

بهبود برآش رگرسیون با استفاده از خوشبندی شبکه‌ی عصبی به منظور پیش‌بینی اوج صرف انرژی الکتریکی ماهانه

علیرضا سروش (دانشجوی دکتری)

رضا براذران کاظم‌زاده (دانشیار)

اردشیر بحرانی‌نژاد (استادیار)

دانشکده‌ی فنی و هندسی، بخش هندسی صنایع، دانشگاه تربیت مدرس

در سیستم قدرت الکتریکی، پیش‌بینی اوج بار به منظور بهینه‌سازی اقتصادی، برنامه‌ریزی خط‌مشی، تخصیص بودجه و مدیریت ساخت نیروگاه‌ها نقش بسیار مهمی بازی می‌کند. دقت روش پیش‌بینی در توسعه‌ی استراتژی تأمین قدرت، و طرح توسعه بتویزه برای کشورهای در حال توسعه بسیار مهم است. زیرا در این کشورها نزد رشد تقاضا پویا و زیاد است. در این نوشتار برای اولین بار یک مدل رگرسیون تلفیقی به منظور پیش‌بینی اوج بار الکتریکی ماهانه با استفاده از روش خوشبندی و آنالیز مؤلفه‌های اصلی^۱ (PCA) ارائه شده است. بدین منظور داده‌های تقاضای اوج بار ماهانه^۲ ۱۴ سال گذشته در شبکه‌ی قدرت الکتریکی سراسری ایران مورد تجزیه و تحلیل قرار می‌گیرد. مدل ارائه شده امکان پیش‌بینی انرژی الکتریکی مصرفی یا اوج بار ماهانه را برای آینده فراهم می‌کند. بدین ترتیب که ابتدا برای بهبود برآش رگرسیون، نقشه‌ی خودسازماندهی^۳ (SOM) به منظور خوشبندی اوج بار مصرفی ماهانه طراحی شده است و ماه‌های مشابه با یکدیگر در گروه‌های یکسان قرار داده شده‌اند. سپس با بهکارگیری شاخص دیویس - بولین بهترین حالت خوشبندی تعیین شده است. همچنین به منظور کاهش ابعاد و روده‌ها و بهبود نتایج از آنالیز مؤلفه‌های اصلی استفاده شده است. به منظور پیش‌بینی اوج بار ماهانه برای هر خوشبندی از روش رگرسیون استفاده شده است. آنالیز و مقایسه‌ی نتایج پیش‌بینی با روش رگرسیون بدون انجام خوشبندی نشان می‌دهد که دقت عمل مدل ارائه شده بسیار خوب است و خوشبندی داده‌ها موجب بهبود پیش‌بینی شده است.

a.soroush@modares.ac.ir
rkazem@modares.ac.ir
bahreinnejad@modares.ac.ir

وازگان کلیدی: پیش‌بینی، اوج بار الکتریکی ماهانه، خوشبندی، نقشه‌ی خودسازمانده، رگرسیون، شاخص دیویس - بولین.

۱. مقدمه

تأمین انرژی الکتریکی مورد نیاز مصرف‌کنندگان به اقتصادی‌ترین وجه ممکن در شرایط شبکه، و فراتر از آن مبنای برنامه‌های توسعه‌ی ظرفیت‌های تأسیساتی شبکه‌ی برق رسانی کشور است و نهایتاً در کل برنامه‌ی تأمین نیاز جامعه به حامل‌های مختلف انرژی نقش اساسی دارد.

به‌طور کلی برای الکتریکی در طی روز هفته، ماه و حتی سال تغییر می‌کند اما آنچه که در یک جامعه‌ی معین از نظر مصرف برای الکتریکی ثابت می‌ماند، روند تغییرات بار است. هنر پیش‌بینی بار آن است که با مطالعه و تحلیل روند گذشته‌ی بار و کسب شناخت کافی از عوامل مؤثر و میزان انرگذاری هریک از این عوامل، از میان روش‌ها و مدل‌های مختلف پیش‌بینی بار مناسب‌ترین و نزدیک‌ترین مدلی را که با واقعیت موجود در شبکه مطابقت دارد انتخاب، و بدین‌سان بار دوره‌های زمانی

در سالیان گذشته پیش‌بینی برای الکتریکی به دلیل نقش مهم آن در عملیات مؤثر و اقتصادی استفاده از برق مورد توجه دانشگاهیان و محققان صنعتی قرار گرفته است. برنامه‌ی تولید نیروگاه‌ها در دوره‌های مختلف زمانی براساس تغییرات بار طی ساعت، روز هفته، ماه و سال تنظیم می‌شود. انجام این برنامه‌ریزی نیاز به آگاهی یا پیش‌بینی بار برای این دوره‌های زمانی دارد. از طرف دیگر، برنامه‌های توسعه‌ی نیروگاه‌ها و ظرفیت‌های تولیدی نیز به همین صورت و با پیش‌بینی اوج بار در دوره‌های برنامه‌ریزی تدوین می‌شود. بنابراین، پیش‌بینی بار مبنای بهره‌برداری از ظرفیت نیروگاه‌ها و شبکه‌ی برق رسانی و تخصیص بهینه‌ی ظرفیت‌ها به منظور

تاریخ: دریافت ۱۱/۶/۱۳۸۶، داوری ۹/۱۳۸۶، پذیرش ۱۲/۸/۱۳۸۶.

پیش‌بینی‌های کوتاه‌مدت مناسب‌ترند، زیرا این مدل‌ها بر داده‌های گذشته‌یی که اخیراً به‌وقوع پیوسته‌اند تأکید می‌کنند.

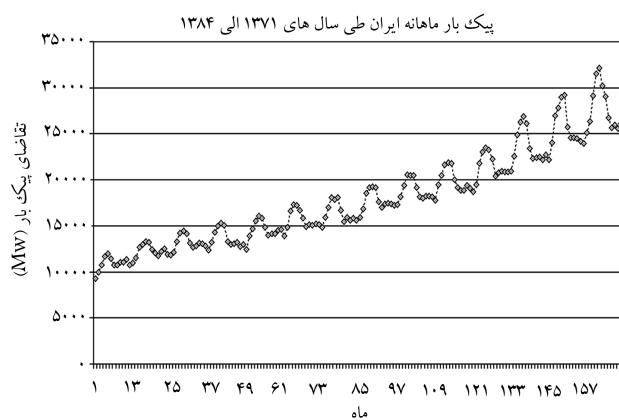
پیش‌تر در سال ۲۰۰۴، مدل‌هایی برای پیش‌بینی اوج بار ماهانه‌ی هر سال و پیش‌بینی انرژی، بالستفاده از شبکه‌های عصبی پیشخواراند و با شیوه‌ی یادگیری پس انتشار ارائه شده بود.^[۴] ارائه‌ی این مدل با استفاده از دو روش پیش‌بینی مجرماً برای پیش‌بینی اوج بار ماهانه، شامل مدل‌های تکثیری^۵ و فرازینه^۶ صورت گرفت. قابلیت این مدل‌ها بر روی شبکه‌ی قدرت الکتریکی مصروف آزمایش قرار گرفته است.^[۶]

پس از مطالعه و مرور ادبیات مربوط به پیش‌بینی اوج بار ماهانه متوجه می‌شویم که تمامی محققین داده‌های اوج بار ماهانه را در قالب یک مجموعه در نظر گرفته و با یکی از ابزارها به پیش‌بینی آن پرداخته‌اند؛ درحالی که لحاظ داده‌های مشابه و غیرمشابه در یک مجموعه موجب افزایش خطای پیش‌بینی خواهد شد. از این‌رو، در ادامه مدلی ارائه خواهیم کرد که با خوش‌بندی داده‌های اوج بار ماهانه دقت پیش‌بینی در آن به میزان قابل توجهی افزایش خواهد یافت.

۳. تحلیل داده‌ها

در این تحقیق از داده‌های مصرف اوج بار ماهانه در شبکه سراسری ایران در سال‌های ۱۳۷۱ الی ۱۳۸۴، که جمیعاً معادل ۱۶۸ ماه است، برای پیش‌بینی اوج بار ماهانه استفاده می‌شود. لازم به ذکر است که در بیشتر سال‌ها، اوج بار سالانه در تیر یا مردادماه رخ داده است. همچنین، براساس همین بازه زمانی، اطلاعات مربوط به متوسط دمای هوای ماهیانه^۳ شهر تهران (با هوای سرد)، تبریز (با هوای سرد) و اهواز (با هوای گرم) از سازمان هواشناسی تهیه شده است. دمای هوای یکی از عوامل تأثیرگذاری است که می‌تواند به پیش‌بینی دقیق‌تر اوج بار ماهانه کمک کند.

شکل ۱ روند سری زمانی تقاضای اوج بار ماهانه‌ی شبکه‌ی سراسری ایران طی ۱۴ سال متولی را نمایش می‌دهد. چنان‌که مشاهده می‌شود مصرف بار در هر سال، نسبت به همان مقطع زمانی در سال قبل، روندی رویه افزایش نشان می‌دهد. در فروردین ماه اوج بار در کمترین میزان خود قرار دارد، اما با گرم‌ترشدن هوا مصرف برق افزایش یافته، و با کاهش میزان گرما اوج بار کاهش می‌یابد؛ مجدداً با سرد شدن هوا اوج بار (نه به‌اندازه‌ی ماه‌های گرم سال) افزایش می‌یابد. این شیوه‌ی تحلیل صرفاً نوعی بررسی دیداری است و ممکن است در آن خطای وارد شده باشد، از این‌رو، با توجه به این‌که تغییرات



شکل ۱. سری زمانی داده‌های تقاضای اوج بار ماهانه در شبکه‌ی سراسری ایران.

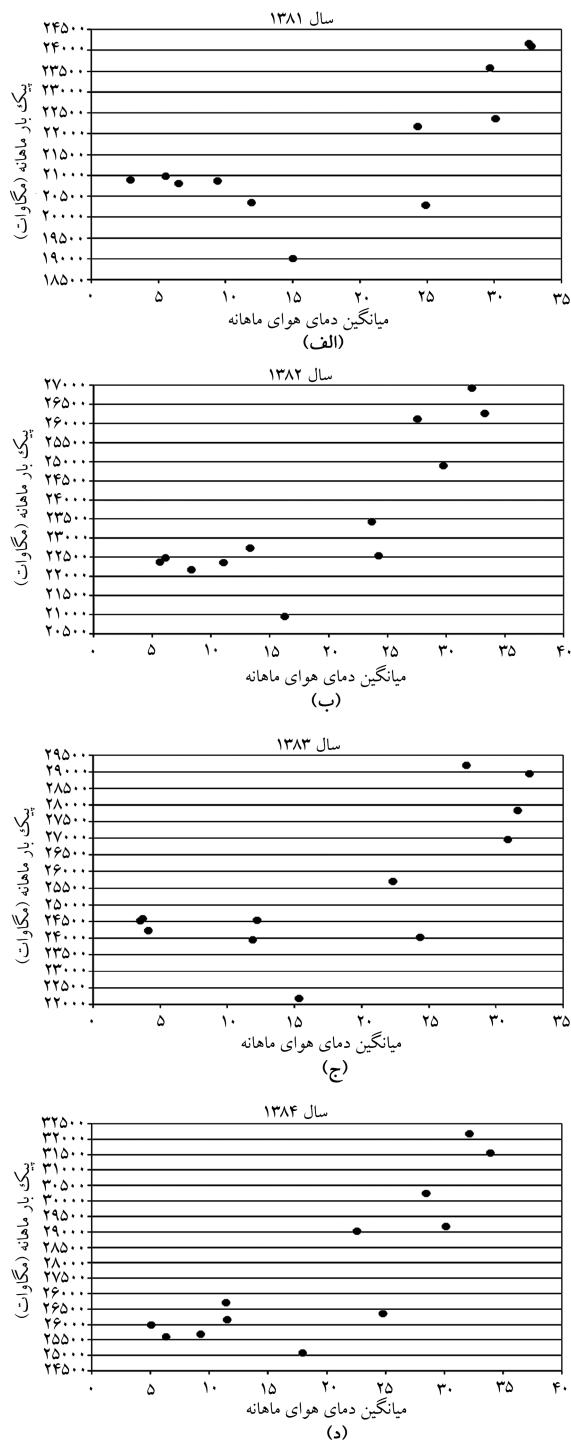
مخالف مورد نیاز شبکه را با تخمینی قابل قبول پیش‌بینی کند. بدليل وجود رفتار حد پذیرفته شده و قابل تحمل بیشتر باشد. دقت نسبی در پیش‌بینی بار وجود دارد اما این خطای نباید از اهمیت خاصی برخوردار است. به خصوص هنگامی که پیش‌بینی بار مبنای برنامه‌ریزی توسعه‌یی شبکه و ظرفیت نیروگاهی باشد زیرا هرگونه پیش‌بینی مازاد مصرف، موجب سرمایه‌گذاری اضافی و عاطل‌ماندن ظرفیت تأسیساتی می‌شود؛ به عکس هرگونه پیش‌بینی کمتر از نیاز واقعی، شبکه را با کمبود تولید و صدمه به تجهیزات بر اثر بار اضافی مواجه خواهد کرد.

هدف از پیش‌بینی اوج بار ماهانه، پیش‌بینی تقاضای الکتریکی آینده مبتنی بر داده‌های اوج بار مصرفی و شرایط آب و هوایی است. ایجاد یک متدولوزی میان مدت دقیق، سریع و قوی برای پیش‌بینی بار ماهانه موجب برآورد دقیق تر میزان مصرف الکتریسیته خواهد شد. پیش‌بینی اوج بار الکتریکی ماه بعد، کاربردی اساسی در عملیات و برنامه‌ریزی سیستم قدرت الکتریکی دارد.

بنابراین، روش‌های پیش‌بینی مختلفی در این حوزه پیشنهاد شده‌اند. برخی از محققین در مقالات از مدل‌های سری زمانی و رگرسیون استفاده کرده‌اند. با استفاده از این روش‌ها رابطه‌ی بین متغیرهای مستقل و متغیرهای است (پیش‌بینی) قابل درک و ساده است. همچنین، در دو دهه‌ی گذشته تحقیقات گسترده‌یی در خصوص کاربرد روش‌های هوش مصنوعی^۳ (AI) برای مسئله‌ی پیش‌بینی بار انجام شده است. در میان این روش‌ها، شبکه‌های عصبی مصنوعی^۴ (ANN) پیشترین توجه را به‌سوی خود جلب کرده‌اند. اولین گزارش‌ها در مورد کاربردشان در مسئله‌ی پیش‌بینی بار در اوخر دهه‌ی ۱۹۸۰ و اوایل دهه‌ی ۱۹۹۰ منتشر شده بود.^[۱] در تمامی مقالاتی که درباره‌ی پیش‌بینی اوج بار ماهانه به چاپ رسیده است، نویسنگان کلیه ماههای سال را در یک دسته قرار داده و پیش‌بینی اوج بار را برای یک چند ماه بعد ارائه کرده‌اند، به‌طوری که داده‌های اوج بار ماهانه مشابه و غیرمشابه در یک دسته فرض شده‌اند که این موضوع موجب افزایش خطای پیش‌بینی خواهد شد. در این نوشتار پس از مرور کارهای انجام شده در این زمینه، مدل رگرسیون تلفیقی ارائه می‌شود که ابتدا از یک شبکه‌ی نقشه‌ی خودسازمان‌ده (SOM) برای خوش‌بندی ماههای سال استفاده می‌کند و پس از کاهش ابعاد و رودی‌ها با استفاده از PCA، پیش‌بینی اوج بار ماه بعد به روش رگرسیون انجام می‌شود. همچنین، این پیش‌بینی با استفاده از روش رگرسیون بدون انجام خوش‌بندی نیز صورت می‌گیرد و در انتهای با مقایسه‌ی نتایج به دست آمده نتیجه‌گیری خواهیم کرد.

۲. مروری بر ادبیات موضوع

چنان‌که پیش‌تر اشاره شد، در خصوص پیش‌بینی اوج بار ماهانه مقالات چندانی به چاپ نرسیده است اما در این بخش برخی از مقالات چاپ‌شده در این خصوص را مورد بررسی قرار می‌دهیم. در سال ۲۰۰۵ محققان به‌منظور پیش‌بینی مصرف الکتریسیته یا بار ماهانه‌ی میان‌مدت از شبکه‌ی عصبی استفاده کردند؛ آنان برای انجام این تحقیق بارهای ماهانه‌ی شش ماه قبل را به عنوان متغیرهای ورودی برگزیدند و نتایج پیش‌بینی را با روش میانگین متحرک مقایسه کردند.^[۲] در سال ۲۰۰۶ نیز تعداد دیگری از محققین، با استفاده از روش میانگین متحرک یک پارچه‌ی اتورگرسیو فصلی (SARIMA) نسبت به پیش‌بینی تقاضای اوج بار ماهانه در منطقه‌ی سلیمانیه‌ی عراق اقدام کردند.^[۳] این عده در پایان تحقیق مورد نظر به این نتیجه رسیدند که مدل‌های میانگین متحرک پک‌پارچه‌ی اتورگرسیو (ARIMA) برای



شکل ۳. رابطه‌ی میان اوج بار و میانگین وزنی متوسط دمای هوای ماهانه طی سال‌های ۱۳۸۱ تا ۱۳۸۴.

۴. خوشبندی با استفاده از شبکه‌ی عصبی نقشه‌خودسازمان ده

هیچ کدام از تحقیقات انجام شده در زمینه‌ی پیش‌بینی اوج بار ماهانه برای انجام پیش‌بینی، داده‌های اوج بار مصرفی را دسته‌بندی نکرده‌اند.^[۲-۶] درحالی‌که استفاده

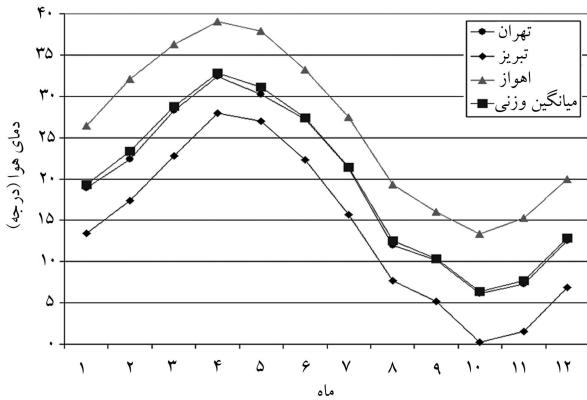
فصلی یکی از دلایل بسیار مهم برای انجام خوشبندی است، لزوم استفاده از ابزاری برای شناسایی و طبقه‌بندی دقیق تر این الگوهای مصرف در دسته‌های یکسان بیشتر نمایان می‌شود، زیرا طبقه‌بندی داده‌ها موجب کاهش آشفتگی و افزایش در دقت پیش‌بینی اوج بار ماهانه شود.

۱.۳. تأثیر دمای هوا بر الگوی مصرف بار

یکی از مهم‌ترین عوامل مؤثر بر الگوی مصرف میزان درجه حرارت است. بارهای خانگی و تجاری در ماه‌های گرم سال به دلیل استفاده از وسایل سردکننده - مانند کولر، فن و... - و در ماه‌های سرد سال به دلیل استفاده از وسایل گرم‌کننده الکتریکی تحت تأثیر درجه حرارت‌اند.

به همین منظور، دمای سه شهر تهران، اهواز و تبریز به عنوان شاخصی برای سه نوع منطقه‌ی آب و هوایی (معتدل، گرم و سرد) از میان مناطق آب و هوایی مختلف کشور در نظر گرفته شده است و با توجه به ثقل بار مصرفی هریک از مناطق مزبور ضرایب $0,02$ ، $0,05$ و $0,15$ در ماه‌های آبان، آذر، دی، بهمن، اسفند و فروردین و ضرایب $0,02$ ، $0,05$ و $0,10$ در ماه‌های یوپایی، ژانویه، فروردین، اردیبهشت، خرداد، تیر، مرداد، شهریور، مهر به ترتیب به دمای تهران، اهواز و تبریز اختصاص داده شده است. این ضرایب با تقسیم جداگانه‌ی مجموع بار مصرفی استان‌هایی که دارای آب و هوای معتدل، گرم و سرد هستند بر مجموع بار مصرفی کلیه استان‌ها در هریک از ماه‌های سال حاصل شده است. شکل ۲ متوسط دمای هوای ماهانه سه شهر تهران، اهواز و تبریز و نیز میانگین وزنی آنها را در سال ۱۳۸۴ براساس وزن‌های مذکور نمایش می‌دهد.

چنان که در شکل ۱ نشان داده شد، از آنجا که در برخی از ماههای سال با مصرف اوج بار تقریباً یکسان در دمای هوای متفاوت موافق هستیم، و صرفاً استفاده از مصرف اوج بار برای دسته‌بندی ماههای سال نمی‌تواند آنها را از یکدیگر تفکیک کند و احتمال ایجاد آشفتگی در زمان پیش‌بینی افزایش می‌یابد. به همین دلیل از متغیر دما برای تفکیک اوج بار این ماههای استفاده می‌شود. باید به این نکته اشاره کرد که رابطه‌ی میان مصرف اوج بار ماهانه و دمای هوا در هر سال تقریباً دارای شکل مشابهی است. به عنوان مثال، شکل ۳ رابطه‌ی میان مصرف اوج بار ماهانه و میانگین وزنی متوسط دمای هوا را طی سال‌های ۱۳۸۱ تا ۱۳۸۴ نشان می‌دهد.



شکل ۲. متوسط دمای هوای ماهانه‌ی شهرهای تهران، اهواز، تبریز و میانگین وزنی آنها در سال ۱۳۸۴.

چنان‌که مشاهده می‌شود در الگوریتم نقشه خودسازمان‌ده که در شکل ۵ توصیف شده است، $N_m(t)$ نمایش‌گر پارامتر آموزشی فاصله‌ی همسایگی است که حاکی از فاصله‌ی همه‌ی نمونه‌های قرار گرفته در یک شاعع مشخص از نمونه‌ی بندۀ m است. (t) نمایش‌گر نزد یادگیری فاز ترتیب است که مقدار اولیه‌ی آن توسعه کاربر تعیین می‌شود؛ بهیان دیگر، پارامتر آموزشی است که میزان تغییرات وزن و بایاس را در طول یادگیری کنترل می‌کند. این دو پارامتر آموزشی در دو فاز ترتیب و تنظیم تغییر می‌کنند. (t) نیز پارامتر آموزشی نمایش‌گر پهناهی تابع همسایگی^۷ است که همچون نزد یادگیری بصورت یک‌نواخت کاهاش می‌یابد.

از طرف دیگر در ادبیات الگوریتم خودسازمان‌ده قاعده‌یی برای تعیین تعداد خوش‌ها وجود ندارد و فقط در سال ۲۰۰۰ قاعده‌یی از \sqrt{N} تا $2\sqrt{N}$ به منظور تعیین دامنه‌ی تعداد خوش‌ها پیشنهاد شد (N تعداد نمونه‌ها در مجموعه داده‌هاست).^[۸] در شکل ۴ مفهوم پایه‌یی نقشه خودسازمان‌ده ارائه شده است. در این شکل، X_i نمایش‌گر بردار ورودی x_i و w_j نمایش‌گر مختصات مرکز نمونه خروجی زام است. w_j نیز نشان‌دهنده‌ی وزن متصل کننده بردار ورودی x_i به نمونه خروجی زام است. همچنین، الگوریتم نقشه خودسازمان‌ده به ترتیبی که در شکل ۵ توصیف شده است، قابل اجرا است.

$$E = \sum_{j=1}^C \sum_{x \in Q_j} h_m \|x - c_j\|^r \quad (1)$$

که در آن C تعداد خوش‌ها، h_m هسته همسایگی در واحد بندۀ m ، و c_j مرکز خوش‌های زاست. همچنین، در این مقاله برای انتخاب بهترین خوش‌بندی از شاخص دیویس - بولین^۸ استفاده می‌شود که در آن S_c فاصله‌ی درون خوش‌یی (مجموع فاصله‌ی بین کلیه‌ی بردارهای ورودی قرار گرفته در یک خوش از مرکز همان خوش) و d_{ce} فاصله‌ی بین خوش‌یی (مجموع فاصله‌ی بین مراکز کلیه‌ی خوش‌ها) را نمایش می‌دهد. براساس شاخص اعتبارسنجی دیویس - بولین، بهترین خوش‌بندی رابطه‌ی ۲ را کمینه می‌کند:

$$\frac{1}{C} \sum_{j=1}^C \max_{i \neq j} \left\{ \frac{S_c(Q_j) + S_c(Q_i)}{d_{ce}(Q_j, Q_i)} \right\} \quad (2)$$

این شاخص که فاصله‌ی درون خوش‌یی و نیز فاصله‌ی بین خوش‌یی را هنگام ارزیابی خوش‌بندی حاصله مورد ارزیابی قرار می‌دهد، شاخص مناسبی برای سنجش

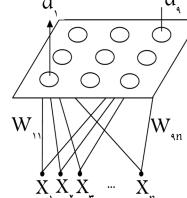
از دسته‌بندی مناسب می‌تواند به کاهاش خطای پیش‌بینی کمک کند. از این‌رو، در این تحقیق از نقشه خودسازمان‌ده (SOM) به عنوان یکی از ابزارهای بسیار مناسب برای خوش‌بندی استفاده شده است.

نقشه خودسازمان‌ده در سال‌های اخیر کاربردهای فراوانی در زمینه‌های علوم مهندسی پژوهشی، زیست‌شناسی و اقتصاد در میان محققان پیدا کرده است. طی سال‌های ۱۹۹۸ تا ۲۰۰۲ تعداد ۲۰۹۶ مقاله‌ی علمی به جای رسیده که به نوعی از این الگوریتم در تدوین آنها استفاده شده است.^[۹]

خوش‌بندی Q_i ، به معنای افزار مجموعه‌یی از داده‌ها به مجموعه‌یی از خوش‌های

$i = 1, \dots, C$ است. یک تعریف قابل قبول از خوش‌بندی بهینه، افزایی است که فواصل بین نمونه‌های داخلی را کمینه، و فواصل بین خوش‌های را بیشینه کند.^[۱۰] در شکل ۴ مفهوم پایه‌یی نقشه خودسازمان‌ده ارائه شده است. در این شکل، X_i نمایش‌گر بردار ورودی x_i و w_j نمایش‌گر مختصات مرکز نمونه خروجی زام است. w_j نیز نشان‌دهنده‌ی وزن متصل کننده بردار ورودی x_i به نمونه خروجی زام است. همچنین، الگوریتم نقشه خودسازمان‌ده به ترتیبی که در شکل ۵ توصیف شده است، قابل اجرا است.

بردارهای ورودی به آرایه‌یی از نمونه‌ها متصل می‌شوند (معمولاً یک بعد (یک ردیف) یا دو بعد (یک شبکه مستطیلی)):



زمانی که یک ورودی ارائه می‌شود ناجیه‌های معینی از آرایه «برانگیخته» خواهد شد و وزن‌های متصل کننده‌ی ورودی‌ها به آن ناجیه تقویت خواهد شد.

در طول یادگیری: - وزن‌های متصل کننده فضای ورودی به نمونه تقویت می‌شود.

- همچنین وزن‌های نمونه در همسایگی نمونه بندۀ تقویت می‌شود (اگرچه نه چندان زیاد).

زمانی که یادگیری کامل شد ورودی‌های مشابه در ناجیه‌های یکسان برانگیخته خواهند شد.

با این روش الگوهای ورودی مشابه شناسایی شده و با یکدیگر گروبنده یا خوش‌بندی می‌شود.

شکل ۴. مفهوم پایه‌یی نقشه خودسازمان‌ده.

۱. ابتدا w_j ‌ها با مقادیر تصادفی وزن‌دهی می‌شوند. اندازه همسایگی (\circ) N_m باید بزرگ (اما کمتر از تعداد گره‌ها در یک بعد آرایه) باشد. تابع پارامتر $\alpha(t)$ و (σ^2) بین 0 و 1 است.

۲. در هر مرحله آموزش، یک الگوی ورودی x به صورت تصادفی از مجموعه لایه ورودی انتخاب می‌شود. شباهت (فاصله) d این ورودی با وزن‌های w هرگز زاز طریق رابطه زیر محاسبه می‌شود.

$$d_j = \|x - w_j\| = \sqrt{\sum_{i=1}^n (x_i - w_{ij})^2} \quad (3)$$

۳. گره با حداقل فاصله را به عنوان m بندۀ انتخاب می‌شود.

۴. سپس وزن‌های متصل کننده‌ی لایه ورودی به نمونه گره‌های همسایه‌اش بر اساس قاعده یادگیری به روز می‌شوند:

$$w_{ij}(t+1) = w_{ij}(t) + c[x_i - w_{ij}(t)]$$

که $(\alpha(t))$ برای تمامی گره‌های j در (t) $c = \alpha(t) \exp(-\|r_i - r_m\|/\sigma^2)$ می‌شود.

که $r_i - r_m$ فاصله فیزیکی (تعداد گره‌ها) بین گره i و گره بندۀ m است.

۵. به همین ترتیب الگوریتم از مرحله ۲ با تعداد دوره‌های آموزشی مختلف ادامه داده می‌شود؛ t تا یک افزایش می‌یابد، سپس فاصله همسایگی، $\alpha(t)$ و (σ^2) کاهاش می‌یابد، به طوری که:

$$\alpha(t) = \alpha(\circ) N_m(t) / N_m(\circ)$$

الگوریتم تکرار می‌شود تا وزن‌ها به ثبات برسند.

شکل ۵. الگوریتم نقشه خودسازمان‌ده.

فاصله‌ای اقلیدسی با استفاده از رابطه‌ی ۴ محاسبه می‌شود:

$$d_{rs} = \sqrt{((y_r - y_s)^2)} \quad (4)$$

تقسیم‌بندی الگوریتم خودسازمان ده نیز هست، زیرا هر قدر مقدار رابطه‌ی ۲ کم‌تر باشد، نشان دهنده‌ی خوب بودن نتایج خوش‌بندی به لحاظ کروی بودن خوش‌ها^۹ است.^[۸]

۱.۴ هنجارسازی داده‌های ورودی

از آنچه حداقل و حداکثر اوج بار مصرفی ماهانه در هر سال نسبت به سال قبل رو به افزایش است، خوش‌بندی داده‌های هر سال به صورت جداگانه و با استفاده از الگوریتم خودسازمان ده ضرورت می‌باشد؛ زیرا اوج بار ماهانه در یک ماه از سال، نسبت به سال قبل خود بیشتر است. این مسئله موجب می‌شود که هنگام خوش‌بندی، ماه‌های مشابه در دو سال متفاوت در خوش‌های مختلف قرار بگیرند و به همین دلیل بردارهای ورودی سال‌های ۱۳۸۴ تا ۱۳۷۱ به صورت مجزا برای خوش‌بندی ماه‌های سال آموزش داده می‌شوند (شامل سال‌های ۱۳۸۱ تا ۱۳۷۱ به عنوان سال‌های مورد استفاده برای برآورد ضرایب رگرسیونی، و سال‌های ۱۳۸۲ تا ۱۳۸۴ به عنوان سال‌های مورد استفاده برای پیش‌بینی)، و پس از تعیین بهترین تعداد خوش‌های در هر سال، وجه اشتراک بین آنها مشخص می‌شود. به این ترتیب بهترین حالت خوش‌بندی ماه‌های سال براساس اوج بار ماهانه و میانگین وزنی متوسط دمای هوای ماهانه ثابت می‌شود. این کار موجب افزایش اطمینان مان نسبت به ثبات خوش‌بندی حاصله، و امکان تعیین آن برای سال‌های آتی خواهد شد.

همچنین پس از تعیین محدوده‌ی ورودی های مشخص می‌شود که مقدار اوج بار ماهانه نسبت به دمای هوا عددی بزرگ‌تری است. این مسئله باعث می‌شود که در زمان خوش‌بندی عامل دما تأثیر چندانی در تقسیم‌بندی نداشته باشد و خوش‌بندی فقط براساس اوج بار مصرفی ماهانه انجام شود. برای جلوگیری از وقوع این مشکل باید ورودی‌ها را هنجارسازی کرد. به این منظور از هنجارسازی استاندارد با میانگین صفر و واریانس واحد استفاده می‌شود. میانگین و انحراف معیار داده‌های ورودی با استفاده از رابطه‌ی ۳ محاسبه می‌شوند:

$$y_{new} = \frac{y_{old} - mean}{std}, \quad (3)$$

که در آن y_{old} مقدار اصلی، y_{new} مقدار جدید، و $mean$ و std به ترتیب میانگین و انحراف معیار داده‌های اصلی‌اند.

۲.۴ الگوی آرایه‌بی شبکه و نرم فاصله

چنان‌که پیش‌تر نیز اشاره شد، برای تعیین دامنه‌ی تعداد خوش‌های مورد استفاده برای دسته‌بندی داده‌ها از قاعده‌ی $2 \leq \sqrt{N}$ استفاده می‌شود. با توجه به این که تعداد نمونه‌های ما همان اوج بار مصرفی در هریک از ماه‌های سال و برابر ۱۲ است، بنابراین تعداد خوش‌های باید بین ۲ تا $\sqrt{3/4}$ باشد و بهمین دلیل برای تعیین بهترین خوش‌بندی باید بردارهای ورودی در حالت‌های ۲ و ۳ نرون و الگوهای آرایه‌بی (۱،۲) و (۱،۳) مورد آموزش قرار گیرند. بردارهای ورودی شامل دو عنصر اوج بار ماهانه و میانگین وزنی متوسط دمای هوای ماهانه است. عدد اول داخل پرانتز نمایش‌گر تعداد دسته براساس مشخصه‌ی اوج بار ماهانه و عدد دوم تعداد دسته براساس مشخصه‌ی میانگین وزنی متوسط دمای هوای ماهانه است و از ضرب این دو عدد، تعداد نرون مورد استفاده برای آموزش شبکه به دست می‌آید. همچنین برای سنجش فواصل درون‌خوش‌بی و بین خوش‌بی از معیار فاصله‌ی اقلیدسی استفاده می‌شود. برای اساس، با فرض این که ماتریس داده‌ی y شامل k^{*n} (۱*n) بودار ورودی y_n , ..., y_1 , y_2 , ..., y_n باشد، فواصل مختلف بین بردار y_i و y_j به عنوان

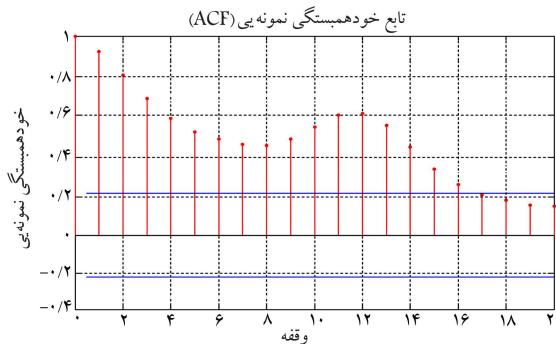
۴.۴ خروجی خوش‌بندی

همان‌طورکه پیش از این بیان شد، شبکه‌ی عصبی SOM با دو آرایه‌ی مختلف و با استفاده از الگوریتم آموزشی افزایشی تصادفی و در دو مرحله ترتیب و تنظیم آموزش داده شد. بردارهای ورودی هریک از سال‌های ۱۳۸۴ تا ۱۳۷۱ به صورت جداگانه آموزش داده شده و نتایج خوش‌بندی حاصل شد. سپس به منظور انتخاب بهترین خوش‌بندی از میان دو آرایه‌ی ممکن، شاخص اعتبارسنجی دیویس - بولدین با استفاده از فاصله‌ی اقلیدسی محاسبه شده است. جالب توجه است که در تمامی سال‌های مذکور خروجی خوش‌بندی مشابه بوده، به‌طوری‌که در حالت دو خوش‌های اردیبهشت، خرداد، تیر، مرداد، شهریور و مهر در یک خوش‌های ماه‌های آبان، آذر، دی، بهمن، اسفند و فروردین در خوش‌های دیگر قرار گرفته‌اند. در حالت سه خوش‌های نیز ماه‌های فروردین، آبان، آذر، دی، بهمن و اسفند دریک خوش‌های ماه‌های اردیبهشت و مهر در خوش‌های دوم و ماه‌های خرداد، تیر، مرداد و شهریور در خوش‌های سوم واقع شده‌اند. جدول ۱ شاخص دیویس - بولدین به دست آمده برای هریک از سال‌های ۱۳۸۴ تا ۱۳۷۱ را در حالت‌های ۲ و ۳ خوش‌های نشان می‌دهد. چنان‌که در جدول ۱ مشاهده می‌شود، کم‌ترین مقدار شاخص دیویس - بولدین بالاستفاده از سه نرون با خوش‌های دیگر می‌باشد. لذا آرایه‌ی انتخاب شده (۱,۳) است و پیش‌بینی برای هر ماه در قالب یکی از این سه خوش‌های به صورت جداگانه انجام می‌شود. خروجی و نتیجه‌ی خوش‌بندی نهایی ماه‌های سال به صورت زیر است:

خوش‌بندی ۱: ماه‌های فروردین، آبان، آذر، دی، بهمن و اسفند؛

جدول ۱. مقادیر شاخص دیویس - بولдин برای تعداد خوشهای مختلف طی سال‌های ۱۳۷۱-۱۳۸۴.

۱۳۷۱		۱۳۷۲		۱۳۷۳		۱۳۷۴		۱۳۷۵		۱۳۷۶		۱۳۷۷		سال
۲	۳	۲	۳	۲	۳	۲	۳	۲	۳	۲	۳	۲	۳	تعداد خوشة
۲,۵۱	۱,۰۵	۲,۵۴	۱,۱	۲,۶۸	۱,۲۸	۲,۵۹	۰,۸۶	۲,۴۷	۱,۰۸	۲,۴۲	۰,۹۵	۲,۴۳	۰,۹۱	مقدار شاخص دبیوس - بولدین
۱۳۷۸		۱۳۷۹		۱۳۸۰		۱۳۸۱		۱۳۸۲		۱۳۸۳		۱۳۸۴		سال
۲	۳	۲	۳	۲	۳	۲	۳	۲	۳	۲	۳	۲	۳	تعداد خوشة
۲,۰	۰,۹۴	۲,۰۲	۱,۰۲	۲,۴۱	۰,۸۵	۲,۴۹	۱,۲۵	۲,۳۹	۰,۸۵	۲,۲۵	۰,۹۴	۲,۴۱	۱,۰۳	مقدار شاخص دبیوس - بولدین



شکل ۶. همبستگی سری زمانی داده‌های اوج بار ماهانه طی سال‌های ۱۳۷۱ تا ۱۳۸۴.

بهگونه‌یی است که از وقفه‌ی اول تا هشتم کاهش می‌یابد، با تغییر شرایط فصلی از وقفه‌ی نهم مجدد افزایش می‌یابد، و در وقفه‌ی دوازدهم (همان ماه در سال گذشته) بیشینه‌ی می‌شود. براساس این نمودار، وقفه‌هایی که دارای بیش از ۱۶ هم‌بستگی هستند به عنوان تعدادی از عوامل تأثیرگذار بر مصرف اوج بار ماهانه در نظر گرفته شده‌اند. بدین ترتیب، متغیرهای ورودی برای هر یک از سه خوشۀ عبارت‌انداز: شماره‌ی ما (M)، شماره‌ی سال (Y)، میانگین وزنی متوسط دمای هوای ماهانه‌ی سه شهر تهران، تبریز و اهواز در ماه جاری (T_0): اوج بار ماهانه (L_۱) و میانگین وزنی متوسط دمای هوای ماهانه‌ی سه شهر تهران، تبریز و اهواز در ماه گذشته (T_1): اوج بار ماهانه (L_۲) و متوسط دمای هوای ماهانه‌ی سه شهر تهران، تبریز و اهواز در دو ماه گذشته (T_2): اوج بار ماهانه (L_۳) و میانگین وزنی متوسط دمای هوای ماهانه‌ی سه شهر تهران، تبریز و اهواز در ماه گذشته (T_3): اوج بار ماهانه (L_{۱۲}) و متوسط دمای هوای ماهانه‌ی سه شهر تهران، تبریز و اهواز در سال گذشته (T_{12}). در نتیجه معادله‌ی رگرسیونی هریک از آنها چنین نوشته می‌شود:

$$L_* = \beta_* M + \beta_r Y + \beta_t T_* + \beta_L L_* + \beta_T T_* + \beta_{L'} L_* + \beta_{T'} T_*$$

همچنین L نشانگر مقدار برآورد شده برای اوج بار ماه بعد است. برای پیش‌بینی اوج بار ماهانه در هریک از خوشه‌ها می‌توان از معادله‌ی بالا استفاده کرد، اما بهتر است به جای استفاده از این معادله دو عمل پیش‌پردازشی را بر روی داده‌ها انجام دهیم تا پیش‌بینی‌ها بهبود یابند:

۱. هنجارسازی داده‌ها که موجب یکسان‌سازی مقادیر متغیرها شده و امکان برآوردن دقیق تر پارامترها را فراهم می‌کند.

۲. کاهش ابعاد مسئله با استفاده از آنالیز مؤلفه‌های اصلی (PCA) که از طریق

خوشیه‌ی ۲: ماه‌های اردیبهشت و مهر؛
خوشیه‌ی ۳: ماه‌های خرداد، تیر، مرداد و شهریور.

پادآوری مجدد این نکته ضرورت دارد که استفاده از شبکه‌ی عصبی *SOM* یادگاری خطا‌ی پیش‌بینی از طریق دسته‌بندی بهینه‌ی داده‌های ورودی نزدیک موجب کاهش خطای پیش‌بینی از طریق دسته‌بندی بهینه‌ی داده‌های ورودی نزدیک به یکدیگر در یک خوشة می‌شود. همچنین برای اطمینان از عملکرد *SOM*, الگوریتم *K-means* نیز مورد آزمون قرار گرفت. مقایسه‌ی این دو روش با یکدیگر نشان داد که *SOM* به عنوان ورودی برای بخش پیش‌بینی جواب‌های بهتری ارائه می‌کند. دلایل این امر آن است که *K-means* مقدار اولیه‌ی تصادفی را به مراکز خوشه‌ها تخصیص می‌دهد و در هر اجرا خروجی متفاوتی ارائه می‌کند، اما با به کارگیری *SOM* یک خروجی حاصل می‌شود. از طرف دیگر *K-means* واریانس بین خوشیه‌ی را بیشینه می‌کند اما تضیین نمی‌کند که نتیجه یک کمینه واریانس کلی داشته باشد.^[۱۰] در ادامه در خصوص شیوه‌ی انجام پیش‌بینی بحث خواهیم کرد.

۵. پیش‌بینی با روش رگرسیون

روش رگرسیون به مطالعه‌ی وابستگی یک متغیر وابسته به یک یا چند متغیر مستقل می‌پردازد که با تخمین یا پیش‌بینی میانگین مقادیر متغیر وابسته در حالتی که مقدارهای متغیرهای مستقل معلوم با معین شده باشند، صورت می‌ذیرد. اصطلاح «خطی بودن» رگرسیون همیشه به رگرسیونی اطلاق می‌شود که از نظر پارامترها خطی باشد (یعنی پارامترها توان ۱ داشته باشند) که در این حالت ممکن است مدل از نظر متغیرهای مستقل، خطی یا غیرخطی باشد.^[۱] در این نوشتار، مانند بخش خوبه‌بندی داده‌های ۱۱ سال (سال‌های ۱۳۷۱ تا ۱۳۸۱) برای تعیین پارامترها یا ضرایب متغیرهای مدل و داده‌های سه سال (سال‌های ۱۳۸۲ تا ۱۳۸۴) به منظور پیش‌بینی و اعتیارسنجی مدل مورد استفاده قرار می‌گیرد. در زیربخش‌های بعدی به معرفی مشخصات مدل پیش‌بینی خواهیم پرداخت.

۱.۵. متغیرهای ورودی

وجود هم بستگی میان مقادیر متولی داده‌ها یک ابزار کلیدی برای شناسایی الگوی پایه‌بی و تعیین مدلی مناسب با توجه به سری داده‌ها است. در مجموعه‌بی از اعداد کاملاً تصادفی، هم بستگی میان مقادیر متولی نزدیک یا برابر با صفر خواهد بود، در حالی که مقادیر داده‌بی با مشخصه‌ی فصلی یا دوره‌بی به شدت هم بستگی خواهند داشت. شکل ۶ هم بستگی سری زمانی داده‌های اوج بار ماهانه طی سال‌های ۱۳۷۱ تا ۱۳۸۴ را نشان می‌دهد.

همان طور که در شکل ۶ مشاهده می‌کنید، الگوی فصلی و دوره‌بی میان مقادیر اوج بار ماهانه وجود داشته و این مقادیر به شدت با یکدیگر هم بسته‌اند. این همبستگی

الف) اولین مؤلفه بیشینه‌ی واریانس داده‌ها را لاحاظ کرده و دومین مؤلفه بیشینه‌ی واریانس لاحاظ نشده توسط اولین مؤلفه را لاحاظ می‌کند و الی آخر.

$$w_{k1} + w_{k2} + \dots + w_{kp} = 1 \quad k = 1, 2, \dots, p \quad (ب)$$

$$w_{kj} w_{j1} + w_{kj} w_{j2} + \dots + w_{kj} w_{jp} = 0 \quad j \neq i \quad (ج)$$

بدین ترتیب، پس از استفاده از PCA برای کاهش تعداد متغیرهای اصلی مدل رگرسیون هر خوشه، تعداد متغیرهای اصلی مدل رگرسیون در خوشه‌ی ۱ از ۱۱ متغیر به ۵ متغیر جدید، تعداد متغیرهای اصلی خوشه‌ی ۲ از ۱۱ متغیر به ۴ متغیر جدید، تعداد متغیرهای اصلی خوشه‌ی ۳ از ۱۱ متغیر به ۳ متغیر جدید و تعداد متغیرهای اصلی بدون استفاده از خوشه‌بندی از ۱۱ متغیر به ۴ متغیر جدید کاهش می‌یابد. شکل ۷ ماتریس مؤلفه‌های دوران داده شده^{۱۲} مجموعه داده‌های هر سه خوشه به صورت جداگانه پس از انجام خوشه‌بندی و همچنین ماتریس مؤلفه‌های دوران داده شده کلیه داده‌ها بدون خوشه‌بندی را نشان می‌دهد.

چنان که در شکل ۷ مشاهده می‌شود، ۴ متغیر جدید برای کلیه داده‌ها حاصل می‌شود که با استفاده از آن تقریباً ۹۸٪ درصد کل واریانس مجموعه‌ی داده‌ها محاسبه می‌شود. به طوری که متغیرهای اصلی ($Y, L1, L2, L3, L12$) در شکل‌گیری مؤلفه‌ی اول، متغیرهای اصلی ($T, T1, T2, T3$) در شکل‌گیری مؤلفه‌ی دو، متغیرهای اصلی ($T2, T3$) در شکل‌گیری مؤلفه سوم، و متغیر اصلی M در شکل‌گیری مؤلفه چهارم تأثیر بیشتری دارند. همچنین مقدار کلی ۰٪ برای سنتجه‌ی کفایت نمونه‌گیری کایسرا - میر - اولکین^{۱۳} (KMO) نشان می‌دهد که ماتریس هم‌بستگی برای فاکتورگیری مناسب است.^[۱۲]

در خصوص خوشه‌ی ۱ نیز با در نظر گرفتن ۵ متغیر جدید تقریباً ۹۸٪ درصد کل واریانس مجموعه داده‌ها محاسبه می‌شود. به طوری که متغیرهای اصلی ($T, T12$) در شکل‌گیری مؤلفه‌ی اول، متغیرهای اصلی ($Y, L1, L2, L3, L12$) در شکل‌گیری مؤلفه‌ی دوم، متغیرهای اصلی ($T1, T2, T3$) در شکل‌گیری مؤلفه‌ی سوم، و متغیر اصلی M در شکل‌گیری مؤلفه ۰٪ برای سنتجه‌ی KMO نشان می‌دهد که ماتریس هم‌بستگی مقدار کلی ۷۸٪ برای سنتجه‌ی دارند. همچنین مقدار کلی ۰٪ برای فاکتورگیری نسبتاً مناسب است. به همین ترتیب در خصوص خوشه‌ی ۲ نیز با در نظر گرفتن ۴ متغیر جدید تقریباً ۹۹٪ درصد کل واریانس مجموعه داده‌ها و در مردم در خوشه‌ی ۳ نیز با در نظر گرفتن ۳ متغیر جدید برای کلیه داده‌ها، تقریباً ۹۸٪ درصد کل واریانس مجموعه داده‌ها محاسبه می‌شود. مقدار کلی ۰٪ برای سنتجه‌ی KMO به ترتیب برای خوشه‌های ۲ و ۳ نتیجه می‌دهد که ماتریس هم‌بستگی برای فاکتورگیری مناسب است. به این ترتیب معادلات رگرسیونی کلیه داده‌ها بدون خوشه‌بندی و هر یک از سه خوشه براساس ماتریس مؤلفه‌های دوران داده شده چنین نوشته می‌شود:

$$L_a = \beta_0 + \sum_{p=1}^4 \beta_p C_p \quad (\text{معادله کلیه داده‌ها})$$

$$L_{c1} = \beta_0 + \sum_{p=1}^5 \beta_p C_p \quad (\text{معادله خوشه } ۱)$$

$$L_{c2} = \beta_0 + \sum_{p=1}^4 \beta_p C_p \quad (\text{معادله خوشه } ۲)$$

$$L_{c3} = \beta_0 + \sum_{p=1}^3 \beta_p C_p \quad (\text{معادله خوشه } ۳)$$

ایجاد متغیرهای جدیدی که ترکیبی از متغیرهای اصلی هستند موجب از بین رفتن هم‌بستگی میان متغیرهای اصلی در مدل رگرسیون می‌شود. در بخش بعدی در خصوص پیش‌پردازش داده‌ها و نتایج آن بحث خواهیم کرد.

۲.۵ پیش‌پردازش داده‌ها

اگر مراحل پیش‌پردازش معینی بر روی ورودی‌ها و مقادیر واقعی خروجی - که همان متغیرهای ما هستند - صورت گیرد ضرایب (پارامترهای) دقیق تری برای این متغیرها به منظور پیش‌بینی در آینده حاصل می‌شود. از این‌رو، پیش از برآورد ضرایب هم مقیاس‌سازی ورودی‌ها و خروجی‌ها انجام می‌شود. پیش‌پردازش داده‌ها سبب می‌شود داده‌ها در دامنه‌ی معینی فشرده شوند. این فشرده‌سازی قادر است نتایج تخمین رگرسیونی را بهبود بخشد. در این تحقیق نیز به دلیل متفاوت بودن مقیاس داده‌های اوج بار ماهانه و میانگین وزنی متوسط دمای هوای ماهانه، استفاده از هنجارسازی ضروری بمنظور می‌رسد. از این‌رو هنجارسازی داده‌های هر دسته با استفاده از روش هنجارسازی استاندارد با میانگین صفر و واریانس واحد انجام می‌شود. همچنین گاهی ابعاد بردار ورودی بزرگ است اما مؤلفه‌های بردارهای ورودی بهشت هم‌بسته‌اند. در چنین شرایطی کاهش ابعاد بردارهای ورودی بسیار مفید است. آنالیز مؤلفه‌های اصلی (PCA) ابزاری کارا برای انجام این کار است.^[۱۴] از این‌رو، بردارهای ورودی هنجارشده با میانگین صفر و واحد مورد آنالیز مؤلفه‌های اصلی قرار می‌گیرند. از آنالیز مؤلفه‌های اصلی به منظور کاهش ابعاد بردارهای ورودی و کاهش پیچیدگی مسئله در هر یک از دسته‌ها، و نیز برای حذف عواملی که تأثیرگذاری کم تری بر متغیر خروجی دارند، استفاده می‌کنیم. PCA مولفه‌های اصلی را که درصد انگذاری شان در کل تغییرات مجموعه داده‌ها کمتر از ۱٪ است حذف می‌کنند. با استفاده از آنالیز مؤلفه‌های اصلی، با تعداد متغیرهای کمتر و معناری ساده‌تری سروکار داشته و نتایج پیش‌بینی بهتری حاصل خواهد شد.^[۱۴]

PCA یک روش آماری برای تعریف متغیرهای جدید بر حسب ترکیب خطی از متغیرهای اولیه است. متغیرهای جدید نسبت به هم مستقل‌اند و واریانس آنها دارای روند نزولی است. هدف از PCA استخراج مؤلفه‌های اصلی مجموعه‌ی از متغیرهای اولیه است. برای اساس، اولین مؤلفه ای استخراجی دارای بیشترین واریانس مجموعه‌ی اولیه داده‌ها است و مؤلفه‌های استخراجی بعدی واریانس کمتری از مجموعه اولیه داده‌ها را لاحاظ کرده و مجموع واریانس مؤلفه‌های استخراجی مساوی واریانس کل داده‌ها است. همچنین مؤلفه‌های استخراج شده نسبت به هم مستقل‌اند. به طور کلی در روش آنالیز مؤلفه‌ای اصلی از P متغیر اولیه می‌توان m مؤلفه‌ی اصلی مستقل ($P < m$) استخراج کرد. از طریق مؤلفه‌های استخراجی فضای P بعدی اطلاعات به فضای m بعدی قابل کاهش است. از نظر ریاضی مؤلفه‌های اصلی P متغیر اولیه چنین نمایش داده می‌شوند.^[۱۲]

$$\xi_1 = w_{11}z_1 + w_{12}z_2 + \dots + w_{1p}z_p$$

$$\xi_2 = w_{21}z_1 + w_{22}z_2 + \dots + w_{2p}z_p$$

⋮

$$\xi_p = w_{p1}z_1 + w_{p2}z_2 + \dots + w_{pp}z_p$$

در این روابط $\xi_1, \xi_2, \dots, \xi_p$ مؤلفه‌ی اصلی، و w_{kj} ضریب چامین متغیر در k امین مؤلفه است. هدف از آنالیز مؤلفه‌های اصلی تخمین ضرایب است w_{kj} این شرط که:

ماتریس مؤلفه‌های دوران داده شده کلیه داده‌ها					ماتریس مؤلفه‌های دوران داده شده خوشه ۱					
متغیرهای اصلی	مؤلفه				متغیرهای اصلی	مؤلفه				
	۱	۲	۳	۴		۱	۲	۳	۴	
M	۲,۷۱E-۰۲	-,۶۶۴	,۱۵۵	,۷۳۰	M	۳,۹۰E-۰۲	-,۶۹۲	-۴,۶۰E-۰۲	,۷۱۹	-۴,۹۱E-۰۴
Y	,۹۸۰	۲,۹۴۶E-۰۲	-۷,۲۲E-۰۲	-۵,۶۰E-۰۲	Y	,۹۸۲	۷,۸۲E-۰۲	-۲,۵۲E-۰۲	-۴,۹۶E-۰۲	۲,۴۷E-۰۲
T	۴,۷۰E-۰۲	,۹۸۷	۶,۳۴E-۰۲	-,۱۰۱	T	۲,۲۸E-۰۲	,۹۵۸	-۶,۸۹E-۰۲	-۸,۹۲E-۰۲	,۲۴۸
L1	,۹۷۴	,۱۳۷	,۱۳۴	۵,۸۶E-۰۲	L1	,۹۹۴	۲,۴۱E-۰۲	۷,۰۴E-۰۲	۳,۲۴E-۰۲	-۵,۷۵E-۰۳
T1	۹,۵۱E-۰۲	,۸۱۸	,۵۵۵	-۵,۶۷E-۰۲	T1	,۱۱۴	,۴۵۷	,۸۶۶	-۱,۳۲E-۰۲	۴,۴۸E-۰۲
L2	,۹۷۵	۴,۹۲۷E-۰۳	,۱۹۰	۱,۰۰E-۰۲	L2	,۹۷۴	۴,۴۱E-۰۲	,۱۹۵	۳,۹۸E-۰۲	۶,۲۳E-۰۳
T2	,۱۲۹	,۴۲۴	,۸۹۳	۷,۱۰E-۰۳	T2	,۱۱۴	-۹,۱۴E-۰۲	,۹۸۲	-۱,۸۹E-۰۲	-۲,۴۰E-۰۲
L3	,۹۶۶	-,۱۳۶	,۱۸۲	-۳,۹۷E-۰۲	L3	,۹۶۴	-۳,۴۳E-۰۲	,۲۴۲	-۹,۸۸E-۰۳	۸,۶۶E-۰۳
T3	,۱۳۶	-۷,۲۹E-۰۲	,۹۷۹	۹,۳۷E-۰۲	T3	,۱۱۴	-۳۷۶	,۹۱۰	۳,۱۴E-۰۳	-۵,۱۷E-۰۳
L12	,۹۶۵	,۲۱۱	۲,۴۵E-۰۲	۶,۲۱E-۰۲	L12	,۹۹۶	-۲,۵۲E-۰۲	۵,۰۶E-۰۳	۲,۵۶E-۰۲	۱,۱۸E-۰۲
T12	۶,۴۲۶E-۰۲	,۹۸۵	۶,۴۲۵E-۰۲	-۹,۸۸۸E-۰۲	T12	۵,۲۹E-۰۲	,۹۶۱	-۶,۷۸E-۰۲	-۷,۹۲E-۰۲	-۷,۲۴۸

ماتریس مؤلفه‌های دوران داده شده خوشه					ماتریس مؤلفه‌های دوران داده شده خوشه				
متغیرهای اصلی	مؤلفه				متغیرهای اصلی	مؤلفه			
	۱	۲	۳	۴		۱	۲	۳	
M	,۹۸۶	,۱۴۷	-۱,۷۴E-۰۲	۵,۹۴E-۰۳	M	۷,۲۹E-۰۲	,۹۶۱	-,۲۵۲	
Y	-,۱۴۱	,۹۷۲	۸,۰۷E-۰۲	۳,۵۵E-۰۲	Y	,۹۷۸	-۳,۸۶E-۰۲	,۱۲۳	
T	-,۸۷۴	,۱۲۵	,۱۵۹	,۴۳۸	T	۵,۰۳E-۰۲	-۹,۷۸E-۰۲	,۹۶۹	
L1	,۲۲۲	,۹۷۱	۵,۲۴E-۰۳	۲,۲۳E-۰۲	L1	,۹۷۹	,۱۶۵	۸,۴۱E-۰۲	
T1	,۹۵۶	,۲۰۷	۲,۷۰E-۰۲	,۱۳۷	T1	,۱۱۵	,۹۶۴	,۱۷۸	
L2	,۲۳۳	,۹۶۷	۲,۴۹E-۰۲	۱,۹۵E-۰۲	L2	,۹۷۰	,۲۲۷	۱,۴۸E-۰۲	
T2	,۹۷۶	,۱۹۹	۳,۷۰E-۰۳	-۱,۱۵E-۰۲	T2	,۱۱۰	,۹۸۳	-۶,۷۲E-۰۲	
L3	,۲۰۹	,۹۷۳	۱,۴۳E-۰۲	۱,۹۱E-۰۲	L3	,۹۸۷	,۱۳۶	-۵,۵۴E-۰۲	
T3	,۹۸۰	,۱۷۴	۱,۵۹E-۰۳	-۲,۵۳E-۰۳	T3	,۱۲۷	,۹۶۴	-,۱۸۲	
L12	-۲,۶۷E-۰۲	,۹۹۵	۴,۷۳E-۰۲	۷,۲۱E-۰۳	L12	,۹۸۸	۳,۶۸E-۰۲	,۱۲۳	
T12	-,۸۱۳	,۲۵۱	,۵۱۶	۹,۵۱E-۰۲	T12	,۱۱۷	-,۱۰۱	,۹۶۵	

شکل ۷. ماتریس‌های مؤلفه‌های دوران داده شده در دو حالت پس از خوشبندی و بدون خوشبندی.

پیش‌بینی اوج بار ماه بعد پس از انجام خوشبندی، و بدون استفاده از خوشبندی مورد مقایسه قرار خواهد گرفت.

۳.۵. معیارهای عملکرد
در بیشتر نوشتارها، تنها میانگین درصد قدرمطلق خطای $MAPE$ (^{۱۵}) به عنوان شاخصی برای سنجش میزان خطای پیش‌بینی ارائه شده است اما $MAPE$ یک استاندارد در صنعت تأمین الکترونیک است که بهوضوح کفايت ننمی‌کند. در زمينه‌ی انتخاب معیارهای خطای برای کمک به مقایسه‌ی روش‌های پیش‌بینی بحث‌های بسیاری انجام شده است. بیشتر محققین با این موضوع موافق‌اند که باید از تابع جریمه‌ی همبسته با خطاهای پیش‌بینی در ارزیابی یک روش استفاده شود. اگر تابع خسارت ^{۱۶}

که در آن C_p نمایش‌گر متغیر جدید یا مؤلفه p و β_p نمایش‌گر ضریب متغیر p و مقدار برآورده شده برای اوج بار ماه بعد است.

پیش از انجام پیش‌بینی با استفاده از معادلات رگرسیونی حاصله، بررسی مناسب بودن مدل‌های رگرسیونی با استفاده از تحلیل باقی‌مانده‌ها ^{۱۴} ضروری به نظر می‌رسد. شکل ۸ تحلیل باقی‌مانده‌ها برای کلیه داده‌ها و برای هر یک از سه خوشه را نمایش می‌دهد.

همان‌طور که در شکل ۸ مشاهده می‌کنید، پراکندگی باقی‌مانده‌ها تصادفی بوده و میزان انحراف از مدل رگرسیونی قابل قبول است. همچنین می‌توان متوجه شد که باقی‌مانده دارای توزیع نرمال است و جملات خطای واریانس ثابت دارند. بنابراین، از معادلات ذکر شده برای برآورد ضرایب مدل‌های رگرسیونی به ترتیبی که در بخش نتایج پیش‌بینی توضیح داده خواهد شد، استفاده می‌شود و نتایج مدل در دو حالت

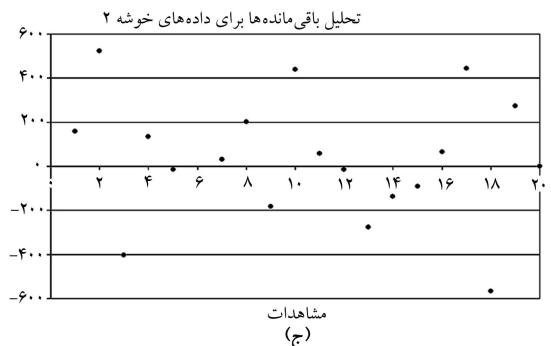
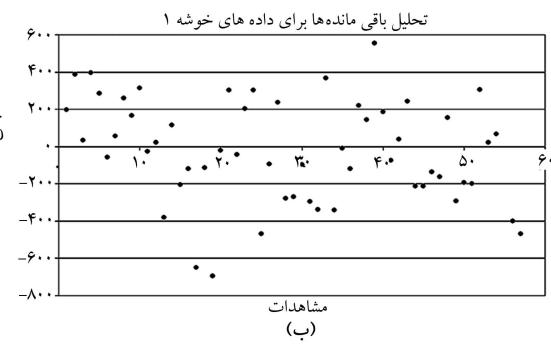
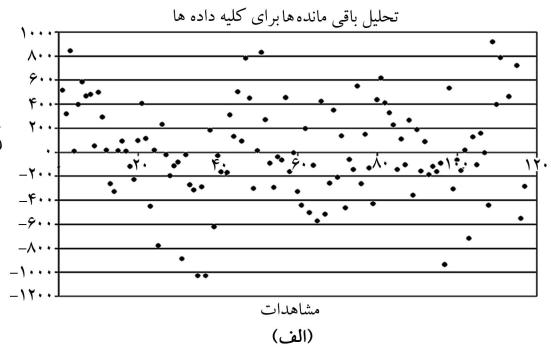
در این تحقیق برای سنجش بهترین پیش‌بینی اوج بار ماهانه از معیارهای میانگین قدرمطلق خطای MAE ، میانگین درصد قدرمطلق خطای $MAPE$ ، پیشینه‌ی قدرمطلق خطای $MAXAE$ و پیشینه‌ی درصد قدرمطلق خطای $MAXAPE$ برای برآورد خطای به صورت عادی استفاده می‌شود. همچنین از معیار میانگین مربعات خطای MSE و پیشینه‌ی مربعات خطای $MAXSE$ در سنجش خطاهای بزرگ بهره می‌گیرند. برای سنجش همبستگی بین مقادیر خروجی واقعی و مقادیر پیش‌بینی شده توسط مدل، معیار R به کار گرفته می‌شود. لازم به ذکر است که با کاهش شش معیار اول و افزایش معیار R مدل بهبود می‌یابد.

۴.۵ نتایج پیش‌بینی

همان‌طور که پیش‌تر بیان شد، پیش‌بینی اوج بار ماه بعد برای هر یک از سه خوشة بالاستفاده از معادلات رگرسیونی ارائه شده به صورت جداگانه انجام شد، به طوری که داده‌های ۱۱ سال برای تعیین پارامترهای مدل‌ها و داده‌های سه سال برای پیش‌بینی (اعتبارسنجی) مدل‌های رگرسیونی حاصل شده برای هر خوشه به کار گرفته شد. معیارهای یادشده در بخش قبل نیز عملکرد هر یک از خوشه‌ها را نشان می‌دهند. جدول ۲ بهترین مقادیر حاصل از پیش‌بینی بالاستفاده از مدل‌های رگرسیون تلفیقی برای هریک از سه خوشه‌ی حاصل از خوشبندی را نمایش می‌دهد. همچنین نتایج مدل ارائه شده بدون استفاده از PCA قابل مقایسه است.

چنان‌که مشاهده می‌کنید در خوشه‌های اول و دوم تمامی معیارهای عملکرد و در خوشه‌ی سوم معیارهای مرتبط با میانگین خطای با بهکارگیری مدل رگرسیون تلفیقی نسبت به مدل رگرسیون تلفیقی بدون استفاده از PCA جواب‌های بسیار بهتری ارائه می‌کنند. به طوری که در خوشه‌ی ۱ مدل رگرسیون تلفیقی پیش‌بینی ماه بعد به طور متوسط با ۱/۱۱ درصد خطای برآورد می‌شود، درحالی‌که اگر از PCA برای پیش‌پردازش داده‌ها استفاده نکنیم، این مقدار برابر ۱/۳۸ درصد خواهد بود. در مرور دو خوشه‌ی ۲ و ۳ نیز شاهد وضعیت مشابه خواهیم بود، به طوری که میزان برآورد خطای با استفاده از مدل رگرسیون تلفیقی برای خوشه‌ی ۲ برابر ۳/۰۷ درصد و برای خوشه‌ی ۳ برابر ۱/۶۵ درصد است. یادآور می‌شود که یکی از دلایلی که موجب بالاودن میانگین خطای خوشه‌ی ۲ نسبت به خوشه‌های ۱ و ۳ شده است، کمبودن تعداد داده‌های مورد استفاده برای برآورد دقیق تر ضرایب معادله‌ی رگرسیونی است. همچنین می‌توان به نوسانات زیاد دمای هوا در ماه‌های اردیبهشت و مهر که در این خوشه قرار گرفته‌اند اشاره کرد که تأثیر مستقیم و متقاطعی بر اوج بار ماهانه طی سال‌های مورد نظر داشته‌اند.

در خصوص بالاتر بودن مقادیر معیارهای پیشینه خطای مدل رگرسیون تلفیقی نسبت به همین مدل بدون استفاده از PCA باید بیان کرد، چون پیشینه خطای هر سه خوشه باید در حالت کلی برای ارزیابی عملکرد مدل پیشنهادی مورد استفاده قرار گیرد. با توجه به این‌که پیشینه خطای درین سه خوشه‌ی مدل رگرسیون تلفیقی مربوط به خوشه‌ی دوم با مقدار ۵/۲۶ درصد است و پیشینه خطای در مدل رگرسیون تلفیقی بدون استفاده از PCA نیز مربوط به خوشه‌ی دوم بوده و برابر با ۷/۶۳ درصد است. بنابراین نتیجه می‌گیریم که به طور کلی بالاتر بودن معیارهای پیشینه در خوشه‌ی سوم نقطه‌ضعف مدل پیشنهادی نیست. در ادامه برای نمایش میزان تأثیرگذاری خوشبندی ماه‌های سال در بهبود پیش‌بینی اوج بار ماه بعد، در شکل ۹ نمودارهای مقادیر واقعی و پیش‌بینی شده اوج بار ماهانه طی سال‌های ۱۳۸۲ تا ۱۳۸۴ (سال‌های مورد استفاده برای اعتبارسنجی مدل) در دو حالت پس از انجام خوشبندی و بدون انجام خوشبندی با یکدیگر مقایسه می‌شوند.

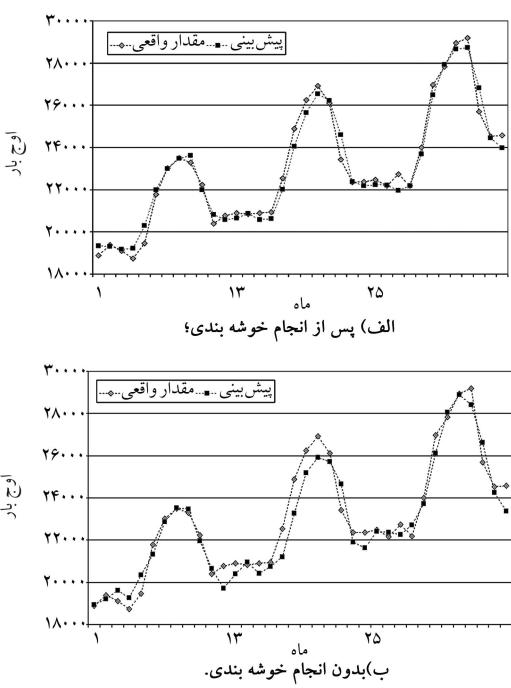


شکل ۸. تحلیل باقی مانده‌ها در دو حالت.

خطی باشد (خطی در درصد، نه در قدرمطلق خطای $MAPE$)، برای سنجش میزان خطای کافی خواهد بود – اگرچه مطالعات اخیر و تجربه‌ی اپراتورهای سیستم نشان می‌دهد که تابع خسارت در مسئله‌ی پیش‌بینی بار بموضع غیرخطی است و در ضمن خطاهای بزرگ ممکن است اثرات خطرازکی برای استفاده‌ی همگانی داشته باشد. به همین دلیل است که اندازه‌گیری مبتتنی بر مربعات خطای توصیه می‌شود، چون آنها خطاهای بزرگ را بیشتر جرمیه می‌کنند.^[۱]

جدول ۲. نتایج حاصل از پیش‌بینی با استفاده از مدل رگرسیون تلفیقی و مقایسه آن با حالت بدون استفاده از PCA.

خواشیده	معیار عملکرد	مدل رگرسیون تلفیقی PCA	مدل رگرسیون تلفیقی بدون استفاده از PCA
خوشیده ۱	MAE	۲۳۵,۵	۲۹۰,۴
	MAPE	۱/۱۱	۱/۳۸
	MSE	۸۶۹۶۰	۱۲۵۹۳۹
	MAXAE	۸۱۰,۲	۸۷۵,۹
	MAXAPE	۳,۵۶	۳,۸۵
	MAXSE	۶۵۶۴۳۷	۷۶۷۱۵۷
	R	۰,۹۸۷	۰,۹۷۹
	MAE	۶۹۱,۴	۸۶۱,۵
	MAPE	۳,۰۷	۳,۶۶
	MSE	۵۷۲۸۱۸	۱۱۶۷۰۵۵
خوشیده ۲	MAXAE	۱۰۸۰,۲	۱۹۶۰,۹
	MAXAPE	۵,۲۶	۷,۶۳
	MAXSE	۱۱۶۶۹۰۰	۳۸۴۵۲۴۴
	R	۰,۹۳۶	۰,۹۳۳
	MAE	۴۲۲,۹	۴۳۸,۳
	MAPE	۱,۶۵	۱,۶۹
	MSE	۲۳۲۲۸۵	۲۵۴۶۸۰
	MAXAE	۹۴۳,۳	۹۳۱,۸
	MAXAPE	۳,۷۹	۳,۳۵
	MAXSE	۸۸۹۸۷۰	۸۶۸۱۷۸
خوشیده ۳	R	۰,۹۸۸	۰,۹۷۷
	MAE	۱۶۰,۳	۳۷۴,۳
	MAPE	۲,۳۴	۱,۶۲
	MSE	۴۶۴۱۰,۸	۲۱۶۴۱۲
	MAXAE	۱۶۰,۸,۴	۱۰,۸۰,۲
	MAXAPE	۶,۴۶	۵,۲۶
	MAXSE	۲۵۸۶۹۱۸	۱۱۶۶۹۰۰
	R	۰,۹۷۳	۰,۹۸۷
	MAE	۱۶۰,۳	۳۷۴,۳
	MAPE	۲,۳۴	۱,۶۲



شکل ۹. نمودار مقایسه مقادیر واقعی و پیش‌بینی شده اوج بار ماهانه طی سال‌های ۱۳۸۲-۱۳۸۴ در دو حالت.

جدول ۳. نتایج کلی عملکرد دو حالت پیش‌بینی.

مدل رگرسیون	مدل رگرسیون تلفیقی	مدل پیش‌بینی	معیار عملکرد
۵۴۳,۳	۳۷۴,۳	MAE	
۲,۳۴	۱,۶۲	MAPE	
۴۶۴۱۰,۸	۲۱۶۴۱۲	MSE	
۱۶۰,۸,۴	۱۰,۸۰,۲	MAXAE	
۶,۴۶	۵,۲۶	MAXAPE	
۲۵۸۶۹۱۸	۱۱۶۶۹۰۰	MAXSE	
۰,۹۷۳	۰,۹۸۷	R	

را با خطای معادل ۱,۶۲ درصد خطأ انجام دهد و در هر پیش‌بینی حدود ۳۷۴,۳ مگاوات خطا وجود دارد. این درحالی است که با بهکارگیری مدل رگرسیون بدون استفاده از خوشبندی می‌توان به طور متوسط اوج بار مصرفی ماه بعد را با خطای معادل ۲,۳۴ درصد پیش‌بینی کرد؛ در هر پیش‌بینی حدود ۵۴۳,۳ مگاوات خطا وجود دارد. این مقایسه نشان می‌دهد که خوشبندی ماه‌های سال با بهبود برازش رگرسیونی موجب کاهش خطای پیش‌بینی به میزان قابل توجهی شده است.

۶. نتیجه‌گیری

در این نوشتار یک مدل رگرسیون تلفیقی برای پیش‌بینی اوج بار ماه بعد ارائه شد. در این تحقیق، ابتدا از یک نقشه خودسازمان ده برای تعیین بهترین خوشبندی بهمنظر تقسیم‌بندی ماه‌های سال براساس دو فاکتور اوج بار مصرفی ماهانه و میانگین وزنی متوسط دمای هوای ماهانه سه شهر تهران، تبریز و اهواز استفاده شد. بدلیل اختلاف

مقایسه‌ی دو نمودار الف و ب در شکل ۹ بیان‌گر این نکته است که در نمودار الف (یعنی پس از استفاده از خوشبندی) تطابق بیشتری بین مقادیر واقعی و پیش‌بینی شده‌ی اوج بار ماهانه نسبت به نمودار ب وجود دارد. این نکته مؤید بهبود نتایج پیش‌بینی با استفاده از مدل ارائه شده است.

همچنین، بهمنظور مقایسه‌ی نتایج حاصل از مدل رگرسیون تلفیقی و مدل رگرسیون بدون استفاده از خوشبندی، میانگین وزنی نتایج حاصله برای هر یک از سه خوشبنده شده است. برای این کار، و بهمنظور محاسبه‌ی میانگین مقادیر حاصله برای سه معیار عملکرد اول بر حسب تعداد نمونه‌های موجود در هر خوشبندی، یک ضریب وزنی مطابق رابطه زیر در نظر گرفته شده است:

$$\text{میانگین سه خوشبندی} = 18 * \text{مقدار معیار عملکرد خوشبندی اول} + 6 * \text{مقدار معیار عملکرد خوشبندی دوم} + 12 * \text{مقدار معیار عملکرد خوشبندی سوم}.$$

از طرف دیگر، برای سه معیار عملکرد بعدی نیز بیشترین مقدارهای سه خوشبندی لحاظ شده است. یادآور می‌شود که، به عنوان مثال، ضریب وزنی ۱۸ از طریق ضرب مدت سه‌سال در شش‌ماهی که در خوشبنده ۱ قرار گرفته‌اند، قابل محاسبه می‌شود. در درخصوص خوشبندی‌های ۲ و ۳ نیز ضریب وزنی به همین ترتیب محاسبه می‌شود. در جدول ۳ نتایج حاصل از پیش‌بینی با و بدون استفاده از خوشبندی مقایسه شده است.

با توجه به جدول ۳، مدل رگرسیون تلفیقی می‌تواند به طور میانگین هر پیش‌بینی

روش رگرسیون برای پیش‌بینی اوج بار ماهانه هر یک از خوش‌ها به صورت جداگانه مورد استفاده قرار گرفت. با مقایسه نتایج حاصل از روش مدل رگرسیون تلفیقی و روش رگرسیون نتیجه می‌گیریم که خوش‌بندی ماه‌های سال با بهبود برازش رگرسیونی موجب کاهش خطای پیش‌بینی شده است.

مقیاس این دو فاکتور، از هنجارسازی داده‌ها پیش از آغاز عملیات خوش‌بندی استفاده شد. برای تعیین بهترین خوش‌بندی، با استفاده از شاخص دیویس - بولدن در نهایت سه خوش‌هه انتخاب شد. سپس برای کاهش ابعاد متغیرهای ورودی و بهبود نتایج پیش‌بینی روش PCA پیش از تعیین مدل رگرسیونی به کار گرفته شد. در ادامه،

پانوشت

1. principal component analysis
2. self-organizing map
3. artificial intelligence
4. artificial neural networks
5. multiplicative
6. additive
7. width of the neighborhood function
8. davies-bouldin index
9. spherical clusters
10. random order incremental training
11. feature maps
12. rotated component matrix
13. kaiser-meyer-olkin measure of sampling adequacy
14. residuals
15. mean absolute percentage error
16. loss function
17. mean absolute error
18. mean of square error

منابع

1. Hippert, H.S.; Pedreira, C.E., and Castro, S.R. "Neural networks for short-term load forecasting: a review and evaluation", *IEEE Transactions on Power Syst.* **16**(1), pp. 44-55 (2001).
2. Yalcinoz, T., and Eminoglu, U. "Short term and medium term power distribution load forecasting by neural networks", *Energy Conversion and Management*, **46**, pp. 1393-1405, (2005).
3. Kareem, Y.H., and Majeed, A.R. "Monthly peak-load demand forecasting for sulaimany governorate using SARIMA", *IEEE*, pp. 1-5 (2006).
4. Phimphachan, S.; Chamnonglhai, K.; Kumhom, P.; Jittiwarangkul, N., and Sangswang, A. "Energy and peak load forecast models using neural network for fast developing area", International Symposium on Communications and Information Technologies, Sapporo. Japan, October 26-29 (2004).
5. Phimphachanh, S.; Chamnonglhai, K.; Kumhom, P., and Sangswang, A. "Using neural network for long term peak load forecasting in vientiane municipality", *IEEE*, pp. 319-322 (2004).
6. Temraz, H.K.; Salama, M.A., and Quintana, V.H., "Application of the decomposition technique for forecasting the load of a large electric power network", *IEE Proc. Cener. Transm. Distrib.*, **143**(1), (January 1996).
7. Oja, M.; Kaski, S., and Kohonen, T. "Bibliography of self-organizing map (SOM) papers: 1998-2001 addendum", *Neural Computing Surveys*, **3**, pp. 1-156, (2002).
8. Vesanto, J., and Alhoniemi, E. "Clustering of the self-organizing map", *IEEE Transactions on Neural Networks*, **11**(3), pp. 586-600 (2000).
9. Demuth, H., and Beale, M. MATLAB 6.5 / Neural Network Toolbox, version 4, The MathWorks, Inc.,(CD-ROM),1-840 (2002).
10. Bishop, C.M. *Neural Networks for Pattern Recognition*, First Edition, Oxford University Press (1995).
11. Gujarati, D. *Basic Econometrics*, Third edition, McGraw-Hill (1995).
12. Sharma, S. *Applied Multivariate Techniques*, First Edition, John Wiley & Sons, Inc. (1996).

