

پیش‌بینی پیک بار الکتریکی روزانه با استفاده از شبکه عصبی تلفیقی

محمد رضا امین ناصری^۱، علیرضا سروش^{۲*}

^۱دانشگاه تربیت مدرس - دانشکده فنی و مهندسی - بخش مهندسی صنایع

^۲دانشگاه تربیت مدرس - دانشکده فنی و مهندسی - بخش مهندسی صنایع

*soroosha@modares.ac.ir

چکیده

اقتصاد دنیای صنعتی و رقابتی امروز بشدت متکی به انرژی الکتریکی است. همچنین کلیه شئون زندگی امروز به تولید برق وابسته است. از آنجاییکه انرژی الکتریکی قابل ذخیره‌سازی نیست و تولید بیشتر یا کمتر از حد میزان مصرف خساراتی را در پی دارد، از این جهت برنامه‌ریزی برای میزان تولید انرژی الکتریکی و بویژه پیک بار الکتریکی یکی از مهمترین عملیاتهای زمانبندی تولید برق برای روز بعد است. در این مقاله، ابتدا جهت کاهش نویز پیش‌بینی، نقشه خودسازماندهی به منظور دسته‌بندی داده‌ها براساس مشخصه‌های پیک بار مصرفی و دمای مشابه طراحی شده است و داده‌های نزدیک به یکدیگر در گروه‌های یکسان قرار داده شده‌اند. آنگاه، با بکارگیری شاخص دیویس-بولدین جهت تعیین تعداد دسته‌ها، بهترین حالت دسته‌بندی با استفاده از ۵ دسته حاصل شده است. سپس از شبکه خودسازمانده دیگری برای تقسیم‌بندی هریک از دسته‌ها براساس مشخصه پیک بار استفاده شده است. به این ترتیب ۵ دسته حاصل از شبکه خودسازمانده اول به ۱۲ دسته جهت پیش‌بینی پیک بار مصرفی تبدیل شده است. سپس جهت پیش‌بینی پیک بار، شبکه عصبی پیش‌خوراند مبتنی بر روشهای شیب مزدوج استفاده شده است. این مدل بر روی داده‌های پیک بار مصرفی شرکت برق منطقه‌ای تهران اجرا و ارزیابی شده است. نتایج پیش‌بینی نشان می‌دهد که دسته‌بندی داده‌ها موجب بهبود پیش‌بینی شده است.

واژه‌های کلیدی: پیش‌بینی - پیک بار روزانه - شبکه نقشه خودسازمانده - شبکه عصبی پیش‌خوراند - روشهای شیب مزدوج.

۱- استادیار بخش مهندسی صنایع - دانشگاه تربیت مدرس
۲- کارشناسی ارشد مهندسی صنایع - سیستم‌های اقتصادی و اجتماعی - دانشگاه تربیت مدرس

صنعت برق از صنایع زیربنائی یک کشور و رکنی بسیار مهم در رشد و پیشرفت جوامع امروزی محسوب می‌شود. بازار تقاضای جهانی برق با رشد سالانه ۲,۴ درصد، در سال ۲۰۳۰ دو برابر سال ۲۰۰۰ خواهد شد که این میزان رشد بسیار سریعتر از دیگر منابع انرژی است. سهم برق از میزان کل مصرف انرژی از ۱۸ درصد در سال ۲۰۰۰ به ۲۲ درصد در سال ۲۰۳۰ افزایش می‌یابد. رشد تقاضای برق در کشورهای در حال توسعه در بالاترین حد قرار دارد و با رشد سالانه بیش از ۴ درصد تا سال ۲۰۳۰ به سه برابر می‌رسد. در نتیجه سهم کشورهای در حال توسعه از تقاضای جهانی برق از ۲۷ درصد در سال ۲۰۰۰ به ۴۳ درصد در سال ۲۰۳۰ می‌رسد. افزایش میزان انرژی برق در دنیا اهمیت این انرژی را نیز نشان می‌دهد. از طرف دیگر با تکنولوژی موجود هنوز نمیتوان ذخیره این انرژی را در ابعاد بزرگ امکان‌پذیر نمود؛ بنابراین پیش‌بینی دقیق بار مصرفی میتواند نقش مهمی در استفاده اقتصادی از انرژی الکتریکی داشته باشد.

از سالها پیش، پیش‌بینی بار الکتریکی به دلیل نقش مهم آن برای عملیات موثر و اقتصادی استفاده از برق مورد توجه دانشگاهیان و محققان صنعتی قرار گرفته است. خطاهای پیش‌بینی بزرگ ممکن است منجر به ریسک بیش از اندازه یا زمانبندی محافظه‌کارانه بیش از حد شود که این موضوع می‌تواند جریمه‌های اقتصادی ناخواسته‌ای را در پی داشته باشد. مقادیر پیش‌بینی بالاتر نیز ممکن است، منجر به تولید مقادیر زیادی واحدهای برق شود و بنابراین ذخایر بالاتر از نیاز حقیقی تولید گردد، در صورتیکه مقادیر پیش‌بینی کمتر ممکن است به ناتوانی در ایجاد ذخایر برق قابل قبول منجر شود. در هر دو مورد هزینه عملیاتی بالاتری تحمیل میشود [۱].

هدف از پیش‌بینی بار کوتاه‌مدت، پیش‌بینی تقاضای الکتریکی آینده مبتنی بر داده‌های بار مصرفی و شرایط آب و هوایی است. ایجاد یک مدل‌سازی پیش‌بینی بار کوتاه‌مدت دقیق، سریع و قوی می‌تواند موجب برآورد دقیقتر میزان مصرف الکتریسته گردد [۲]. پیش‌بینی پیک بار الکتریکی روزانه روز بعد، کاربردی اساسی در عملیات و برنامه‌ریزی سیستم قدرت الکتریکی دارد. این پیش‌بینی، نقشی اساسی در عملیات ورود و خروج نیروگاهی و زمانبندی آن دارد [۳].

از اینرو، تکنیک‌های پیش‌بینی متنوعی در این حوزه پیشنهاد شده‌اند. برخی از محققین در مقالات از مدل‌های سری زمانی و رگرسیون خطی استفاده نموده‌اند. در این روشها رابطه بین متغیرهای مستقل و متغیر وابسته (پیش‌بینی) قابل درک است. لیکن، مدل‌سازی همبستگی پیچیده بین بار و متغیرهای ورودی همچون شرایط آب‌وهوایی و تفاوت‌های بین روزهای هفته با استفاده از این تکنیکها مشکل است.

در دو دهه گذشته، تحقیق زیادی بر روی کاربرد تکنیک‌های هوش مصنوعی^۳ (AI) برای مساله پیش‌بینی بار انجام شده اند. در میان این تکنیکها، مدل‌هایی که بیشترین توجه را به سوی خود جلب کرده اند، شبکه‌های عصبی مصنوعی^۴ (ANNs) هستند. اولین گزارشها در مورد کاربردشان در مساله پیش‌بینی بار در اواخر دهه ۱۹۸۰ و اوایل دهه ۱۹۹۰ منتشر شده بود. تکنیک شبکه عصبی بخاطر قابلیت خوب آن در مدل‌سازی غیرخطی به شکل گسترده‌ای در پیش‌بینی بار برق بکاربرده شده است [۴].

در اکثر مقالات به چاپ رسیده، شیوه تفکیک داده‌های پیک‌بار هر سال از پیش تعیین شده بوده است، بدین صورت که بدون ارائه دلیلی مستدل ایام سال به چند دسته تقسیم شده است و سپس پیش‌بینی برای هر دسته انجام شده است. این مقاله مدل شبکه عصبی تلفیقی را ارائه می‌کند که دو شبکه نقشه خودسازمانده^۵ (SOM) پیاپی را برای دسته‌بندی ایام سال استفاده می‌کند و سپس پیش‌بینی پیک‌بار روز بعد توسط شبکه عصبی پیش‌خوراند^۶ مبتنی بر روشهای شیب مزدوج^۷ انجام میشود. همچنین، این پیش‌بینی با استفاده از شبکه عصبی پیش‌خوراند بدون انجام دسته‌بندی نیز صورت می‌گیرد و نتایج حاصل با یکدیگر مقایسه می‌شوند.

در بخشهای بعدی ابتدا به طور خلاصه به مرور کارهای انجام شده در این زمینه خواهیم پرداخت. سپس شبکه‌های عصبی نقشه خودسازمانده و نحوه بکارگیری آن را شرح خواهیم داد. در ادامه با استفاده از شبکه عصبی پیش‌خوراند مبتنی بر روشهای شیب مزدوج به پیش‌بینی مصرف پیک‌بار روزانه می‌پردازیم؛ همچنین پیش‌بینی را بدون استفاده از نقشه خودسازمانده انجام خواهیم داد و در انتها با مقایسه نتایج بدست‌آمده، نتیجه‌گیری خواهیم نمود.

³ Artificial Intelligence

⁴ Artificial Neural Networks

⁵ Self-Organized Mapping

⁶ Feedforward

⁷ Conjugate Gradient

۲- مروری بر ادبیات موضوع

همانطور که پیش از این اشاره شد، برای پیش‌بینی پیک بارروانه روشهای مختلفی توسط محققین بکارگرفته شده است. برخی از محققین از روشهای سری زمانی و رگرسیون خطی یا روشهای تلفیقی آنها با سیستم خبره استفاده نموده‌اند. امجدی از یک مدل سری زمانی استفاده کرده است که تجربیات اپراتور خبره را نیز بعنوان یکی از پارامترهای مدل در نظر می‌گیرد. دو مدل سری زمانی برای پیش‌بینی بارهای ساعتی و پیک بارروزهای هفته و تعطیلات آخرفته و عمومی استفاده می‌گردد. از هشت مدل برای بارهای پیک شنبه‌ها، یکشنبه‌ها تا چهارشنبه‌ها، پنجشنبه‌ها و جمعه‌ها بعلاوه تعطیلات عمومی در دو دسته سرد و گرم استفاده می‌شود. درضمن، ایشان بیان میکنند که اکثر رویکردهای پیش‌بینی بار متداول هیچ راه‌حلی برای پیش‌بینی پیک بارروانه ارائه نمیکنند [۵].

صادقپور و امین‌ناصری از ترکیب سیستم خبره با رگرسیون خطی چندمتغیره برای پیش‌بینی پیک بار استفاده نموده است. ۱۶ فرمول رگرسیونی برای هر فصل ۴ فرمول براساس تقسیم بندی روزهای هفته بصورت جداگانه در نظر گرفته شده است. برای پیش‌بینی روزهای تعطیلی خاص نیز برحسب عزا یا جشن، ضریبی خاص در نظر گرفته شده است [۶].

صیاد از روشی هوشمند برای پیش‌بینی بار روز بعد استفاده نمودند. مدلی با استفاده از روش رگرسیون چندمتغیره خطی طراحی نمودند. برای تشخیص موارد خاص همچون روزهای تعطیل از سیستم خبره استفاده شده است [۷].

برخی دیگر، از شبکه نقشه خودسازمانده و تلفیق آن با شبکه پرسپترون برای پیش‌بینی استفاده کرده‌اند. مقدس تفرشی و یاریان با استفاده از ترکیب شبکه های عصبی کوهون و پرسپترون به پیش‌بینی بار کوتاه‌مدت پرداخته است. همچنین، برای پیش‌بینی بار روزهای سال از ۹ مدل جداگانه استفاده می‌کند. ۷ مدل برای پیش‌بینی بار هر روز هفته، یک مدل برای پیش‌بینی روزهای تعطیل و یک مدل برای پیش‌بینی روزهای بعداز تعطیل در نظر گرفته شده است [۸].

کارپینتیرو و همکارانش یک مدل عصبی مصنوعی متشکل از دو شبکه نقشه خودسازمانده، یکی بالای دیگری ایجاد نمودند. آن شبکه‌ها، اطلاعات متن را به صورت کارا رمزی و هدایت می‌کنند. مدل برای پیش‌بینی هر ساعت یکبار بارالکتريکی در طول ۲۴ ساعت بعد آموزش داده و ارزیابی شده بود [۹]، [۱۰]، [۱۱].

برخی دیگر نیز با شناسایی روزهای وابسته به روز موردنظر یا با بررسی عوامل تاثیرگذار دیگر بر مصرف بار به گونه‌ای دیگر از شبکه عصبی برای پیش‌بینی استفاده نمودند. هوانگ و همکارانش یک شبکه عصبی غیرثابت برای پیش‌بینی پیک بار استفاده کردند. به منظور پیش‌بینی دقیقتر چندین تکنیک شامل، آنالیز گری^۸، قاعده یادگیری پس انتشار تصادفی با نرخ یادگیری پویا و مومنتوم استفاده می‌شود. پنج شبکه پیک بار تا پنج روز بعد را محاسبه می‌کنند [۳].

ایزاکا و همکارانش یک شبکه عصبی ساختار یافته قابل آنالیز ارائه نموده‌اند که می‌تواند دانایی مناسب را استخراج کند و دلایل نتایج پیش‌بینی را با همبستگی مستقل بین متغیرهای ورودی و پیک بار توضیح می‌دهد. در این تحقیق، در بهار تنها همبستگی مثبت بین پیک‌بار هدف و پیک‌بار قبلی دیده می‌شود و در تابستان تنها همبستگی مثبت بین پیک‌بار هدف و دما مشاهده می‌شود [۱۲].

ساینی و همکارش در مقاله‌ای برای پیش‌بینی پیک بارروانه از شبکه عصبی پیشخوراند همراه با چهار الگوریتم آموزشی پس انتشار شیب مزدوج و الگوریتم سربعترین نزول^۹ استفاده نموده‌اند. در مقاله دیگری برای پیش‌بینی پیک بارروانه از شبکه عصبی پیشخوراند با الگوریتمهای لونبرگ-مارکوآرت^{۱۰} و شبه‌نیوتنی بریدن-فلچر-گلدفار-شانو^{۱۱} و تقاطع یک مرحله‌ای^{۱۲} استفاده نموده‌اند. آنها در این مقالات علاوه بر بار، فاکتورهای آب و هوایی مینیوم و ماکزیمم دمای هوا، رطوبت نسبی، سرعت باد، ساعات آفتابی، پوشش ابر، میزان بارش، فشار بخار آب، دمای خاک در عمق ۵، ۱۰ و ۲۰ سانتیمتر در نظر گرفتند. پیش‌بینی برای یک هفته در هر فصل محاسبه شده است. آنها روزهای هفته را به چهار دسته روزهای کاری، روزتعطیل، روزشنبه، روز یکشنبه تقسیم نمودند [۱۳]، [۱۴].

آقای سو و چن از یک مدل شبکه عصبی مصنوعی برای پیش‌بینی پیک بار ناحیه‌ای از تایوان استفاده کردند و با تقسیم این ناحیه به چهار بخش بر خصوصی‌سازی بازار برق تاکید نمودند [۱۵].

⁸ Gray

⁹ Steepest Descent


¹⁰ Levenberg-Marquardt

¹¹ Broyden-Fletcher-Goldfarb-Shanno

¹² One Step Secant

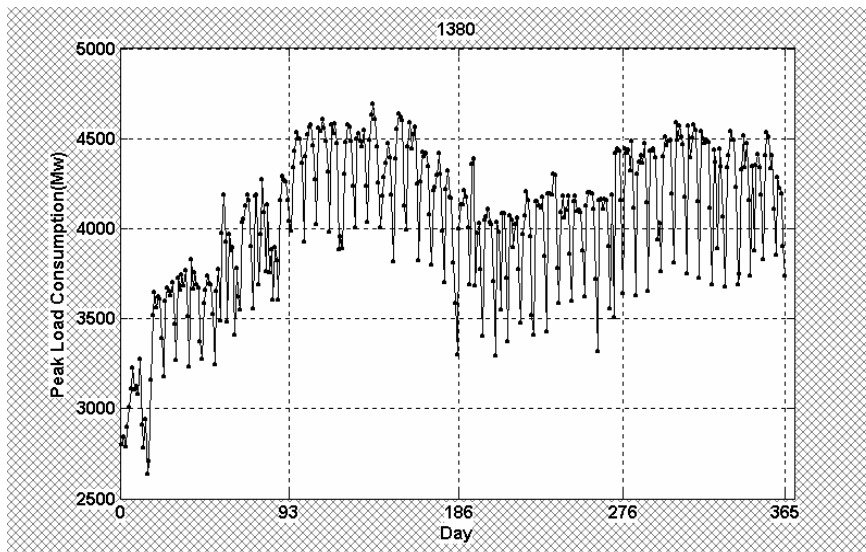
۳- تحلیل داده‌ها

در این تحقیق از داده‌های مصرف پیک‌بار روزانه چهار سال برق منطقه‌ای تهران که معادل ۱۴۶۱ روز است، برای انجام پیش‌بینی پیک بار روزانه استفاده می‌شود. ساعت پیک‌بار این منطقه در نیمه اول سال بین ساعات ۱۹ الی ۲۳ و در نیمه دوم سال بین ساعات ۱۸ الی ۲۲ می‌باشد. همچنین، براساس همین بازه زمانی اطلاعات مربوط به دمای هوا در زمان وقوع پیک‌بار از سازمان هواشناسی تهران تهیه شده است. شکل (۱) روند سری زمانی مصرف روزانه پیک‌بار منطقه در طی چهار سال را نمایش می‌دهد.



شکل ۱- سری زمانی داده‌های مصرف پیک بار روزانه

همانطور که در شکل (۱) مشاهده می‌شود مصرف بار روندی روبه افزایش در هر سال نسبت به همان مقطع زمانی در سال قبل را نمایش می‌دهد. این مساله نشان‌دهنده آن است که امکان دسته‌بندی همزمان داده‌های تمامی سالها وجود ندارد، زیرا ممکن است داده‌های بهار سال ۱۳۸۱ با داده‌های زمستان سال ۱۳۷۸ در یک گروه بعنوان داده‌های مشابه قرار گیرد که این مساله منطقی بنظر نمی‌رسد، زیرا الگوی مشابهی در تمامی سالها دیده نمی‌شود و این چنین دسته‌بندی قابل تعمیم به سالهای بعد نمی‌باشد. به همین دلیل باید دسته‌بندی هر یک از سالها به صورت جداگانه انجام شود و سپس اشتراکات میان دسته‌بندیهای چهارسال شناسایی گردد. پس از تحلیل روند تغییرات مصرف بار در طول چهار سال به بررسی روند مصرف بار در طول یک سال می‌پردازیم. شکل (۲) روند مصرف پیک‌بار هر فصل در طول سال ۱۳۸۰ را نمایش می‌دهد.



شکل ۲- روند مصرف پیک‌بار هر فصل در طول سال ۱۳۸۰

همانطور که در شکل (۲) مشاهده می‌شود متوسط مصرف پیک‌بار در فصل بهار کمتر از سایر فصول بوده و پس از آن فصل پاییز دارای متوسط مصرف پیک‌بار کمتری است؛ فصول تابستان و زمستان نیز با میانگین مصرفی بالاتر از دوفصل دیگر تقریباً مقدار مصرف یکسانی دارند، هرچند در تابستان تاحدی متوسط مصرف پیک‌بار بیشتر است. همچنین در هر ۱۲ ماه سال نوسانات زیادی در روند مصرف پیک‌بار مشاهده می‌شود. این شیوه تحلیل صرفاً نوعی بررسی دیداری است و می‌تواند دارای خطا باشد، بنابراین لزوم استفاده از ابزاری برای شناسایی و طبقه‌بندی دقیقتر این الگوهای مصرف در دسته‌های یکسان بیشتر نمایان می‌گردد، زیرا طبقه‌بندی داده‌ها موجب می‌شود با نقاط دورافتاده و نویزهای کمتری در پیش‌بینی مصرف پیک بار مواجه شویم.

۳-۱- تاثیر دمای هوا بر الگوی مصرف بار

یکی از مهمترین عوامل موثر بر الگوی مصرف میزان درجه حرارت می‌باشد. بارهای خانگی و تجاری در ماههای گرم سال بدلیل استفاده از وسایل سردکننده مانند کولر و فن، ... و در ماههای سرد سال بدلیل استفاده از وسایل گرم کننده الکتریکی تحت تاثیر درجه حرارت می‌باشند.

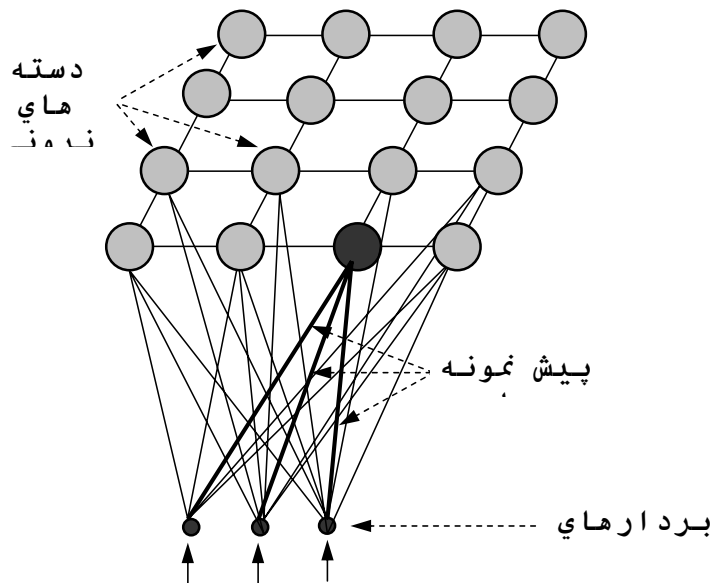
همانطور که در شکل (۲) نشان داده شد، میزان مصرف بار در ایام گرم و سرد تقریباً دارای مقدار یکسانی است و تنها استفاده از مصرف پیک‌بار برای دسته‌بندی ایام سال نمی‌تواند ایام گرم و سرد را از هم تفکیک نماید و در نتیجه احتمال ایجاد نویز در زمان پیش‌بینی افزایش می‌نماید. به این دلیل می‌توان از پارامتر دما جهت تفکیک مصرف بار ایام گرم و سرد استفاده نمود. رابطه میان مصرف پیک‌بار و دمای هوا در هر سال تقریباً دارای شکل مشابهی است. به همین دلیل، استفاده از این عامل می‌تواند در دستیابی به الگویی مشخص جهت دسته‌بندی ایام سال تاثیرگذار باشد.

۴- دسته‌بندی با استفاده از شبکه عصبی نقشه خودسازمانده

در اکثر تحقیقات انجام شده در زمینه پیش‌بینی بار کوتاه‌مدت وضعیت دسته‌بندی داده‌ها پیش از انجام پیش‌بینی بدون ارائه دلیل قابل قبولی از پیش تعیین شده است [۳]، [۷-۵]، [۱۵-۱۲]. لیکن، استفاده از دسته‌بندی مناسب می‌تواند منجر به کاهش نویز در حین انجام پیش‌بینی شود. الگوریتم نقشه خودسازمانده ابزار بسیار خوبی جهت دسته‌بندی داده‌ها می‌باشد.

الگوریتم نقشه خودسازمانده (SOM) در سالهای اخیر کاربردهای فراوانی را در زمینه‌های علوم مهندسی تا پزشکی، بیولوژی و اقتصاد در میان محققان پیدا کرده است. تنها ۲۰۹۲ مقاله علمی در طی سالهای ۱۹۹۸ الی ۲۰۰۲ ارائه شده است که به نوعی از این الگوریتم استفاده نموده‌اند [۱۶].

دسته‌بندی Q ، به معنای افراز مجموعه‌ای از داده‌ها به مجموعه‌ای از دسته‌های Q_i ، $i = 1, \dots, C$ است. یک تعریف قابل قبول از دسته‌بندی بهینه افرازی است که فواصل بین نمونه‌های داخلی را حداقل کند و فواصل بین دسته‌ها را حداکثر کند. معمولاً SOM متشکل از قاعده‌ای دوبعدی، شبکه‌ای از واحدهای نقشه است. هر واحد i توسط یک بردار پیش‌نمونه $m_i = [m_{i1}, \dots, m_{id}]$ نمایش داده می‌شود که d بعد بردار ورودی است. واحدها توسط یک رابطه همسایگی به مجاورت آنها متصل می‌شوند. تعداد واحدهای نقشه که معمولاً از چند تا چندین هزار تغییر می‌کند، دقت و قابلیت تعمیم SOM را تعیین می‌کند. در طول آموزش، SOM یک شبکه فیزیکی تشکیل می‌دهد که توده/نبوه تشکیل شده از داده‌های ورودی را درهم می‌آمیزد. نقاط داده‌ای واقع شده نزدیک یکدیگر در فضای ورودی، به صورت واحدهای نقشه نزدیک به هم ترسیم می‌شوند. بنابراین SOM می‌تواند همچون یک نقشه توپولوژی از فضای ورودی به شبکه دو بعدی واحدهای نقشه تعبیر شود. شبکه دو بعدی امکان نمایش و تفسیر شکل بی‌نظم و ترتیب دسته‌بندیها را می‌دهد شکل (۳) یک شبکه عصبی نقشه خودسازمانده را نمایش می‌دهد.



شکل ۳- شبکه عصبی نقشه خودسازمانده

SOM به صورت تکراری آموزش داده می‌شود. در هر مرحله آموزش، یک بردار نمونه x به صورت تصادفی از مجموعه داده‌های ورودی انتخاب می‌شود. فواصل بین x و همه بردارهای پیش‌نمونه محاسبه می‌شوند. بهترین میزان تطبیق^{۱۳} (BMU)، که اینجا توسط b مشخص می‌شود، توسط رابطه (۱) محاسبه می‌شود:

$$\|x - m_b\| = \min\{\|x - m_i\|\} \quad (1)$$

سپس بردارهای پیش‌نمونه به‌روز می‌شوند. BMU و همسایه‌های توپولوژیکی آن به نزدیکی بردار ورودی در فضای ورودی حرکت داده می‌شوند.

به دلیل اینکه تعداد دسته‌ها نامعلوم است، می‌توان الگوریتم SOM برای مجموعه‌ای از تعداد دسته‌های مختلف، از ۲ تا \sqrt{N} تکرار شود، که N تعداد نمونه‌ها در مجموعه داده‌هاست. الگوریتم SOM مورد استفاده در زمان اجرا تابع خطای رابطه (۲) را مینیمم می‌کند:

$$E = \sum_{k=1}^C \sum_{x \in Q_k} \|x - c_k\|^2 \quad (2)$$

که C تعداد دسته‌هاست، و c_k مرکز دسته k است.

در این مقاله، برای انتخاب بهترین دسته‌بندی از میان تقسیم‌بندی‌های مختلف از شاخص دیویس-بولدین^{۱۴} استفاده می‌گردد، که S_c را برای فاصله درون دسته‌ای و d_{ce} برای فاصله بین دسته‌های استفاده می‌کند. براساس شاخص اعتبارسنجی دیویس-بولدین، بهترین دسته‌بندی رابطه (۳) را مینیمم می‌کند:

$$\frac{1}{C} \sum_{k=1}^C \max_{l \neq k} \left\{ \frac{S_c(Q_k) + S_c(Q_l)}{d_{ce}(Q_k, Q_l)} \right\} \quad (3)$$

که C تعداد دسته‌ها است. این شاخص هم فاصله درون دسته‌ای و هم فاصله بین دسته‌ای را هنگام ارزیابی دسته‌بندی حاصل شده مورد ارزیابی قرار می‌دهد و شاخص مناسبی برای سنجش تقسیم‌بندی نقشه خودسازمانده است، زیرا هر قدر مقادیر کمتر باشد، نشان‌دهنده نتایج دسته‌بندی خوبی برای دسته‌های گروهی^{۱۵} است [۱۷].

¹³ Best Matching Unit

¹⁴ Davies-Bouldin Index

¹⁵ Spherical Clusters

۴-۱- تعیین محدوده ورودیها و نرمالسازی آنها

همانطور که پیش از این نشان داده شد، مینیمم و ماکزیمم مصرف بار در هر سال نسبت به سال قبل در حال افزایش است. به همین دلیل باید داده‌های هر سال را به صورت جداگانه با استفاده از نقشه خودسازمانده دسته‌بندی نمود. زیرا میزان مصرف بار در یک روز از سال نسبت به سال قبل خود بیشتر است، این موجب می‌شود که در هنگام دسته‌بندی یک روز مشابه در دو سال متفاوت در دسته‌های مختلفی قرار گیرند، به همین منظور هر سال بصورت مجزا برای دسته‌بندی روزهای سال آموزش داده می‌شود و اشتراک بین سالها کشف می‌گردد. این امر موجب می‌شود که اطمینان ما به ثبات دسته‌بندی حاصل شده افزایش یابد و از امکان تعمیم آن برای سالهای آتی مطمئن شویم. همچنین، پس از تعیین محدوده ورودیها مشخص می‌گردد که پیک بار نسبت به دمای هوا دارای مقادیر بزرگتری است، این مساله باعث می‌گردد که در زمان دسته‌بندی فاکتور دما تاثیر چندانی در تقسیم‌بندی نداشته باشد و دسته‌بندی تنها براساس مصرف پیک‌بار انجام شود. برای رفع این مشکل، ورودیها را باید نرمالسازی نمود. به این منظور، از نرمالسازی استاندارد با میانگین صفر و واریانس یک استفاده می‌شود.

۴-۲- آموزش SOM

SOM با استفاده از الگوریتم آموزش افزایشی تصادفی^{۱۶} برای تقسیم بندی مجموعه داده‌های هر سال آموزش داده شده است. در این الگوریتم در هر دوره آموزشی، همه بردارهای آموزشی (یا توالی ها) هرکدام یکبار بصورت تصادفی به شبکه ارائه میشوند و مقادیر وزنی و بایاس بعد از ارائه هر بردار بروز می‌شوند. آموزش زمانی متوقف می‌شود که یکی از شرایط ذیل محقق شود: ماکزیمم تعداد دوره‌های آموزشی، دستیابی به حداقل خطا، رسیدن به ماکزیمم مقدار زمان. نقشه‌ها در دوفاز ترتیب و تنظیم آموزش داده شده‌اند: آموزش دوفاز با تعداد دوره‌های آموزشی ۱۰۰۰ و ۲۰۰۰ آزمایش شده‌اند و نرخهای یادگیری اولیه برای فاز ترتیب ۰.۹ و برای فاز تنظیم ۰.۰۲ در نظر گرفته شده‌اند. نرخ یادگیری به صورت خطی در طول آموزش با میل به سمت صفر کاهش پیدا می‌کند. تعداد مراحل در فاز ترتیب ۱۰۰۰ مرحله طول می‌کشد و فاصله همسایگی در فاز تنظیم در فاصله نزدیک یک باقی می‌ماند.

۴-۳- تعیین محدوده تعداد دسته‌ها، نوع توپولوژی و نرم فاصله

در ادبیات موضوع رابطه‌ای برای تعیین حداکثر تعداد دسته‌ها جهت تقسیم‌بندی وجود ندارد و همانطور که اشاره گردید میتوان از \sqrt{N} الی \sqrt{N} دسته را مورد بررسی قرار داد. حداکثر تعداد دسته‌ها از جذر ۳۶۵ روز هر سال که بردارهای ورودی ما را تشکیل می‌دهند، برابر ۱۹.۱ می‌شود. بنابراین باید دسته‌بندی بردارهای مصرف پیک‌بار روزانه حداکثر برای ۱۹ دسته آزمایش شود تا بهترین تقسیم‌بندی حاصل گردد. لیکن، در این تحقیق دسته‌بندی را با دو دسته آغاز کرده و تا ۱۲ دسته ادامه می‌دهیم. زیرا مشاهده می‌کنیم که با افزایش تعداد دسته‌ها بهبودی در دسته‌بندی و مقدار شاخص دیویس- بولدین دیده نمی‌شود. همچنین، با افزایش تعداد دسته‌ها بر پیچیدگی مساله افزوده می‌شود. بنابراین باید تعداد دسته‌ای را انتخاب کرد که علاوه بر تامین هدف کاهش نویز، میزان پیچیدگی مساله نیز حداقل گردد. تقسیم‌بندی بردارهای ورودی می‌تواند توپولوژیهای مختلفی را داشته باشند. به همین دلیل دسته‌بندی بردارها با هر تعداد دسته با توپولوژیهای مختلف مورد آزمایش قرار می‌گیرند. توپولوژیهایی که در این مساله مورد آزمایش قرار می‌گیرند عبارتند از: (۱ ۲)، (۱ ۳)، (۲ ۲)، (۱ ۴)، (۱ ۵)، (۲ ۳)، (۱ ۶)، (۱ ۷)، (۱ ۸)، (۲ ۴)، (۱ ۹)، (۳ ۳)، (۱ ۱۰)، (۲ ۵)، (۱ ۱۱)، (۱ ۱۲)، (۲ ۶). همچنین، برای سنجش فواصل درون دسته‌ای و بین دسته‌ای از نرم فاصله اقلیدسی استفاده می‌گردد.

¹⁶ Random Order Incremental Training

۴-۴ - نتایج محاسبات و خروجی دسته‌بندی

مساله با توپولوژیهای مختلف بیان شده برای دسته‌بندی اجرا می‌شود؛ پس از آن، بهترین دسته‌بندی برای ۱۷ حالت، ۳ و ۲ و ۱۱ و ۱۲ نرون با توپولوژیهای مختلف بوسیله حداقل‌سازی تابع خطا انتخاب می‌شود. سپس، جهت‌گزینش بهترین تقسیم‌بندی از میان دسته‌بندی‌های مختلف، شاخص اعتبارسنجی دیویس-بولدین با استفاده از نرم فاصله اقلیدسی محاسبه می‌گردد. بدین منظور، ابتدا فاصله اقلیدسی بین مراکز حاصل شده برای هر یک از دسته‌ها محاسبه می‌گردد. سپس، میانگین فاصله اقلیدسی هر یک از نمونه‌ها در هر دسته از مرکز آن دسته تعیین می‌شود، پس از آن ماکزیمم مقدار مجموع میانگین هر دسته با سایر دسته‌ها تقسیم بر فاصله مراکز آن دو دسته محاسبه می‌گردد، با محاسبه میانگین این مقادیر ماکزیمم، شاخص اعتبارسنجی دیویس-بولدین برای هر تعداد دسته محاسبه می‌گردد. جدول (۱) مقادیر شاخص دیویس-بولدین برای توپولوژیهای مختلف را ارائه می‌کند.

جدول ۱- مقادیر شاخص دیویس-بولدین برای توپولوژیهای مختلف

۸	۷	۶	۶	۵	۴	۴	۳	۲	تعداد دسته
(۱۸)	(۱۷)	(۱۶)	(۲۳)	(۱۵)	(۱۴)	(۲۲)	(۱۳)	(۱۲)	نوع توپولوژی
۱,۸۴۶	۱,۵۲۷	۱,۵۵۶	۱,۳۱۱	۱,۲۵۷	۱,۸۵۳	۳,۹۳۷	۲,۲۸۵	۳,۸۷۶	مقدار شاخص دیویس-بولدین
	۱۲	۱۲	۱۱	۱۰	۱۰	۹	۹	۸	تعداد دسته
	(۲۶)	(۱۱۲)	(۱۱۱)	(۲۵)	(۱۱۰)	(۳۳)	(۱۹)	(۲۴)	نوع توپولوژی
	۲,۳۸۶	۱,۳۵۴	۱,۳۹۹	۲,۶۴۴	۱,۴۳۸	۱,۴۶۳	۱,۶۰۳	۲,۰۷۷	مقدار شاخص دیویس-بولدین

طبقه‌بندی بردارهای ورودی به دو دسته، شاخص ۳,۸۷۶ حاصل می‌سازد، با افزایش تعداد دسته‌ها میزان شاخص تا ۱,۲۵۷ کاهش می‌یابد که این مقدار با تقسیم بندی به پنج دسته یا نرون بدست می‌آید؛ در ادامه با افزایش نرون‌ها بهبودی در نتیجه حاصل نمی‌شود. همچنین با افزایش تعداد دسته‌ها پیچیدگی مساله افزایش می‌یابد و الگوی خاصی در دسته‌بندی مشاهده نمی‌شود. بنابراین تقسیم‌بندی بردارهای ورودی به ۵ دسته که نمایانگر روزهای سال می‌باشند، بهترین و مناسبترین حالت خواهد بود، زیرا مینیمم مقدار شاخص دیویس-بولدین در این وضعیت بدست آورده می‌شود و پیچیدگی مساله نیز کم است.

به این ترتیب، بهترین دسته‌بندی برای تفکیک هفته‌های یکسال با توجه به شرایط آب و هوایی مشابه هر مقطع از سال براساس دو عامل دمای هوا و مصرف پیک بار حاصل می‌گردد. لیکن، برای تفکیک ایامی از سال که دارای دمای هوای تقریباً مشابه و اختلاف پیک بار محسوسی هستند، نیاز به استفاده از شبکه نقشه خودسازمانده دیگری است تا هر یک از پنج نرون حاصل از نقشه خودسازمانده اولیه را براساس عامل مصرف پیک بار تقسیم‌بندی بنماید. به این ترتیب، علاوه بر کاهش نویز حاصل از اختلاف دمای هوا، نویز حاصل از اختلاف پیک بار نیز کاهش می‌یابد. به این ترتیب که نرون یک به دو دسته، نرون دو به سه دسته، نرون سه به چهار، نرون چهار به همان یک دسته و نرون پنج به دو دسته تقسیم می‌گردد. پس از انجام دسته‌بندی هر یک از نرون‌ها، ۱۲ دسته برای انجام پیش‌بینی حاصل می‌گردد. خروجی و نتیجه دسته‌بندی نهایی ایام سال به صورت زیر است:

نرون ۱: دسته سوم شنبه‌ها تا چهارشنبه‌ها (هفته آخر خرداد، تیر، مرداد، شهریور، هفته اول مهر)، دسته سوم پنجشنبه‌ها (تیر، مرداد، سه هفته اول شهریور)

نرون ۲: دسته دوم شنبه‌ها تا چهارشنبه‌ها (هفته آخر اردیبهشت، سه هفته اول خرداد، سه هفته آخر مهر، دوهفته اول آبان)، دسته دوم پنجشنبه‌ها (خرداد، هفته آخر شهریور، هفته اول مهر)، دسته دوم جمعه‌ها و ایام تعطیل (سه هفته آخر خرداد، تیر، مرداد، شهریور، هفته اول مهر)

نرون ۳: ایام عید، دسته اول شنبه‌ها تا چهارشنبه‌ها (فروردین، سه هفته اول اردیبهشت)، دسته اول پنجشنبه‌ها (فروردین، اردیبهشت، سه هفته آخر مهر، دوهفته اول آبان)، دسته اول جمعه‌ها و ایام تعطیل (فروردین، اردیبهشت، هفته اول خرداد، سه هفته آخر مهر، دوهفته اول آبان، هفته آخر اسفند)

نرون ۴: دسته سوم جمعه‌ها و ایام تعطیل (دوهفته آخر آبان، آذر، دی، بهمن، سه هفته اول اسفند)

نرون ۵: دسته چهارم شنبه‌ها تا چهارشنبه‌ها (دوهفته آخر آبان، آذر، دی، بهمن، اسفند)، دسته چهارم پنجشنبه‌ها (دوهفته آخر آبان، آذر، دی، بهمن، اسفند)

۵- پیش‌بینی با استفاده از شبکه عصبی پیشخوراند

پس از انجام دسته‌بندی، در این مرحله به پیش‌بینی پیک‌بار روز بعد خواهیم پرداخت. پیش‌بینی با استفاده از شبکه عصبی پیشخوراند صورت می‌گیرد. بدین ترتیب که داده‌های سه سال برای آموزش مدل و داده‌های یک سال جهت پیش‌بینی و اعتبارسنجی مدل مورد استفاده قرار می‌گیرد.

یک شبکه عصبی می‌تواند توسط یادگیری الگوهای داده، نظیر $(X_1, X_2, \dots, X_n, Y)$ آموزش داده شود. در اینجا X_1, X_2, \dots, X_n ورودیهای شبکه و Y خروجی آن است. فرض ما برای آموزش این است که Y به X_1 تا X_n وابسته است. در صورتیکه الگوهای داده به اندازه کافی در دسترس باشد، یک مدل شبکه عصبی می‌تواند توسعه داده شود که ارتباط بین ورودیهای X_1 تا X_n با خروجی Y را بیان کند. بنابراین، این مدل می‌تواند بعنوان ابزاری برای پیش‌بینی Y براساس ورودیهای X_1 تا X_n مورد استفاده قرار گیرد. این کار، با آموزش مدل امکانپذیر است. در فرایند آموزش باید عملکرد شبکه با معیار مناسبی سنجیده شود. در ادامه به معرفی مشخصات مدل می‌پردازیم.

۵-۱- داده‌های ورودی

عوامل تاثیرگذار بر مصرف پیک‌بار در حالت‌های مختلف یک وقفه^{۱۷} و دو وقفه در دسته‌های پنجشنبه‌ها، جمعه‌ها و ایام تعطیل و شنبه‌ها تا چهارشنبه‌ها مورد بررسی و آزمایش قرار گرفتند. در نهایت بهترین نتایج در هردسته با داده‌های ورودی زیر بدست آمده‌اند:

دسته ایام عید: روز ماه، شماره سال، دمای هوای همان روز، پیک‌بار و دمای هوای روز مشابه قبلی.

دسته اول جمعه‌ها و ایام تعطیل: شماره ماه، شماره سال، دمای هوا همان روز، پیک‌بار و دمای هوای هفته قبل.

دسته دوم جمعه‌ها و ایام تعطیل: شماره ماه، شماره سال، دمای هوای همان روز، پیک‌بار و دمای هوای هفته قبل.

دسته سوم جمعه‌ها و ایام تعطیل: شماره ماه، شماره سال، دمای هوای همان روز، پیک‌بار و دمای هوای هفته قبل.

دسته اول پنجشنبه‌ها: شماره ماه، شماره سال، دمای هوای همان روز، پیک‌بار و دمای هوای هفته قبل و دوهفته قبل.

دسته دوم پنجشنبه‌ها: شماره ماه، شماره سال، دمای هوای همان روز، پیک‌بار و دمای هوای هفته قبل.

دسته سوم پنجشنبه‌ها: شماره ماه، شماره سال، دمای هوای همان روز، پیک‌بار و دمای هوای هفته قبل و دو هفته قبل.

دسته چهارم پنجشنبه‌ها: شماره ماه، شماره سال، دمای هوای همان روز، پیک‌بار و دمای هوای هفته قبل.

دسته اول شنبه‌ها تا چهارشنبه‌ها: شماره ماه، شماره سال، دمای هوای همان روز، پیک‌بار و دمای هوای روز قبل و هفته قبل.

دسته دوم شنبه‌ها تا چهارشنبه‌ها: شماره ماه، شماره سال، دمای هوای همان روز، پیک‌بار و دمای هوای روز قبل و هفته قبل.

دسته سوم شنبه‌ها تا چهارشنبه‌ها: شماره ماه، شماره سال، دمای هوای همان روز، پیک‌بار و دمای هوای روز قبل و هفته قبل.

دسته چهارم شنبه‌ها تا چهارشنبه‌ها: شماره ماه، شماره سال، دمای هوای همان روز، پیک‌بار و دمای هوای روز قبل و هفته قبل.

¹⁷ Lag

۵-۲- پیش‌پردازش داده‌ها

اگر مراحل پیش‌پردازش معینی بر روی ورودیها و هدفهای شبکه انجام شود، آموزش شبکه عصبی می‌تواند کارا تر انجام شود. از اینرو، پیش از آموزش هم مقیاس‌سازی ورودیها و هدفها انجام میشود. پیش‌پردازش داده‌ها سبب می‌شود داده‌ها در دامنه معینی فشرده شوند. زمانیکه از توابع سیگموئید برای لایه‌های پنهان شبکه استفاده می‌شود، این فشرده‌سازی می‌تواند نتایج شبکه را بهبود بخشد. سپس داده‌های نرمال شده مورد آنالیز مولفه اصلی^{۱۸} (PCA) قرار می‌گیرند. از آنالیز مولفه اصلی جهت کاهش ابعاد بردارهای ورودی و کاهش پیچیدگی مساله در هریک از دسته‌ها و حذف عواملی که تاثیرگذاری کمتری بر روی متغیر خروجی دارند، استفاده میکنیم. این آنالیز زمان آموزش کمتر، معماری ساده‌تر، آموزش با داده‌های مشابه و پیش‌بینی بهتر را در پی خواهد داشت.

۵-۳- وضعیت تعداد لایه‌ها، توابع تبدیل و تعداد نرونها

توابع تبدیل گوناگونی برای استفاده در لایه‌های مختلف یک شبکه وجود دارد. با توجه به نوع مساله و کاربرد مورد نظر هریک از توابع در جایی مورد استفاده قرار می‌گیرند. استفاده از توابع تبدیل سیگموئید و تانژانت هیپربولیک در لایه پنهان، سبب تثبیت خروجی نرونهای این لایه در بین محدوده‌های معین $[0, 1]$ و $[-1, 1]$ می‌شود و در نتیجه با جلوگیری از تولید مقادیر بسیار بزرگ که باعث از کار افتادن شبکه می‌شود، از شکست فرایند آموزش جلوگیری خواهد شد.

در این تحقیق از شبکه‌ای دو لایه استفاده می‌شود که شامل یک لایه مخفی می‌باشد، تعداد نرونها در لایه مخفی بسته به تعداد متغیرهای ورودی و تعداد الگوهای آموزشی از ۱ تا ۵۰ گره در نظر گرفته شده است. در لایه خروجی نیز یک نرون وجود دارد که پیش‌بینی پیک بار روز بعد را با توجه به ورودیهای مورد نیاز هر دسته به ما ارائه می‌کند. همچنین، در لایه مخفی به دلیل مثبت بودن خروجیها از تابع تبدیل لجستیک سیگموئید استفاده می‌گردد و به سبب نبود محدودیت در مقدار خروجیها از تابع تبدیل خطی در لایه خروجی استفاده می‌شود.

۵-۴- الگوریتمهای آموزش شبکه

قاعده یادگیری در شبکه عصبی، جهت یاد دادن کاری خاص به شبکه استفاده می‌شود. برای این کار از رویه‌ای که وزن‌ها و بایاسهای شبکه را اصلاح می‌نماید استفاده می‌شود که الگوریتم آموزش نامیده می‌شود. در این تحقیق الگوریتمهای شیب مزدوج (CG) شامل شیب مزدوج فلچر-ریوز (CGF)، شیب مزدوج پولاک-ریبر (CGP)، شیب مزدوج پاول-بیل (CGB)، شیب مزدوج مقیاس‌بندی شده (SCG) در طراحی مدل مورد بررسی قرار گرفته‌اند که در هر دسته با توجه به تعداد ورودیها و شرایط آن دسته با استفاده از یکی از الگوریتمها بهترین نتیجه حاصل شده است.

- الگوریتم شیب مزدوج با اصلاح فلچر-ریوز^{۱۹}

همه الگوریتمهای شیب مزدوج، با جستجو در جهت نزول شیب در تکرار اول (منفی شیب) شروع می‌شوند ($P = -g_0$). پس از آن یک جستجوی خطی، برای تعیین فاصله بهینه برای حرکت در طول جهت جستجوی فعلی، انجام می‌شود.

$$X_{k+1} = X_k + \alpha_k P_k \quad (5)$$

سپس جهت جستجوی بعدی که مزدوج با جهت‌های جستجوی قبلی است، تعیین می‌شود. رویه عمومی برای تعیین جهت جستجوی جدید، ترکیب جهت نزول شیب جدید با جهت جستجوی قبلی است.

$$P_k = -g_k + \beta_k P_{k-1} \quad (6)$$

¹⁸ Principal Component Analysis

¹⁹ Fletcher_Reeves

نسخه‌های مختلف شیب مزدوج، با توجه به محاسبه ثابت از یکدیگر متمایز می‌شوند. برای اصلاح فلچر-ریوز این مقدار ثابت به صورت روبرو محاسبه می‌شود.

$$\beta_k = \frac{g_k^T \cdot g_k}{g_{k-1}^T \cdot g_{k-1}} \quad (7)$$

این الگوریتم در تکرارهای کمتری نسبت به الگوریتم پس انتشار ارتجاعی، همگرا می‌شود.

- الگوریتم شیب مزدوج با اصلاح پولاک-ریبر ۲۰

در این الگوریتم، کلیه موارد شبیه الگوریتم قبلی است با این تفاوت که ثابت بصورت روبرو محاسبه می‌شود:

$$\beta_k = \frac{\Delta g_{k-1}^T \cdot g_k}{g_{k-1}^T \cdot g_{k-1}} \quad (8)$$

عملکرد این الگوریتم، شبیه الگوریتم قبلی است. ولی نمی‌توان گفت که کدام الگوریتم برای حل یک مسئله خاص بهتر عمل می‌نماید.

- الگوریتم شیب مزدوج با اصلاح پاول-بیل ۲۱

در همه الگوریتم‌های شیب مزدوج، جهت جستجو بصورت دوره‌ای، به مقدار منفی گردایان تنظیم می‌شود. نقطه تنظیم مجدد استاندارد، زمانی اتفاق می‌افتد که تعداد تکرارها، برابر تعداد پارامترهای شبکه (وزن‌ها و بایاس‌ها) شود. اما روش‌های دیگری نیز برای تنظیم مجدد وجود دارد که راندمان آموزش را بهبود می‌بخشد. یکی از این روش‌ها، روش پیشنهاد شده توسط پاول است که براساس نسخه قبلی پیشنهادی شده توسط بیل، انجام شده است. در این تکنیک شروع مجدد در صورتی انجام می‌شود که راست گوشه‌ای کمی در سمت چپ بین شیب فعلی و شیب قبلی وجود داشته باشد. این قضیه توسط نامساوی زیر آزمایش می‌شود:

$$\left| g_{k-1}^T \cdot g_k \right| \geq 0.2 \|g_k\|^2 \quad (9)$$

در صورتیکه این شرایط برقرار باشد، جهت جستجو مجدداً به مقدار منفی شیب تنظیم می‌شود. این الگوریتم نسبت به الگوریتم قبلی، دارای راندمان بهتری است.

- الگوریتم شیب مزدوج مقیاس‌بندی شده

هر یک از الگوریتم‌های شیب مزدوج بحث شده، در هر بار تکرار الگوریتم، به یک جستجوی خطی نیازمندند. این جستجوی خطی از نظر محاسباتی بسیار هزینه‌بر است. زیرا لازم است که شبکه به همه ورودی‌های آموزش، که برای هر جستجو چندین بار محاسبه می‌شوند، پاسخ گوید. الگوریتم شیب مزدوج مقیاس‌بندی شده که توسط مولر توسعه داده شده، برای اجتناب از صرف زمان در جستجوی خطی، طراحی گردیده است. این الگوریتم پیچیده‌تر از آن است که در این چند سطر مختصر توضیح داده شود. اما ایده اصلی آن ترکیب رویکرد ناحیه اعتماد مدل که توسط الگوریتم لونیبرگ-مارکوارت استفاده می‌شود با رویکرد شیب مزدوج است. این الگوریتم ممکن است برای همگرایی به تکرارهای بیشتری نسبت به الگوریتم‌های شیب مزدوج دیگر، احتیاج داشته باشد. اما تعداد محاسبات در هر تکرار به طور قابل ملاحظه‌ای، کاهش می‌یابد. زیرا هیچ جستجوی خطی در آن انجام نمی‌شود [۱۸]، [۱۹].

۵-۵- معیارهای عملکرد

اکثر مقالات، فقط میانگین درصد قدرمطلق خطا (MAPE)^{۲۰} را گزارش کرده‌اند؛ MAPE، یک استاندارد در صنعت تامین الکتریسیته است که بوضوح کافی نیست. انتخاب معیارهای خطا برای کمک به مقایسه روش‌های پیش‌بینی بسیار بحث شده است، اکثر مولفین توافق

²⁰ Polak_Ribiere

²¹ Powell_Beale

²² Mean Absolute Percentage Error

کرده‌اند که تابع جریمه همبسته با خطاهای پیش‌بینی باید در ارزیابی یک روش استفاده شود. اگر تابع جریمه خطی باشد (خطی در درصد نه در قدرمطلق خطا)، MAPE، میزان خطایی کافی خواهد بود؛ هرچند مطالعات اخیر و تجربه اپراتورهای سیستم نشان می‌دهد که تابع جریمه در مساله پیش‌بینی بار بوضوح غیرخطی است و اینکه خطاهای بزرگ ممکن است اثرات خطرناکی برای استفاده همگانی داشته باشد. به همین دلیل اندازه‌گیری مبتنی بر مربعات خطا توصیه می‌شود، چون آنها خطاهای بزرگ را بیشتر جریمه می‌کنند. در این تحقیق برای سنجش بهترین پیش‌بینی پیک بار از معیارهای میانگین قدرمطلق خطا²³ (MAE) و MAPE و از معیار میانگین مجموع مربعات خطا²⁴ (MSE) برای سنجش خطاهای بزرگ استفاده می‌شود، قابل ذکر است که با کاهش این سه معیار مدل بهبود می‌یابد. در نهایت حالتی انتخاب می‌شود که معیارهای عملکرد خوب بیشتری دارا باشد.

۵-۶- نتایج پیش‌بینی

همانطور که پیش از این بیان گردید، پیش‌بینی پیک بار روز بعد با استفاده از شبکه عصبی پیش‌خوراند و چهار الگوریتم آموزشی SCG, CGF, CGP, CGB انجام شد و داده‌های سه سال جهت آموزش و داده‌های یکسال برای اعتبارسنجی استفاده گردید. MAE, MAPE, MSE معیارهای مقایسه عملکرد شبکه‌ها می‌باشند. نتایج نشان می‌دهد که بهترین پیش‌بینی هریک از دسته‌ها با الگوریتمها و تعداد نرونهای مخفی متفاوت حاصل گردیده است. جدول (۲) بهترین مقادیر حاصل از پیش‌بینی با استفاده از شبکه عصبی پیش‌خوراند و بکارگیری الگوریتمهای ذکر شده را برای هریک از ۱۲ دسته حاصل از دسته‌بندی نشان می‌دهد.

جدول ۲- نتایج حاصل از پیش‌بینی با استفاده از شبکه عصبی پیش‌خوراند

نام دسته	ایام عید			دسته اول جمعه‌ها و ایام تعطیل			دسته دوم جمعه‌ها و ایام تعطیل			دسته سوم جمعه‌ها و ایام تعطیل		
	MSE	MAPE	MAE	MSE	MAPE	MAE	MSE	MAPE	MAE	MSE	MAPE	MAE
معیار عملکرد شبکه عصبی پیش‌خوراند	۸۵۹۴٫۸	۲٫۲۹	۶۶٫۸	۱۴۶۶۶	۲٫۹۳	۹۶٫۲	۵۵۶۵٫۶	۱٫۶۴	۶۲٫۱	۶۷۰۷٫۲	۱٫۸۹	۶۷٫۳
نام دسته	دسته اول پنجشنبه‌ها			دسته دوم پنجشنبه‌ها			دسته سوم پنجشنبه‌ها			دسته چهارم پنجشنبه‌ها		
معیار عملکرد شبکه عصبی پیش‌خوراند	۲۰۰۷	۱٫۰۶	۳۷٫۵	۴۲۷۲٫۷	۱٫۴۴	۵۷	۳۵۰۴٫۳	۱٫۱۴	۴۷٫۹	۴۶۶۸٫۲	۱٫۳۱	۵۱٫۶
نام دسته	دسته اول شنبه‌ها تا چهارشنبه‌ها			دسته دوم شنبه‌ها تا چهارشنبه‌ها			دسته سوم شنبه‌ها تا چهارشنبه‌ها			دسته چهارم شنبه‌ها تا چهارشنبه‌ها		
معیار عملکرد شبکه عصبی پیش‌خوراند	۴۰۳۹٫۷	۱٫۲۷	۴۶٫۲	۵۳٫۷	۱٫۳۵	۵۰۲۰٫۵	۷۴۶۷٫۶	۱٫۵۱	۶۵٫۷	۷۲۶۱٫۲	۱٫۵۳	۶۴٫۶

همچنین، جهت نمایش میزان تاثیرگذاری دسته‌بندی ایام سال در بهبود پیش‌بینی پیک بار روز بعد، محاسبات را با استفاده از شبکه عصبی پیش‌خوراند و تنها براساس تقسیم‌بندی روزهای هفته به سه دسته شنبه تا چهارشنبه، پنجشنبه، جمعه و ایام تعطیل نیز انجام شد. جدول (۳) نتایج حاصل از پیش‌بینی بدون استفاده از شبکه نقشه خودسازمانده را نشان می‌دهد.

²³ Mean Absolute Error

²⁴ Mean of Square Error

جدول ۳- نتایج حاصل از پیش‌بینی با شبکه عصبی پیش‌خوراند بدون استفاده از نقشه خودسازمانده

نام دسته	دسته شنبه‌ها تا چهارشنبه‌ها	دسته پنجشنبه‌ها	دسته جمعه‌ها و ایام تعطیل
معیار عملکرد			
MAE	۸۲,۷	۶۱,۱	۸۷,۴
MAPE	۲	۱,۵۹	۲,۵۲
MSE	۱۱۹۷۹	۶۱۳۲,۲	۱۱۸۰۹

پس از انجام پیش‌بینی با استفاده از دو روش، میانگین وزنی نتایج حاصل شده را برای مقایسه عملکرد پیش‌بینی هر یک از دسته‌ها در طول یکسال محاسبه نمودیم. جدول (۴) نتایج کلی عملکرد دو روش پیش‌بینی را ارائه می‌کند.

جدول ۴- نتایج کلی عملکرد دو روش پیش‌بینی

معیار عملکرد	شبکه عصبی پیش‌خوراند تلفیقی	شبکه عصبی پیش‌خوراند
MAE	۶۱,۷	۸۰,۵
MAPE	۱,۵۸	۲,۰۵
MSE	۶۶۲۹,۲	۱۰۶۴۵,۶

مدل شبکه عصبی پیش‌خوراند تلفیقی می‌تواند بطور میانگین هر پیش‌بینی را با خطایی معادل ۱,۵۸ درصد خطا انجام دهد و در هر پیش‌بینی حدود ۶۱,۷ مگاوات خطا وجود دارد. درحالی‌که، با بکارگیری شبکه عصبی پیش‌خوراند بدون استفاده از نقشه خودسازمانده می‌تواند بطور متوسط پیک روز بعد را با خطایی معادل ۲,۰۵ درصد خطا انجام دهد و در هر پیش‌بینی حدود ۸۰,۵ مگاوات خطا وجود دارد. این مقایسه نشان می‌دهد که این شیوه دسته‌بندی ایام سال موجب بهبود چشمگیری در نتیجه پیش‌بینی شده است.

۵-۶- خلاصه و نتیجه‌گیری

در این تحقیق، ابتدا از یک نقشه خودسازمانده برای تعیین بهترین دسته‌بندی برای تقسیم‌بندی هفته‌های سال براساس دو فاکتور مصرف پیک‌بار و دمای هوا در ساعت پیک‌بار استفاده شد. بدلیل متفاوت بودن مقیاس این دو فاکتور، از نرمال‌سازی داده‌ها پیش از آغاز عملیات دسته‌بندی استفاده شد. برای تعیین بهترین دسته‌بندی از شاخص دسته‌بندی دیویس- بولدین استفاده شد. آنگاه، دسته‌های حاصل از خروجی نقشه خودسازمانده اول توسط نقشه خودسازمانده دیگری براساس عامل پیک‌بار مصرفی، هر یک به دسته‌های دیگری تقسیم می‌شود که در نهایت ۱۲ دسته حاصل گردید. سپس با استفاده از شبکه عصبی پیش‌خوراند مبتنی بر شیب مزدوج عمل پیش‌بینی انجام گرفت. با مقایسه نتایج حاصل از روش شبکه عصبی پیش‌خوراند تلفیقی و شبکه عصبی پیش‌خوراند می‌توان متوجه شد که دسته‌بندی موجب بهبود نتایج گردیده است.

مراجع

- [۱] Tzafestas, S.; Tzafestas, E.; "Computational Intelligence Techniques for Short-Term Electric Load Forecasting", Journal of Intelligent and Robotic Systems 31:7, 7-68,2001.
- [۲] Metaxiotis, K., Kagiannas, A., Askounis, D., Psarras, J., "Artificial intelligence in short term electric load forecasting : a state-of-the-art survey for the researcher", Energy Conversion & Management, 44, 1525-1534, 2003.



- [۳] Huang,H.G., Hwang,R.C., Hsieh,J.G.,”A new artificial intelligent peak power load forecaster based on non-fixed neural networks”, Electrical Power Energy Syst.,24, 245-250, 2002.
- [۴] Hippert, H.S., Pedreira, C.E., Castro, S.R.,”Neural Networks for Short-Term Load Forecasting: A Review and Evaluation”, IEEE Transactions on Power Syst.,16:1,44-55, 2001.
- [۵] Amjady, N., ”Short-Term Hourly Load Forecasting Using Time-Series Modeling With Peak Load Estimation Capability”, IEEE Trans. Power Systems, Vol.16, No.4, pp.798-805, November 2001.
- [۶] صادقپور،حسن، امین ناصری،محمدرضا، پیش‌بینی بار روزانه در شبکه برق خراسان با استفاده از سیستم خبره. هفدهمین کنفرانس بین‌المللی برق،(PSC(2002).
- [۷] صیاد،ساعد، صیاد،جهانگیر، پیش‌بینی بار هوشمند سیستم‌های قدرت، پنجمین کنفرانس شبکه‌های توزیع نیرو، مشهد، ۱۳۷۴.
- [۸] مقدس‌تفرشی،مسعود، یاریان،محمد، پیش‌بینی کوتاه مدت بار با استفاده از ترکیب شبکه‌های عصبی کوهونن و پرسپترون، چهاردهمین کنفرانس بین‌المللی برق،(PSC 99)، 10-12 آبان ۱۳۷۸. تهران.
- [۹] Carpinteiro, O. A. S., Alves Da Silva, A. P.,”A hierarchical neural model in short-term load forecasting“, Applied Soft Computing 4,405-412,2004.
- [۱۰] Carpinteiro, O. A. S., Alves Da Silva,A. P.,”A hierarchical self-organizing map model in short-term load forecasting”, J.Intell.Robotic Systems 31(1-3), 105-113,2001.
- [۱۱] Carpinteiro, O. A. S., Alves Da Silva, A. P.,”A hierarchical neural model in short-term load forecasting“, IEEE,120-124,2000.
- [۱۲] Iizaka, T., Matsui, T., Fukuyama, Y.,”A novel daily peak load forecasting Method using Analyzable structured neural network”, IEEE T&D asia yokohama, October, 1-6,2002.
- [۱۳] Saini, L.M., Soni, M.K.,”Artificial neural network based peak load forecasting using Levenberg-Marquardt and quasi-Newton methods”, IEE Proc-Gener.Transm.Distrib,2002.
- [۱۴] Saini, L.M., Soni, M.K.,”Artificial neural network based peak load forecasting using Conjugate Gradient Methods”, IEEE Transactions on Power Systems, Vol.17, No.3, 907-912, August 2002.
- [۱۵] Hsu, C. C., Chen, C. Y.,”Regional load forecasting in Taiwan _applications of artificial neural networks”, Energy Conversion & Management 44,1941-1949,2003.
- [۱۶] Oja M., Kaski, S., Kohonen, T., “Bibliography of Self-Organizing Map (SOM) Papers: 1998-2001 Addendum”, Neural Computing Surveys 3, 1-156,2002.
- [۱۷] Vesanto, J.; Alhoniemi, E.,”Clustering of the Self-Organizing Map”, IEEE Transactions on Neural Networks,Vol.11, No.3, 586-600,2000.
- [۱۸] Demuth, H., Beale, M., MATLAB 6.5/ Neural Network Toolbox, version 4, The MathWorks, Inc.,(CD-ROM),1-840,2002.
- [۱۹] Hagan, M.T., Demuth, H., Beale, M., ”Neural Network Design”, USA, PWS Publishing Company,1996.