها در تشخیص الگوها و یادگیری ارتباط بین ورودیها و خروجیها می‌باشد. الگوریتم مورد استفاده در آموزش شبکه‌های عصبی چند لایه، الگوریتم پس‌انتشار^۷ است که با استفاده از مفهوم گرادیان^۸ و با حرکت بر روی تندترین شیب^۹ موجود در سطح^{۱۰} تابع منجر به رسیدن به نقطه کمینه (سراسری^{۱۱} یا محلی^{۱۲}) تابع می‌گردد [۲].

با توجه به اینکه الگوریتم لونیبرگ-مارکواردت به عنوان سریعترین روش آموزش شبکه‌های عصبی چند لایه توصیه شده‌است، در این مقاله نیز بر اساس الگوریتم لونیبرگ-مارکواردت به آموزش شبکه‌های عصبی پرداخته شده است.

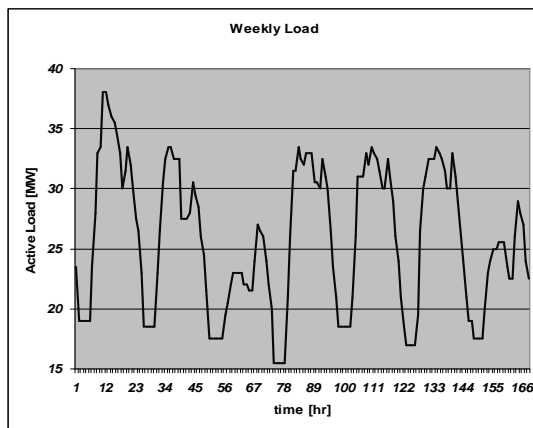
۳- ساختار شبکه عصبی پیشنهادی

ساختار مورد استفاده در اینجا یک شبکه دو لایه است که تابع انتقال لایه اول (لایه پنهان) از نوع سیگموئید و تابع انتقال لایه دوم (لایه خروجی) آن از نوع خط راست می‌باشد.

مهمترین کار در ساختن یک شبکه عصبی برای پیش‌بینی بار، انتخاب متغیرهای ورودی است. قانون کلی

خاصی برای این منظور در دست نیست. این امر بیشتر به قضاوت مهندسی و تجربه وابسته بوده و تقریباً در تمامی موارد با سعی و خطا همراه می‌باشد. با این حال بعضی از مطالعات آماری می‌توانند در تعیین متغیرهایی با تاثیر بیشتر بر بار سیستم موثر باشند [۱]. عمده متغیرهایی که در پیش‌بینی کوتاه مدت بار الکتریکی مورد استفاده واقع می‌شوند، متغیرهای روز هفته، ساعت، دما و اندازه‌گیریهایی ثبت شده مربوط به بار طی چند روز گذشته می‌باشند. در این مطالعه از این متغیرها نیز استفاده خواهد شد.

یکی از مهمترین عواملی که مستقیماً بر شکل‌گیری پروفیل بار هر منطقه تاثیر می‌گذارد، کاری یا غیر کاری بودن روزهای هفته است. تاثیر این عامل به حدی است که با یک دید کلی نیز می‌توان به تفاوت الگو و اندازه پروفیل بار روزانه ایام تعطیل و غیر تعطیل پی برد. این مطلب در شکل (۱) بخوبی نمایان است. پروفیل بار هفتگی پست ۶۳ kV/۲۰ kV کارون، متعلق به برق منطقه‌ای تهران، طی روزهای چهارشنبه ۲۵ مرداد تا سه‌شنبه ۳۱ مرداد ۱۳۸۵ (تعطیل) در این شکل نمایش داده شده‌است. چنانکه مشخص است پروفیل بار در روزهای تعطیل جمعه و سه‌شنبه الگوی متفاوتی را نسبت به روزهای کاری هفته دارا می‌باشد. این تفاوت، علاوه بر الگو، میزان پیک بار مصرفی را نیز شامل می‌گردد، بطوریکه در روزهای عادی، پیک بار در ساعات کاری بعد از ظهر (حدود ساعت ۱۴) رخ می‌دهد ولی در روزهای تعطیل این امر در ساعات آغازین شب (حدود ساعت ۲۰) اتفاق می‌افتد. از نظر میزان بار پیک نیز، تفاوتی در حد ۶ MW را داراست.



شکل ۱: پروفیل بار طی هفته آخر مرداد ۱۳۸۵ (خروجی پست ۶۳ kV/۲۰ kV کارون).

ایده اضافه نمودن دو متغیر جدید به ورودی‌های شبکه هم از همین اختلافات ناشی شده است. متغیر اول نشان‌دهنده کاری یا غیر کاری بودن در هر روز، و متغیر دوم نشان‌دهنده کاری یا غیر کاری بودن هر ساعت می‌باشد. این

⁷ - Back Propagation

⁸ - Gradient

⁹ - Steepest Descent

¹⁰ - Surface

¹¹ - Global

¹² - Local

۸) وضعیت کاری روز: $WD(d,h)$

۵۶ ورودی دیگر نیز متغیرهای مربوط به ۷ روز گذشته می باشند.

$(2+V_i)$ بار همین ساعت در i روز قبل: $L(d-i,h)$

$(3+V_i)$ بار ساعت گذشته در i روز قبل: $L(d-i,h-1)$

$(4+V_i)$ بار ساعت بعد در i روز قبل: $L(d-i,h+1)$

$(5+V_i)$ دمای همین ساعت در i روز قبل: $T(d-i,h)$

$(6+V_i)$ دمای ساعت گذشته در i روز قبل: $T(d-i,h-1)$

$(7+V_i)$ دمای دو ساعت گذشته در i روز قبل: $T(d-i,h-2)$

$(8+V_i)$ وضعیت کاری همین ساعت در i روز قبل: $WH(d-i,h)$

$(9+V_i)$ وضعیت کاری i روز قبل: $WD(d-i,h)$

در حالیکه، $7, 6, 5, \dots, 2, 1, 0, -1, -2, \dots, -i$

نکته لازم به ذکر آنکه، متغیرهای فوق پس از مطالعات و بررسی نتایج شبیه‌سازی‌های بسیار، از میان انبوه متغیرهای مفروض انتخاب گردیده‌اند و وجود هر کدامشان در پیش‌بینی بهتر بار مصرفی موثر می‌باشد. در توجیه انگیزه بکارگیری ورودیهای فوق نیز می‌توان اینگونه استدلال نمود که، استفاده از ورودیهای اول و دوم با توجه به تاثیر روز و ساعت بر بار مصرف بدیهی می‌باشد. از آنجائیکه دما یکی از موثرترین عوامل شکل‌گیری بار بوده ورودی‌های سوم، چهارم، پنجم و ششم نیز به این عامل اختصاص یافته است. از جمله ملاحظات در بررسی‌ها این است که برای پیش‌بینی بار در هر ساعت، علاوه بر در نظر گرفتن دما در همان ساعت، بهتر است که دمای هوا طی دو تا سه ساعت گذشته نیز وارد شبکه شود. دلیل وارد کردن ورودی‌های ۶ و ۷ هم که قبلاً شرح داده شده است.

دسته دوم ورودی‌های اعمال شده به شبکه، اطلاعات روزهای قبل است، این اطلاعات شامل بار، دمای هوا و وضعیت کاری روزهای گذشته طی ساعات مشابه می‌باشند. در واقع ایده بکارگیری این ورودی‌ها، از روش مورد استفاده در [۵] نشأت گرفته است. بدین ترتیب که اگر دو روز مختلف از نظر وضعیت آب و هوایی (از جمله نوسانات ساعتی دما) و کاری مشابه یکدیگر باشند (روزهای مشابه)، دارای الگوی بار مشابهی خواهند بود. سپس قسمتی از اطلاعات دما، بار و وضعیت کاری چند روز قبل (که تقریباً مشابه با روز پیش می‌باشند)، به عنوان ورودی به شبکه اعمال گردید و مشاهده شد که حاصل این امر بهبود نتایج بدست آمده می‌باشد.

به عنوان آخرین نکته در مورد ورودی‌ها، لازم است بدانیم که کلیه داده‌ها نرمالیزه^{۱۳} هستند. نرمالیزه کردن داده-

کار به این دلیل که مولفه بار صنعتی به عنوان بخش عمده‌ای از بار، فقط در ساعات کاری (از روزهای کاری) در مدار می باشد انجام می‌گیرد، می‌توان دسته‌ای از متغیرهای ورودی که نشان‌دهنده کاری یا غیرکاری بودن روزها و ساعات شبانه‌روز می‌باشند را به ورودی‌های شبکه اضافه نمود.

مصرف‌کنندگان الکتریکی، معمولاً، به چهار بخش عمده خانگی، تجاری، صنعتی و روشنایی تقسیم می‌شوند. کاری یا غیرکاری بودن روز و ساعت بر هر چهار بخش فوق اثر می‌گذارد. به طوری که این اثر بر مؤلفه‌های تجاری و صنعتی مستقیم بوده (این بارها تنها در ساعات کاری از روزهای کاری هفته در مدار می‌باشند) و بطور غیر مستقیم نیز بر دو مولفه خانگی و روشنایی تاثیرگذار می‌باشند. از این رو پیشنهاد می‌گردد که یک متغیر ورودی به وضعیت کاری در هر روز و متغیر دیگری نیز به وضعیت کاری هر ساعت اختصاص پیدا کند.

یکی از محاسن عمده این امر، پیش‌بینی نسبتاً دقیق بار در روزهای تعطیل میان هفته می‌باشد. چنانکه در بخشهای بعدی مشاهده خواهد شد، اعمال این متغیرها، تاثیر چشمگیری در پیش‌بینی بار روزهای تعطیل میان هفته خواهد داشت. این ویژگی در کشورهایی مانند ایران که تقویمشان دارای ایام تعطیل نسبتاً زیادی است، امتیاز بزرگی محسوب می‌شود. البته، باید اشاره نمود که این متغیرها، پیش‌بینی بار روزهای عادی را نیز بهبود می‌بخشند، هر چند که این اثر نسبت به تاثیر بر روزهای تعطیل قابل مقایسه نمی‌باشد.

در ادامه کار، متغیر مربوط به وضع کاری هر ساعت، به ورودی‌های شبکه عصبی اضافه شده است. برای ساعات ۸ صبح تا ۴ بعد از ظهر روزهای کاری میان هفته (شنبه تا چهارشنبه) و همچنین ۸ صبح تا ۱ بعد از ظهر آخرین روز کاری هفته (پنج‌شنبه) مقدار این متغیر برابر با $0/5$ و در سایر ساعات هفته برابر با $-0/5$ فرض می‌شود.

شبکه‌ای با ۶۴ ورودی طراحی می‌گردد. خروجی این شبکه بار الکتریکی مصرفی در هر ساعت خواهد بود. ورودیها به شرح زیرند.

۱) روز هفته: $D [1,2,3,6]$

۲) ساعت: $H [1,2,3,6]$

۳) دمای همین ساعت: $T(d,h) [1,2,3,6]$

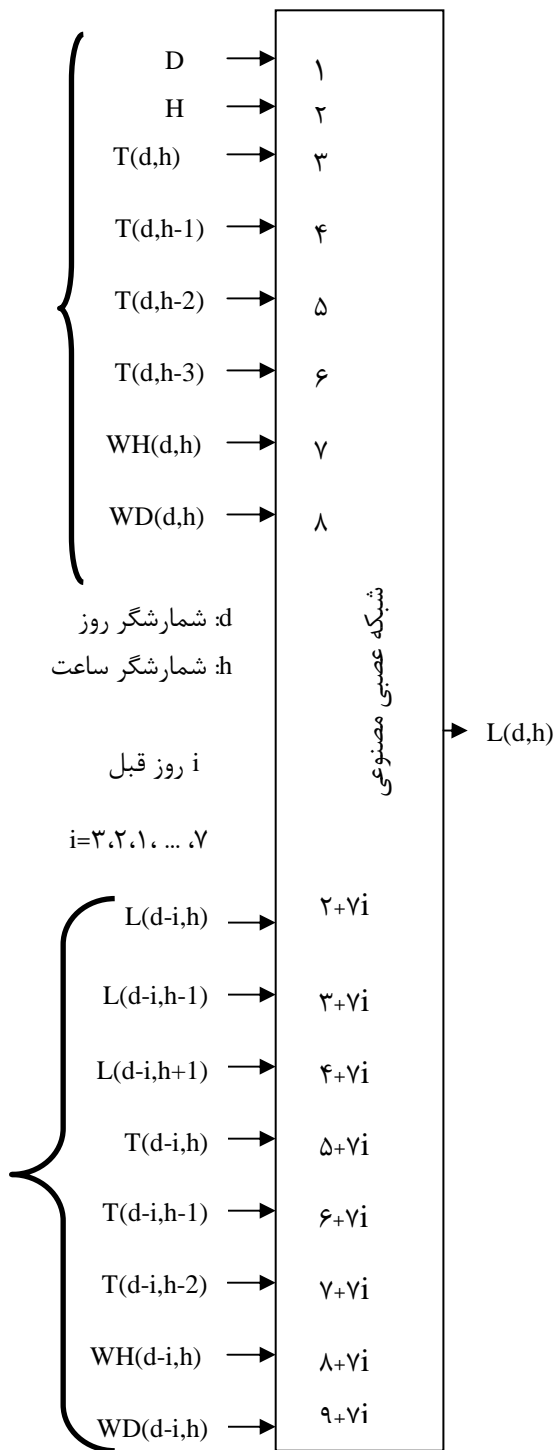
۴) دمای ساعت گذشته: $T(d,h-1) [1,2,3,6]$

۵) دمای دو ساعت گذشته: $T(d,h-2) [1,2,3,6]$

۶) دمای سه ساعت گذشته: $T(d,h-3) [1,2,3,6]$

۷) وضعیت کاری ساعت: $WH(d,h)$

امروز



شکل ۳: شبکه عصبی بکار رفته برای پیش‌بینی کوتاه مدت بار الکتریکی

این نرون‌ها، زمان مورد نیاز جهت آموزش شبکه چهار برابر می‌شود.

۴- نتایج شبیه‌سازی

در ادامه، به منظور بررسی توانایی شبکه طراحی شده برای پیش‌بینی کوتاه مدت بار الکتریکی، شبیه‌سازی بر روی پست کارون برق منطقه‌ای تهران انجام شده است. این شبیه‌سازی‌ها، در دو قسمت، برای روزهای تعطیل و روزهای کاری، انجام شده و در هر دو مورد مشاهده می‌شود که اعمال

ها، سبب تسهیل فرایند آموزش شبکه‌های عصبی شده و به کارکرد تابع تحریک^{۱۴} (تابع انتقال لایه پنهان) نیز انسجام می‌بخشد. این کار باعث می‌گردد تا ورودی‌های دارای مقادیر بزرگ (مثلاً بار کیلوواتی) اثر ورودی‌های دارای مقادیر کوچک مانند روزهای هفته یا دما را تحت تاثیر قرار ندهند و همچنین تقارن ورودی‌های تابع تحریک نیز حفظ شود[۲].

با توجه به اینکه نمونه بار مورد بررسی، خروجی یک پست با توان نامی ۶۰ MW (دو ترانسفورمر ۳۰ MW)، می‌باشند، متغیر خروجی (بار پیش‌بینی شده) در مبنای ۶۰ MW پریونیت شده است.

روش‌های مختلفی جهت نرمالیزه کردن ورودی‌ها مورد بررسی قرار گرفت. مشاهده گردید که بهترین نتیجه زمانی حاصل می‌شوند که هر ورودی با احتمال جمععی خود جایگزین شود. یعنی، ابتدا تابع توزیع احتمال جمععی (cdf)^{۱۵} [۶] مربوط به هر دسته از ورودی‌ها محاسبه شده، سپس هر ورودی با احتمال جمععی مربوط جایگزین گردد. همانطور که پیشتر نیز بدان اشاره گردید، وجود تقارن در دامنه ورودی‌ها می‌تواند باعث بهبود نتایج حاصله گردد، و این در حالیست که cdf، بازه‌ای از صفر تا یک را تحت پوشش خود قرار می‌دهد. برای غلبه بر این مشکل، cdf بدست آمده برای هر دسته از ورودی‌ها، با اعمال یک شیفت ۰/۵ واحدی به سمت چپ، از بازه [۰،۱] به بازه [-۰/۵، ۰/۵] نگاشته می‌شود. البته ورودی‌های مربوط به وضعیت کاری روز و ساعت نیز که دو مقدره می‌باشند (۰/۵ و -۰/۵)، بدون محاسبه cdf، بطور مستقیم وارد شبکه خواهند شد.


از طرفی برای یافتن تعداد بهینه نرون‌های لازم در لایه میانی از روش سعی و خطا استفاده می‌شود. برای شبکه طراحی شده در این مطالعه به نظر می‌رسد که قرار دادن چهار نرون در لایه میانی مطلوب باشد. نکته لازم به ذکر آنست که زمان لازم برای آموزش شبکه عصبی طراحی شده نسبت به تعداد نرون‌های لایه پنهان بصورت غیر خطی (تقریباً بصورت نمایی درجه دو) تغییر کرده است. مثلاً با دو برابر کردن تعداد

¹⁴- Activation Function

¹⁵- Cumulative Probability Distribution Function

جدول ۳: مقایسه صحت پیش‌بینی‌های انجام شده برای چهار حالت مختلف (دوشنبه ۱۶ مرداد).

دوشنبه ۱۶ مرداد ۱۳۸۵	I	WD	WH	WD+ WH
MAPE	5.01826%	4.14611%	4.00542%	3.41549%
MaxAPE	17.7816%	13.1606%	14.0524%	11.5747%
MAPUE	0.0177859	0.0152726	0.014502	0.0125479
MaxAPUE	0.0577813	0.0372883	0.0456704	0.0376129



شکل ۴: تاثیر اعمال ورودی‌های مربوط به وضعیت کاری روز و ساعت بر بهبود نتایج حاصله (دوشنبه ۱۶ مرداد ۱۳۸۵).

از میان روزهای تعطیل، سه روز مورد بررسی قرار می‌گیرند. این روزها عبارتند از: پنج‌شنبه ۸ تیرماه، جمعه ۱۶ تیرماه و سه‌شنبه ۳۱ مردادماه ۱۳۸۵. دقت شود که جمعه همواره یک روز است در حالی که دو روز دیگر جزء روزهای کاری هفته بوده که به مناسبتی تعطیل شده‌اند. نتایج حاصله بیانگر تاثیر چشمگیر اعمال ورودی‌های مربوط به وضعیت کاری روز و ساعت می‌باشد. همانگونه که از جدول‌های ارائه شده مشخص است، خطای پیش‌بینی حدوداً به نصف حالت اولیه کاهش می‌یابد.

جدول ۴: مقایسه صحت پیش‌بینی‌های انجام شده برای چهار حالت مختلف (پنج‌شنبه ۸ تیر).

پنج‌شنبه ۸ تیر ۱۳۸۵	I	WD	WH	WD+WH
MAPE	18.2637%	13.2442%	10.1786%	9.38027%
MaxAPE	42.4885%	28.5904%	25.1275%	21.785%
MAPUE	0.0718685	0.0495743	0.040058	0.0346161
MaxAPUE	0.154546	0.120017	0.104698	0.0798784

ورودی‌های پیشنهادی (وضعیت کاری روز و ساعت) باعث بهبود نتایج حاصله می‌گردد. پیش‌بینی‌ها در چهار حالت انجام می‌شوند:

- حالت اول: بدون اعمال ورودی‌های مربوط به وضعیت کاری (I).
- حالت دوم: با اضافه کردن متغیر مربوط به وضعیت کاری روز (WD).
- حالت سوم: با اضافه کردن متغیر مربوط به وضعیت کاری ساعت (WH).
- حالت چهارم: با اضافه کردن هر دو متغیر مربوط به وضعیت کاری روز و ساعت (WD+WH).

برای پیش‌بینی بار هر روز، از اطلاعات ثبت شده طی ۳۰ روز آخر منتهی به آن روز استفاده می‌شود. هر چند که تعداد روزهای پیشنهاد شده به منظور آموزش شبکه در [۲] برابر با ۲۰ روز می‌باشد، ولی در پست مورد بررسی در این مطالعه، مشاهده می‌شود که ۳۰ روز نتایج بهتری را بدست می‌دهد. جهت بررسی صحت پیش‌بینی‌ها، از چهار شاخص ترتیب بیانگر میانگین درصد خطای مطلق، بیشینه درصد خطای مطلق، میانگین خطای مطلق پیرونی و بیشینه خطای مطلق پیرونی می‌باشند، استفاده شده است [۱-۴-۵].

روزهای کاری و روزهای تعطیل به صورت زیر انتخاب شده‌اند:

از میان روزها کاری، دو روز بطور تصادفی انتخاب می‌گردند، این دو روز عبارتند از، چهارشنبه ۲۱ تیر، و دوشنبه ۱۶ مرداد ۱۳۸۵. نتایج حاصله بیانگر اثر مثبت بکارگیری متغیرهای مربوط به وضعیت کاری روز و ساعت می‌باشد.

جدول ۲: مقایسه صحت پیش‌بینی‌های انجام شده برای چهار حالت مختلف (چهارشنبه ۲۱ تیر).

چهارشنبه ۲۱ تیر ۱۳۸۵	I	WD	WH	WD+ WD
MAPE	8.74275%	6.73177%	6.01578%	6.21144%
MaxAPE	26.6151%	16.387%	20.5303%	17.5287%
MAPUE	0.0393009	0.0315139	0.0279895	0.0286841
MaxAPUE	0.0953708	0.0587202	0.0756969	0.0742569

16- Mean of Absolute Percentage Error

17- Maximum Absolute Percentage Error


18- Mean of Absolute Per-Unit Error

19- Maximum Absolute Per-Unit Error

جدول ۵: مقایسه صحت پیش‌بینی‌های انجام شده برای چهار حالت مختلف (جمعه ۱۶ تیر).

جمعه ۱۶ تیر ۱۳۸۵	I	WD	WH	WD+WH
MAPE	19.9563%	13.104%	16.8628%	12.6365%
MaxAPE	42.7394%	28.613%	31.0957%	26.3765%
MAPUE	0.0652917	0.0450801	0.0544194	0.0413399
MaxAPUE	0.119657	0.082721	0.0910253	0.0902931

—●— target —■— I —▲— WD+WH



شکل ۵: تاثیر اعمال ورودی‌های مربوط به وضعیت کاری روز و ساعت بر بهبود نتایج حاصله. (سه‌شنبه ۱۷ مرداد ۱۳۸۵).

جدول ۶: مقایسه صحت پیش‌بینی‌های انجام شده برای چهار حالت مختلف (سه‌شنبه ۳۱ مرداد).

سه‌شنبه ۳۱ مرداد ۱۳۸۵	I	WD	WH	WD+WH
MAPE	21.3154%	12.4663%	8.30512%	7.1607%
MaxAPE	43.5387%	27.5008%	38.4629%	30.9527%
MAPUE	0.0840013	0.0487193	0.0317763	0.0274611
MaxAPUE	0.170527	0.114587	0.144236	0.116073

۵- نتیجه‌گیری

پیش‌بینی بار یکی از مهمترین مطالعات در برنامه‌ریزی و تصمیم‌گیری سیستم‌های قدرت بوده که نقش بسزایی را در امنیت و اقتصاد سیستم بازی می‌کند. در این مطالعه، با استفاده از شبکه عصبی طراحی شده به پیش‌بینی بار تابستانی پست توزیع ۶۳ kV/۲۰ kV کارون با توان نامی ۶۰ MW، متعلق به برق منطقه‌ای تهران، پرداخته شده است. ورودی‌های اولیه این شبکه، روز، ساعت، دما و سابقه بار موجود بودند.

به علت تأثیر مستقیم وضعیت کاری (تعطیل یا غیر تعطیل بودن) ساعات و روزها در شکل‌گیری پروفیل بار، پیشنهاد گردید که دو دسته متغیر ورودی، به منظور نمایش وضعیت کاری روز و ساعت، به متغیرهای پیشین شبکه اضافه

گردند. نتایج به دست آمده نشان‌دهنده تأثیر بسیار مثبت اضافه کردن دو متغیر پیشنهادی، بویژه در پیش‌بینی بار روزهای تعطیل می‌باشد. اضافه کردن این دو متغیر در پیش‌بینی بار کشورهایمانند ایران که دارای روزهای تعطیل نسبتاً زیادی در تقویم رسمی خود در طول هفته می‌باشند، بسیار سودمند باشد.

۶- مراجع

- [1]. Nahi Kandil, Rene' Wamkeue, Maarouf Saad, Semaan Georges, "An efficient approach for short term load forecasting using artificial neural networks", Electrical Power and Energy Systems 28 (2006) 525–530.
- [2]. B. Satish, K.S. Swarup, S. Srinivas, A. Hanumantha Rao, "Effect of temperature on short term load forecasting using an integrated ANN", Electric Power Systems Research 72 (2004) 95–101.
- [3]. Martin T. Hagan, Howard B. Demuth, Mark Beale, "Neural Network Design", PWS PUBLISHING COMPANY, 20 Park, Boston, Ma 02116-4324.
- [4]. Kandil N, Sood VK, Saad M, "Use of ANNs for short-term load forecasting", Canadian conference on electrical and computer engineering, CCECE'99, Mai 1999, Edmonton, Alberta, Canada.
- [5]. Paras Mandal, Tomonobu Senjyu, Naomitsu Urasaki, Toshihisa Funabashi, "A neural network based several-hour-ahead electric load forecasting using similar days approach", Electrical Power and Energy Systems 28 (2006) 367–373.
- [6]. Roy Billinton, and Ronald N Allan, "Reliability Evaluation of Engineering Systems: Concepts and Techniques", PITMAN PUBLISHING Inc., 1st published reprinted, London 1985.