

روش مؤثر هوشمند به منظور پیش‌بینی بار الکتریکی کوتاه‌مدت

فاطمه ابراهیمی (کارشناس ارشد)

دانشکده فنی مهندسی، دانشگاه قم

امیر افسر (استادیار)

دانشکده مدیریت و اقتصاد، دانشگاه تربیت مدرس

جلال رضایی نور* (دانشیار)

دانشکده فنی مهندسی، دانشگاه قم

علی قبری سرخی (کارشناس ارشد)

دانشکده مهندسی کامپیوتر، دانشگاه صنعتی شاهرود

مهندسی صنایع و مدیریت شریف، تابستان ۱۳۹۶ (دوره ۱، شماره ۱/۲، ص ۴۳-۵۴)

در این نوشتار از روش‌های شبکه‌ی عصبی (NN)، ماشین بردار پشتیبانی (SVM) و تحلیل مؤلفه‌ی اصلی (PCA) با یک رویکرد متوالی برای پیش‌بینی بار کوتاه‌مدت استفاده شده است. ابتدا با استفاده از یک روش غربال‌سازی، داده‌های ورودی استخراج و به کلاس‌هایی تقسیم شدند که بتواند بهترین نتایج را ارائه دهد. سپس مقادیر گذشته بار به همراه اطلاعات وابسته در هر دسته به شبکه‌های عصبی چندلایه‌ی پرسپترون و ماشین بردار پشتیبان به صورت پشت سر هم و وابسته به ساعت قبل داده شده است که ماشین بردار پشتیبان پیشنهادی توانست نتایج بهتری ارائه دهد. سپس با اعمال تحلیل مؤلفه‌ی اصلی به پارامترهای ورودی مجدداً این دو سیستم مورد آزمون قرار گرفت. نتایج نشان داد که هنگام استفاده از تحلیل مؤلفه‌ی اصلی نتایج شبکه‌های عصبی و ماشین‌های بردار پشتیبان بهبود یافته و نتایجی بهتر از پیش‌بینی‌های سنتی ارائه داده است.

fa_brahim85@yahoo.com
aafsar@modares.ac.ir
j.rezaee@qom.ac.ir
ali.ghanbari289@gmail.com

واژگان کلیدی: پیش‌بینی بار الکتریکی، شبکه‌ی عصبی، ماشین بردار پشتیبان، تحلیل مؤلفه‌ی اصلی.

۱. مقدمه

به دلیل اهمیت مسئله‌ی پیش‌بینی بار الکتریکی کوتاه‌مدت، مدل‌های مختلفی به منظور به دست آوردن دقت بالاتر به کار گرفته شده است. روش‌های مختلفی برای پیش‌بینی متغیرهای سری زمانی معرفی شده‌اند. به طور کلی می‌توان این مدل‌ها را به دو دسته سنتی و نوین تقسیم کرد.^[۱] در مدل‌های سنتی روش‌های سری زمانی، رگرسیون، کالمن فیلتر، باکس جنکینز و... در روش‌های نوین نیز استفاده از الگوریتم‌های هوش مصنوعی نظیر شبکه‌ی عصبی، ماشین بردار پشتیبان، منطق فازی به همراه الگوریتم‌های تکاملی نظیر پرندگان، ژنتیک، مورچگان و... را می‌توان نام برد.

رس و همکاران از رگرسیون چندمتغیره برای پیش‌بینی بار استفاده کرده‌اند. آن‌ها از مقدار بار در زمان حال و دو ساعت گذشته، دما در زمان حال و دو ساعت گذشته، باد در زمان حال و دو ساعت گذشته، ابر در زمان حال و دو ساعت گذشته در مدل رگرسیون خود استفاده کردند.^[۵] دانگ و همکارانش از سری زمانی برای پیش‌بینی بار الکتریکی کوتاه‌مدت در سنگاپور استفاده کرده و دو مدل سری زمانی به نام‌های تجزیه‌ی چندگانه و مدل ARIMA فصلی پیشنهاد داده‌اند. خطای پیش‌بینی هر دو مدل از سری زمانی محاسبه و مقایسه شد و نتایج حاصله نشان داد که مدل سری

پیش‌بینی کوتاه‌مدت، میان‌مدت و بلندمدت تقاضای بار الکتریکی برای عملکرد صحیح سیستم‌های قدرت به کار می‌رود. پیش‌بینی‌ها برای فعالیت‌های مربوط به برنامه‌ریزی‌های تولید، خرید سوخت، نگه‌داری، سرمایه‌گذاری و تحلیل‌های امنیتی مورد استفاده قرار می‌گیرد.^[۱] پیش‌بینی تقاضای برق در مقاطع بلندمدت برای یافتن نیازهای آتی به منظور توسعه‌ی نیروگاه‌های کشور و همچنین پیش‌بینی کوتاه‌مدت برای تنظیم میزان مصرف برق در بخش‌های مختلف پرمصرف و کم‌مصرف ضروری است. پیش‌بینی کوتاه‌مدت نقشی کلیدی در عملیات اقتصادی و امنیتی سیستم‌های قدرت دارد.^[۲] پیش‌بینی بار در سیستم قدرت به طور معمول تقسیم می‌شود به:^[۳]

- پیش‌بینی‌های بسیار کوتاه‌مدت برای چند دقیقه‌ی بعد؛
- پیش‌بینی کوتاه‌مدت برای چند روز آتی؛
- پیش‌بینی میان‌مدت برای ۶ ماه تا یک سال آینده؛
- پیش‌بینی بلندمدت برای ده سال آینده.

* نویسنده مسئول

تاریخ دریافت: ۱۳۹۳/۸/۱۰، اصلاحیه ۱۳۹۴/۶/۲۵، پذیرش ۱۳۹۴/۷/۱۱.

زمانی می‌تواند به دقت تقاضا را پیش‌بینی کند در حالی که مدل تجزیه‌ی چندگانه کمی بهتر از ARIMA فصلی عمل کرده است.^[۶]

در دهه‌ی اخیر، بسیاری از محققین از تکنیک هوش مصنوعی به منظور بهبود در دقت پیش‌بینی بار استفاده کردند. سیستم‌های هوشمند مبتنی بر دانش (KBES)^۱ و شبکه‌های عصبی از نمونه‌های مشهورند. اخیراً کار بردهایی از سیستم استنتاج فازی و نظریه‌ی فازی در این زمینه مورد توجه قرار گرفته است.^[۷] پارک و همکاران^[۸] یک شبکه‌ی عصبی سه‌لایه‌ی پس‌انتشار برای مسئله‌ی پیش‌بینی بار الکتریکی روزانه پیشنهاد داده‌اند. ورودی شبکه‌ی عصبی شامل سه شاخص متوسط، پایین‌ترین و بالاترین مقدار بار الکتریکی بوده است و خروجی آن نیز بالاترین مقدار بار الکتریکی بوده است. مدل پیشنهادی او بسیار بهتر از مدل‌های رگرسیونی و سری زمانی عمل کرده است. نوک^[۹] از شبکه‌ی عصبی شعاعی پایه (RBF) برای پیش‌بینی بار الکتریکی استفاده کرده و نشان داده است که RBF حداقل ۱۱ برابر سریع‌تر و قابل اطمینان‌تر از شبکه‌ی عصبی پس‌انتشار بوده است. داربلی و اسلاما^[۱۰] از شبکه‌ی عصبی برای پیش‌بینی بار الکتریکی در Czech استفاده کرده و نشان داده است که مدل پیشنهادی شبکه‌ی عصبی از مدل ARIMA بهتر عمل کرده است. عبدال^[۱۱] شبکه‌ی عصبی پیشنهاد داده است که پیش‌بینی بار یک ساعت آینده را برای پنج سال انجام داده است؛ او دمای ساعتی و بار ساعتی را در نظر گرفته و نتایج مدل پیشنهادی بسیار امیدبخش بوده است. هسیو و چان^[۱۲] مدل شبکه‌ی عصبی را برای پیش‌بینی بار منطقه‌ی تایوان به کار بردند و نشان دادند که مدل پیشنهادی برتر از مدل رگرسیون سنتی است. در تحقیقی که توسط آزاده و همکاران انجام شد، با استفاده از روش‌های ANN و ANFIS تقاضای گاز در ایران پیش‌بینی شد که ANFIS توانست نتایج بهتری نسبت به ANN داشته باشد.^[۱۳]

اخیراً کار بردهایی از مدل شبکه‌ی عصبی با ترکیبی از متدهای آماری و سایر روش‌های هوشمند بسیار مورد توجه قرار گرفته است. مانند ترکیبی از استنتاجات بیزین،^[۱۴] انتقالات موجی،^[۱۵] بهینه‌سازی ازدحام ذرات^[۱۶] و غیره.

الگوریتم هوشمند دیگری که مورد توجه قرار گرفته است، ماشین بردار پشتیبان (SVM) است. در روش SVM از اصول کمینه‌سازی ریسک ساختاری (SRM) استفاده شده است، در حالی که سایر روش‌ها از اصول کمینه‌سازی ریسک تجربی (ERM) بهره می‌برند. ثابت شده است که اصول SRM در مقایسه با ERM عملکرد بهتری از خود نشان می‌دهند.^[۱۷] کائو^[۱۸] از روش SVM برای پیش‌بینی‌های سری زمانی استفاده کرده است. چن و همکاران^[۱۹] در پیش‌بینی بار الکتریکی میان‌مدت توسط SVM پیشگام بوده‌اند. آن‌ها به صورت جزئی بیان کردند که چگونه SVM می‌تواند در پیش‌بینی بار الکتریکی موفق عمل کند. پای و هانگ^[۲۰] نیز از ترکیبی از SVR و الگوریتم شبیه‌سازی تیرید (SA) به منظور پیش‌بینی بار بلندمدت در تایوان استفاده کردند. آنها از الگوریتم SA به منظور تشخیص پارامترها استفاده کردند و نشان دادند که این مدل از ARIMA و GRNN عملکرد بهتری دارد. در جدول ۱ نمونه‌هایی از مقالاتی که در آنها از روش‌های NN و SVM برای پیش‌بینی بار استفاده شده، به همراه متغیرهای مورد استفاده ارائه شده است.

با توجه به اهمیت پیش‌بینی بار الکتریکی کوتاه‌مدت که پیش‌تر بیان شد و نیز تاریخچه‌ی ذکر شده در ارتباط با دستاوردهای مربوط به پیش‌بینی بار الکتریکی، در این پژوهش سعی شده تا با استفاده از روش‌های نوین، به منظور پیش‌بینی بار الکتریکی در یکی از مناطق ایران، بهینه‌سازی در پیش‌بینی‌های سنتی انجام شود. از نوآوری‌های مهم این تحقیق می‌توان به ارائه‌ی روش‌های جدید و منطقی برای پیش‌بینی میزان مصرف انرژی الکتریکی کوتاه‌مدت اشاره کرد که ترکیبی از روش شبکه‌ی عصبی و ماشین بردار پشتیبان با روش کاهش ابعاد یعنی تحلیل مؤلفه‌ی

اصلی است. در بعضی وضعیت‌ها ابعاد بردار ورودی بسیار بزرگ است اما اجزای بردارها همبستگی بالایی دارند. مفید است که در این وضعیت ابعاد بردار ورودی را کاهش دهیم. یک رویه‌ی مناسب برای این عمل استفاده از تحلیل مؤلفه‌ی اصلی است که در این پژوهش از آن استفاده شده است. همچنین می‌توان به انتخاب متغیرهای تأثیرگذار و دسته‌بندی‌های مربوطه در طراحی مدل که با دقت بسیار انجام شده اشاره کرد.

در این مطالعه ابتدا داده‌های مربوط به بار الکتریکی مصرفی در منطقه شمال ایران بررسی و تحلیل می‌شود. با توجه به بررسی مقالات مختلف و حضور افراد خبره در سازمان توزیع برق، عوامل مؤثر در میزان مصرف شناسایی می‌شود. سپس از بین آن‌ها مهم‌ترین عوامل انتخاب می‌شود و داده‌ها به دسته‌های مختلفی تقسیم می‌شود. هر یک از دسته‌ها به طور مجزا با استفاده از شبکه‌های عصبی و ماشین‌های بردار پشتیبان مورد آموزش و آزمون قرار گرفته تا کارایی استفاده از آن‌ها روی داده‌های مورد نظر مشاهده شود. سپس به دلیل ازدیاد تعداد متغیرهای ورودی، با تحلیل مؤلفه‌ی اصلی به داده‌های ورودی از تعداد آن‌ها کاسته و مجدداً با این دو سیستم هوشمند مورد آزمون قرار می‌گیرند تا مشاهده شود که آیا با کاهش ابعاد می‌توان به نتایج مطلوب‌تری دست یافت یا خیر. در ادامه به عوامل مؤثر بر پیش‌بینی بار کوتاه‌مدت و تحلیل داده‌ها و سپس به تشریح دستاورد پیشنهادی و در انتها نیز به ارزیابی نتایج حاصله و نتیجه‌گیری نهایی پرداخته می‌شود.

۲. عوامل مؤثر بر پیش‌بینی بار کوتاه‌مدت

بار مصرفی به عوامل مختلفی همچون مقادیر گذشته بار، متغیرهای آب‌وهوایی (نظیر دما، ابری بودن آسمان، گردوغبار، روشنایی هوا، سرعت باد، رطوبت و خشکی هوا)، شرایط جغرافیایی، مسائل فرهنگی، اجتماعی، سیاسی، اقتصادی، زمان، سطح زندگی مردم و حوادث ناخواسته مثل کودتا، جنگ، سیل، زلزله، طوفان،... و نیز به روزهای هفته و ساعت کاری بستگی دارد. متغیرهای ورودی به منظور پیش‌بینی بار الکتریکی را می‌توان به ۸ دسته تقسیم کرد:^[۳۵]

۱. بار مصرفی گذشته؛
۲. دمای گذشته و آینده؛
۳. ساعت - روز مشخص شده؛
۴. روز - هفته‌ی مشخص شده؛
۵. سرعت باد؛
۶. پوشش ابر؛
۷. بارش باران؛
۸. رطوبت یا خشکی هوا.

هیچ قاعده کلی وجود ندارد که بتوان با توجه به آن، متغیرهای ورودی را انتخاب کرد. این انتخاب فقط با قضاوت مهندسی و به‌کارگیری تجربه صورت می‌گیرد. براساس تحقیقات انجام شده چهار دسته‌ی اول برای به دست آوردن نتایج مناسب کافی است. هرچند که برای مناطقی با شرایط آب‌وهوایی ویژه چهار کلاس باقی نیز ممکن است تأثیرگذار باشد.^[۳۵]


در تحقیقات متفاوت با توجه به شرایط مکانی و آب و هوایی متفاوت، ترکیبی از پارامترهای متفاوت به منظور پیش‌بینی استفاده شده است. از آنجا که پیش‌بینی مورد

جدول ۱. نمونه‌هایی از کارهای انجام شده به منظور پیش‌بینی بار الکتریکی.


متغیرهای ورودی	الگوریتم‌های مورد استفاده	سال	شماره مرجع
<ul style="list-style-type: none"> -- بار الکتریکی یک، دو، سه ساعت گذشته همان روز -- بار الکتریکی یک، دو، سه ساعت گذشته روز گذشته -- بار الکتریکی همان ساعت، یک ساعت قبل و دو ساعت قبل همان روز در هفته گذشته 	GA NN, BBNN, PSO NN	۲۰۰۸	[۲۳]
<ul style="list-style-type: none"> -- شاخص ساعت -- شاخص روز -- تخمین دمای یک ساعت و دو ساعت قبل -- در کل ۳۲ ورودی زیرا دمای هوا در ۱۰ نقطه‌ی مختلف اندازه‌گیری می‌شود 	MLP NN	۲۰۰۶	[۲۴]
<ul style="list-style-type: none"> -- بار الکتریکی ۲۴ ساعت گذشته -- دما، رطوبت، سرعت باد -- فصل (ماه) روز هفته 	MLP NN	۲۰۰۷	[۲۵]
<ul style="list-style-type: none"> -- بار الکتریکی ۲۴ ساعت قبل -- روز هفته -- ساعت روز 	SVM	۲۰۱۰	[۲۶]
<ul style="list-style-type: none"> -- داده‌های آب و هوا -- داده‌های بار الکتریکی 	GA - SVM	۲۰۰۸	[۲۷]
<ul style="list-style-type: none"> -- دمای روز قبل (بیشینه، کمینه، متوسط) -- میزان بارش روز قبل -- بار دو لحظه قبل زمان پیش‌بینی در روز گذشته -- بیشینه و کمینه باریک روز قبل -- بار دو لحظه قبل زمان پیش‌بینی در روز پیش‌بینی -- دمای روز پیش‌بینی (بیشینه، کمینه، متوسط) -- میزان بارش روز پیش‌بینی -- نوع روز پیش‌بینی 	TS*, BPNN, SVM	۲۰۱۰	[۲۸]
<ul style="list-style-type: none"> -- بار الکتریکی هر نیم ساعت ۲۴ ساعت قبل -- متوسط دمای روز قبل -- پیش‌بینی متوسط دمای روز آینده -- روز هفته مورد پیش‌بینی 	SVM	۲۰۰۹	[۲۹]
<ul style="list-style-type: none"> -- بار الکتریکی گذشته -- نوع فصل، نوع روز، ساعت روز -- دمای روز قبل و دمای پیش‌بینی روز مورد نظر (۱۲۰ و ورودی) 	BPNN with GA	۲۰۱۰	[۳۰]
<ul style="list-style-type: none"> -- بار الکتریکی، نوع روز، دم، قیمت لحظه‌ی روز گذشته -- نوع روز، دما، قیمت لحظه‌ی روز پیش‌بینی (۱۰۰ و ورودی) 	FFNN	۲۰۰۱	[۳۱]
<ul style="list-style-type: none"> -- بارهای مصرفی در زمان تعیین شده -- دمای پیش‌بینی -- شاخص ماه 	NN	۲۰۰۵	[۳۲]
<ul style="list-style-type: none"> -- شاخص مربوط به تعطیلات آخر هفته و تعطیلات دیگر -- سرعت و جهت باد این ساعت در روز قبل -- دمای هوا این ساعت در روز قبل -- تابش خورشید روز قبل -- بار واقعی این ساعت در روز قبل -- دمای پیش‌بینی روز بعد در این ساعت 	Beysian NN	۲۰۰۸	[۳۳]

* Time Series Analysis

متغیرهای ورودی	الگوریتم‌های مورد استفاده	سال	شماره مرجع
<p>— پیک بار روز گذشته</p> <p>— دمای روز گذشته (بیشینه، کمینه، متوسط)</p> <p>— رطوبت روز گذشته (بیشینه، کمینه، متوسط)</p> <p>— سرعت باد در روز گذشته (بیشینه)</p> <p>— پیک بار هفته گذشته</p> <p>— دمای هفته گذشته (بیشینه، کمینه، متوسط)</p> <p>— رطوبت هفته گذشته (بیشینه، کمینه، متوسط)</p> <p>— سرعت باد هفته گذشته</p> <p>— دمای روز پیش‌بینی</p> <p>— رطوبت مربوط به روز گذشته (بیشینه، کمینه، متوسط)</p> <p>— سرعت باد مربوط به روز گذشته (بیشینه)</p> <p>— شاخص روز</p>	<p>NN with GA, PSO, constrained method, unconstrained method</p>	۲۰۰۸	[۳۴]



شکل ۱. نمودار مصرفی بار الکتریکی در روزهای کاری یکشنبه تا چهارشنبه.



شکل ۲. نمودار مصرفی بار الکتریکی در کلاس‌های مختلف.

چهارشنبه که در ایران روزهای کاری هفته است، تقریباً الگوی بار مشابهی دارند که در شکل ۱ قابل مشاهده است.

روز شنبه که به‌عنوان اولین روز کاری هفته محسوب می‌شود الگویی متفاوت با مابقی روزها دارد. تعطیل بودن قریب به اتفاق سازمان‌های خصوصی و بعضاً اداری در روز پنج‌شنبه نیز سبب تغییر روند الگوی مصرفی در این روز شده است. در نهایت روز جمعه، به‌عنوان یک روز تعطیل عادی، الگوی خاص خود را دارد. این الگوهای بار مصرفی در شکل ۲ نشان داده شده است.

یکی دیگر از عواملی که در منحنی مصرف تأثیرگذار است، ایام تعطیل است. با

نظر در این پژوهش در یکی از مناطق شمال ایران با شرایط آب‌وهوایی خاص انجام شده، سعی شد از ترکیب جدیدی از پارامترها استفاده شود و همچنین دسته‌بندی‌های داده‌ها به رده‌های متفاوت با ریزینی و دقت بالاتری انجام شود، به‌طوری که چنین دسته‌بندی و ترکیبی از پارامترهای انتخابی در مقالات پیشین مشاهده نشده است. پارامترهایی همچون بار مصرفی گذشته و دمای ساعتی در هر یک از دسته‌بندی‌های در نظر گرفته شده است که در ادامه به نحوه دسته‌بندی این داده‌ها و نیز انتخاب دقیق پارامترها پرداخته می‌شود.

۳. تحلیل داده‌ها

با توجه به عوامل تأثیرگذار ذکرشده، در این مطالعه از اطلاعات انرژی مصرفی الکتریکی گذشته طی سال‌های ۸۹ تا ۹۰ موجود در سازمان توزیع برق مازندران و همچنین مقدار ساعتی دما در هر روز مربوطه استفاده شده است. داده‌ها را پس از جمع‌آوری باید ابتدا به‌روشنی تحلیل کرد و پویایی‌شان را تشخیص داد تا بتوان آنها را به مجموعه‌های کوچک‌تری براساس ویژگی‌های مشترک‌شان تقسیم‌بندی کرد و مدلی جداگانه برای هر یک ساخت.

در بسیاری از منابع تأکید شده است که رفتارهای متفاوت بار الکتریکی را با یک مدل نمی‌توان نشان داد.^[۳۰] در این پژوهش نیز برای اطمینان از این موضوع ابتدا یک بار بدون انجام دسته‌بندی خاصی بر داده‌ها، پیش‌بینی صورت گرفت ولی جواب مساعدی حاصل نشد. به‌همین دلیل بررسی‌های بیشتری روی داده‌ها انجام شد که نتایج حاصله عبارت است از:

- با توجه به این که تغییر فصل‌ها تغییرات چشمگیری در روند مصرف برق می‌گذارد، سعی شده ابتدا یک دسته‌بندی براساس چهار فصل بهار، تابستان، پاییز، زمستان صورت گیرد.
- هر روز هفته منحنی خاص خود را دارد اگرچه، منحنی‌های بار روزهای یکشنبه تا چهارشنبه از مشابهت نسبی برخوردارند و منحنی‌های مصرف بار در روزهای تعطیل متمایزند. همچنین منحنی مصرف بار در روزهای قبل و بعد از روزهای تعطیل از روزهای عادی هفته متمایز است. به‌عبارت دیگر روزهای یکشنبه تا

توجه به این که ایران دو نوع تعطیلی ملی و مذهبی دارد، هردو نوع تعطیلی باید مورد توجه قرار گیرد.

با توجه به موارد ذکر شده برای هر فصل چهار دسته‌ی متفاوت «جمعه»، «شنبه»، «یکشنبه تا چهارشنبه» و «پنج‌شنبه» در نظر گرفته شده است.

۴. مدل پیشنهادی

سیستم پیشنهادی در این تحقیق مبتنی است بر روش‌های شبکه‌ی عصبی، ماشین بردار پشتیبان و تحلیل مؤلفه‌ی اصلی، که در آن به دلیل وابستگی بین مصرف ساعتی داده‌ها از یک روش بازگشتی استفاده شده است؛ داده‌های ساعت قبل نیز خود یک پارامتر ورودی هستند. بدین ترتیب پس از تحلیل داده‌ها و دسته‌بندی آنها در کلاس‌های مختلف، متغیرهای ورودی برای هر کلاس انتخاب می‌شود. پس از نرمال کردن تمام متغیرها در محدوده‌ی مورد نظر به منظور پیش‌بینی بار الکتریکی کوتاه‌مدت، توسط شبکه‌ی عصبی و ماشین بردار پشتیبانی آموزش داده می‌شود و مطلوبیت نتایج حاصل از هر یک مورد بررسی قرار می‌گیرد. سپس با تجزیه و تحلیل مؤلفه‌ی اصلی متغیرهای ورودی، ویژگی‌های بی‌ارزش حذف می‌شود و مجدداً توسط شبکه‌های عصبی و ماشین‌های بردار پشتیبان مورد آموزش و آزمون قرار می‌گیرد. نتایج حاصل از اعمال PCA بر متغیرهای ورودی و سپس آموزش توسط شبکه‌ی عصبی و ماشین بردار پشتیبان با نتایج قبلی مورد مقایسه قرار می‌گیرد تا تأثیر تحلیل مؤلفه‌ی اصلی بر داده‌ها مشاهده شود. این نکته بسیار مهم است که پیش‌بینی به صورت ساعتی برای ۴۸ ساعت به صورت جداگانه است.

۱.۴. انتخاب پارامترها و متغیرهای ورودی

مهم‌ترین اقدام در ساخت شبکه‌ی عصبی به منظور پیش‌بینی بار انتخاب متغیرهای ورودی است. هیچ قاعده‌ی کلی وجود ندارد که بتوان از آن پیروی کرد بلکه با قضاوت مهندسی و عامل تجربه، انتخاب متغیرها با آزمون و خطا انجام می‌گیرد. هرچند برخی از تحلیل‌های آماری در تشخیص این که کدامیک از متغیرها تأثیر مهمتری بر سیستم بار دارند^[۲۲] می‌تواند مؤثر باشد. با بررسی‌های صورت گرفته، از بین عوامل تأثیرگذار دو عامل بار مصرفی گذشته و متغیرهای آب‌وهوا مورد استفاده قرار گرفته است.^[۱۳] از بین متغیرهای آب و هوا تنها از متغیر دما استفاده شده است. با توجه به این که دما تأثیر چشمگیری در روند مصرفی به خصوص در منطقه‌ی شمالی کشور دارد و از طرفی پیش‌بینی به صورت ساعتی است، به نظر می‌رسد استفاده از پارامتر دما به صورت ساعتی یا با فواصل زمانی نزدیک‌تر به جواب بهتری خواهد رسید. به همین دلیل از اطلاعات استخراج شده از سازمان هواشناسی استان مازندران به صورت ساعتی استفاده شده است. جزئیات مربوط به متغیرهای ورودی عبارت است از:

الف) متغیرهای ورودی برای روزهای یکشنبه تا چهارشنبه به صورت ساعتی (۱۳ ورودی)

- اطلاعات بار مصرفی و دما به صورت ساعتی روز قبل و ماه قبل (۲ ورودی) باید اشاره کرد که با توجه به نیاز سازمان‌های توزیع برق به لزوم پیش‌بینی دو روز قبل از مصرف بار، در این سیستم برای شبیه‌سازی دنیای واقعی از اطلاعات مصرفی دو روز قبل به صورت ساعتی استفاده شده است. (در واقع اطلاعات روز قبل موجود نیست.) برای ماه قبل از اطلاعات روز پیش‌بینی در ماه قبل استفاده شده است.

- میزان مصرف ساعتی بار الکتریکی و دما مربوط به دو و سه روز گذشته و همان روز در هفته قبل (۶ ورودی)

- مقدار بار مصرفی و دما مربوط به سال گذشته معادل با روز پیش‌بینی (۲ ورودی)

- بار مصرفی و دمای مربوط به ساعت قبل (۲ ورودی)
- در ساعت اول پیش‌بینی از اطلاعات واقعی استفاده شده است ولی در ساعت‌های بعدی اطلاعات پیش‌بینی شده در ساعت قبل به عنوان ورودی برای ساعت بعد در نظر گرفته می‌شود.

- مقدار دما ساعتی در روز پیش‌بینی (۱۱ ورودی)

ب) متغیرهای ورودی برای روز پنج‌شنبه، جمعه، شنبه (۱۱ ورودی)

- میزان مصرف ساعتی بار الکتریکی و دما مربوط به دو روز گذشته (۴ ورودی)
- میزان مصرف ساعتی بار الکتریکی و دما مربوط به روز پیش‌بینی در هفته گذشته و دو روز قبل از آن (۴ ورودی)

- بار مصرفی و دمای مربوط به ساعت قبل (۲ ورودی)

- مقدار دما مربوط به روز پیش‌بینی به صورت ساعتی (۱۱ ورودی)

ج) متغیرهای ورودی برای تعطیلات خاص (۹ ورودی)

- میزان مصرف ساعتی بار الکتریکی و دما مربوط به دو روز گذشته (۴ ورودی)
- میزان مصرف ساعتی بار الکتریکی و دما مربوط به جمعه گذشته و همین روز در سال گذشته (۴ ورودی)


- مقدار دما ساعتی مربوط به روز پیش‌بینی (۱۱ ورودی)

برای متغیرهای خروجی، ۴۸ خروجی به منظور پیش‌بینی ساعتی در ۴۸ ساعت آینده در نظر گرفته شده است. پیش‌بینی برای هر ساعت به صورت جداگانه انجام می‌شود.


در شکل ۳ شمای کلی سیستم پیشنهادی نمایش داده شده است.^[۲۴] به صورت پشت سر هم ۴۸ سیستم پیش‌بینی اجرا می‌شود و خروجی سیستم قبلی ورودی سیستم بعدی است؛ فقط سیستم اول از اطلاعات واقعی مربوط به روز گذشته که موجود است استفاده می‌کند. هرکدام از این سیستم‌ها بیانگر یک شبکه‌ی عصبی یا SVR است که هرکدام یکی از خروجی‌ها را پیش‌بینی می‌کند؛ به عبارت دیگر از ۴۸ شبکه‌ی عصبی استفاده شده است که بین ۹ تا ۱۳ ورودی قبل از اعمال PCA و ۶ تا ۷ ورودی بعد از اعمال PCA دارد و نیز دارای یک خروجی است.

۲.۴. نرمال‌سازی داده‌ها

یکی از مسائلی که در فرایند پیش‌بینی این پروژه به آن توجه شده، مسئله‌ی نرمال کردن داده‌ها در بازه [۰, ۱] است. این امر به دو دلیل ضروری است: ۱. همه‌ی ورودی‌ها به وزن یکسان نیاز دارند؛ اگر ورودی دارای دو نورو با بازه‌های مختلف باشد، نورو دارای بازه عددی بزرگ‌تر در طی آموزش غلبه می‌کند. ۲. به دلیل توابع انتقال مورد استفاده، هم تابع سیگموئید و هم تابع تانژانت هایپربولیک در بازه‌ی با مقدار محدود عمل می‌کند. هر نورو خروجی‌هایی تولید می‌کند که قدرمطلق آنها کم‌تر از ۱ باشد. اگر داده‌هایی که در شبکه مورد استفاده قرار می‌گیرد در بازه مورد نظر مقیاس‌بندی نشده باشد، شبکه همگرا نخواهد شد یا نتیجه‌ی حاصله معنی‌دار نخواهد بود. پس از مرتب‌سازی داده‌ها به صورت مورد نظر، تمام انواع داده در بازه مورد نظر نرمال شد تا محاسبات راحت‌تر شود.



الف) نمودار مقدار ویژگی برای مجموعه داده روزهای یکشنبه تا چهارشنبه؛



ب) نمودار مقدار ویژگی برای مجموعه داده روزهای شنبه، پنج شنبه و جمعه.

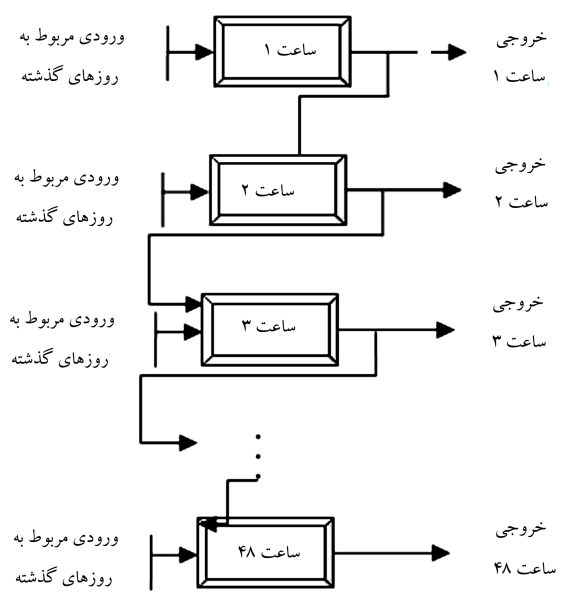
شکل ۴. نمودار scree plot مقدار ویژگی حاصل از روش PCA.

روی مجموعه داده نشان داده شده، که با توجه به نقطه‌ی مشخص شده این تعداد ویژگی مورد استفاده قرار گرفته‌اند.

همانطور که در شکل ۴ الف مشاهده می‌شود، از تعداد ۱۳ ویژگی معرفی شده در مجموعه داده روزهای یکشنبه تا چهارشنبه، ۷ ویژگی اول به عنوان ویژگی‌ها انتخاب شده توسط روش PCA و با استفاده از رابطه‌ی ۱ معرفی شده است. به طور مشابه شکل ۴ ب نشان می‌دهد که ۶ ویژگی اول از ۱۱ ویژگی معرفی شده از روزهای شنبه، پنج شنبه و جمعه انتخاب شده است. در مرحله‌ی جدید این ویژگی‌ها به عنوان ورودی به سیستم‌های پیش‌بینی معرفی می‌شوند.

۴.۴. استفاده از شبکه‌ی عصبی

برای پیش‌بینی میزان مصرف انرژی الکتریکی از رویکرد شبکه‌های عصبی چندلایه‌ی پیش‌خور که عموماً شبکه‌های چندلایه‌ی پرسپترون (MLP) نامیده می‌شود استفاده شده است. برای آموزش شبکه‌ی عصبی فوق از قانون یادگیری پس‌انتشار خطا (BP) استفاده شده است. این قانون از دو مسیر اصلی تشکیل می‌شود: مسیر اول به مسیر رفت موسوم است که در آن، بردار ورودی به شبکه‌ی MLP اعمال و تأثیراتش از طریق لایه‌های میانی به لایه‌های خروجی انتقال می‌یابد. بردار خروجی تشکیل یافته در لایه خروجی، پاسخ واقعی شبکه‌ی MLP را تشکیل می‌دهد. در این مسیر پارامترهای شبکه، ثابت و بدون تغییر در نظر گرفته می‌شود. مسیر دوم به مسیر برگشت موسوم است. در این مسیر، خلاف مسیر رفت، پارامترهای شبکه‌ی MLP تغییر و تنظیم می‌شود. این تنظیم مطابق با قانون اصلاح خطا انجام می‌گیرد. سیگنال خطا در لایه‌ی خروجی شبکه تشکیل می‌شود. بردار خطا برابر با اختلاف



شکل ۳. سیستم پیشنهادی برای پیش‌بینی بار مصرفی.

۳.۴. تحلیل مؤلفه‌های اصلی

به منظور عملکرد بهتر سیستم‌های هوشمند مورد نظر، می‌توان با استفاده از روش تحلیل مؤلفه‌های اصلی، تعداد ورودی‌ها را کاهش داد تا بتوان مدل قوی‌تری طراحی کرد. [۳۷] به زعم اسپیرمن [۳۸] هدف از تحلیل مؤلفه‌های اصلی، بررسی یک حوزه برای کشف ابعاد یا سازه‌های اصلی آن حوزه است. هدف بیشتر مطالعات تحلیل مؤلفه‌های اصلی، خلاصه کردن ماتریس همبستگی هاست به شیوه‌ی که بتوان آن‌ها را برحسب چند عامل زیربنایی تبیین کرد. اگر تمام مؤلفه‌های اصلی ماتریس را استخراج کنیم، می‌توانیم همبستگی‌های بین متغیرها را به طور کامل ایجاد کنیم. با وجود این، چنین کاری ساده‌سازی تلقی نمی‌شود زیرا به تعداد متغیرها مؤلفه وجود دارد. البته در عمل فقط چند مؤلفه که بیشترین مقدار واریانس را تبیین می‌کنند استخراج می‌شود؛ این مؤلفه‌ها باید بتوانند به تفکیک همبستگی‌ها را تبیین کنند. [۳۹]

از آنجا که روش تجزیه و تحلیل مؤلفه‌های اصلی یک روش وزن‌دهی به ویژگی‌ها براساس اهمیت آنهاست، تصمیم گرفته شده با اعمال PCA به ورودی براساس ارزش آنها، تعداد ابعاد ورودی نیز کاهش یابد. در واقع با این کار ویژگی‌های کم اهمیت‌تر حذف شده که علاوه بر کاهش زمان محاسبات، باعث افزایش دقت این نوع از سیستم‌ها می‌شود. در تجزیه و تحلیل مؤلفه‌های اصلی نکته‌ی بسیار پراهمیت، حذف تعداد مناسب ویژگی‌هاست که برای تعیین آن در این مقاله از رابطه‌ی ۱ استفاده شده است:

$$\frac{\sum_{i=1}^n \lambda_i}{\sum_{i=1}^n \lambda_i} > \text{Threshold} \quad (1)$$

که در آن λ مقادیر ویژه به دست آمده بعد از اعمال PCA است؛ i نشان‌دهنده‌ی تعداد بردار ویژه انتخاب شده و n کل ویژگی است. در این مقاله از حد آستانه برابر با ۰/۹۸ استفاده شده است.

برای استفاده از PCA به عنوان روشی برای استخراج بهترین بازه از ویژگی‌ها، از روش معرفی شده در رابطه‌ی ۱ به منظور انتخاب تعداد ویژگی‌ها استفاده شده است. در شکل ۴ نمودار حاصل از مقادیر ویژه بعد از اعمال PCA

پارامترهایی هستند که کیفیت رگرسیون را کنترل می‌کنند.^[۲۲] محدودیت ۲ حاکی از آن است که می‌خواهیم اکثر داده‌های x_i در محدوده ε در $|y - (w^T \phi(x) + b)| \leq \varepsilon$ باشد. اگر x_i در محدوده نباشد، خطایی معادل ξ_i^* یا ξ_i^* ایجاد می‌شود که ما می‌خواهیم تابع هدف را کمینه سازیم. در رگرسیون حداقل مربعات ε همواره صفر است و داده‌ها در فضایی با ابعاد بالا نگاهت نمی‌شود. در صورتی که SVR عمومی‌تر است و رفتار انعطاف‌پذیری بر مسائل رگرسیونی دارد.^[۲۳، ۲۴]

برای حل مسئله با ابعاد خیلی بالا از قضیه‌ی دوگانی لاگرانژ برای تبدیل مسئله‌ی کمینه‌سازی مورد نظر به فرم دوگانی آن استفاده می‌شود که در آن به جای تابع پیچیده‌ی ϕ که به فضایی با ابعاد بالا می‌رود، تابع ساده‌تری به نام تابع هسته (کرنل) ظاهر می‌شود که ضرب برداری تابع ϕ است.

کرنل‌های مختلفی برای استفاده در فضای ویژگی معرفی شده‌اند که بسته به شرایط مختلف مورد استفاده قرار می‌گیرند. این کرنل‌ها در واقع ارتباط‌دهنده‌ی پارامترهای مدل و تابع هدف هستند. در مسئله‌ی مورد نظر کرنل‌های متفاوتی آزمایش شده که بهترین جواب هنگام استفاده از کرنل گوسین به دست آمد و مقدار c و ε براساس سعی و خطا انتخاب شد. با توجه به تقسیم‌بندی‌های انجام شد روی داده‌ها، هر یک از رده‌ها با متغیرهای ورودی تعیین شده توسط SVR مورد آموزش و آزمون قرار گرفتند. سپس برای مشاهده‌ی آثار اعمال PCA بر نتایج حاصل از SVR، بار دیگر SVR با داده‌هایی که PCA بر آن‌ها اعمال شده بود مورد آموزش و آزمون قرار گرفت.

۵. ارزیابی نتایج

مجموعه داده‌ی استفاده شده برای این مقاله، به‌گونه‌ی بوده که از داده‌های سال ۸۹ به‌عنوان مجموعه آموزش استفاده کرده و از مجموعه‌ی ۹۰ به‌عنوان آزمون استفاده شده است. البته باید به این نکته اشاره کرد که این مجموعه آموزش به‌صورت پشت سرهم افزایش می‌یابد چون برای هر روز شبکه دوباره آموزش داده می‌شود؛ روزهای گذشته که می‌توان از سال ۹۰ هم باشد به مجموعه اضافه می‌شود. در واقع برای آموزش هر روز از ۳۶۵ روز گذشته استفاده شده است. البته برای پیش‌بینی یک روز خاص به‌علت نبود امکانات در سازمان‌های توزیع برق به اطلاعات روز قبل، اطلاعات دو روز پیش‌بینی می‌شود. خوشبختانه با هماهنگی‌های انجام شده برای این پروژه تمامی اطلاعات ساعتی مورد نیاز از جمله اطلاعات بار مصرفی کوتاه‌مدت ساعتی، اطلاعات مربوط به هواشناسی استان مازندران به تفکیک ساعت به دست آمده و به‌دقت مورد استفاده قرار گرفته است.

برای ارزیابی کارایی روش پیشنهادی از داده‌های واقعی یکی از مناطق شمالی ایران (مازندران) استفاده شده است. دقت پیش‌بینی با استفاده از دو معیار ضریب تعیین (R^2) و مجذور میانگین مربع خطا (RMSE) مورد بررسی قرار گرفت:

$$R^2 = \left(\frac{\sum_m \sum_n (A_{mn} - \bar{A})(B_{mn} - \bar{B})}{\sqrt{(\sum_m \sum_n (A_{mn} - \bar{A})^2)(\sum_m \sum_n (B_{mn} - \bar{B})^2)}} \right)^2 \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{p=1}^p (dp - zp)^2}{p}} \quad (4)$$

در رابطه‌ی ۳، A_{mn} مقدار واقعی و B_{mn} مقدار پیش‌بینی و \bar{A} میانگین مقادیر واقعی و \bar{B} میانگین مقادیر پیش‌بینی است. در رابطه‌ی ۴ نیز dp بیانگر مقدار واقعی و zp مقدار پیش‌بینی و p تعداد نمونه‌هاست.

یکی از روش‌های آگاهی از بیش‌برازش، استفاده از مجموعه‌ی اعتبارسنجی است؛ در این مقاله برای جلوگیری از مشکل بیش‌برازش در روش شبکه‌ی عصبی

بین پاسخ مطلوب و پاسخ واقعی شبکه است. مقدار خطا، پس از محاسبه، در مسیر برگشت از لایه‌ی خروجی و از طریق لایه‌های شبکه در کل شبکه توزیع می‌شود. پارامترهای شبکه طوری تنظیم می‌شوند که پاسخ واقعی شبکه هرچه بیشتر به سمت پاسخ مطلوب نزدیک شود.

در این تحقیق با توجه به تقسیم‌بندی داده‌ها از چندین شبکه‌ی عصبی MLP استفاده شده است. در لایه‌ی ورودی با توجه به تعداد متغیرهای ورودی که پیش‌تر بیان شد، تعداد نورون مناسب برای هر کلاس انتخاب شد. تعداد نورون‌های لایه‌ی مخفی با روش اعتبارسنجی و با توجه به نتایج انتخاب شده است. تعداد نورون‌های خروجی با توجه به هر ساعت برابر ۱ بوده که هر یک حاکی از میزان مصرف انرژی در ساعت مشخص بوده است. توابع انتقال متفاوتی نیز وجود دارد که از توابع سیگموئید و تانژانت هایپربولیک در لایه‌های پنهان و خروجی استفاده شده است. نوع الگوریتم یادگیری مورد استفاده نیز به‌منظور آموزش Levenberg-Marquardt بوده است. با استفاده از داده‌های سال ۸۹، آموزش شبکه انجام شد و از داده‌های سال ۹۰ به‌منظور آزمون شبکه استفاده کردیم. پس از آن، با اعمال PCA روی متغیرهای ورودی مجدداً تمام رده‌ها با همان نوع شبکه‌ی عصبی مورد بررسی قرار گرفت؛ البته ویژگی‌های ورودی با استفاده از رابطه‌ی ۱ کاهش یافته است. در این مرحله نیز تعداد نورون‌های پنهان براساس اعتبارسنجی انتخاب شد.

۵.۴. ماشین بردار پشتیبان

روش ماشین بردار پشتیبان یکی از روش‌های یادگیری ماشینی است که بر مبنای نظریه‌ی یادگیری آماری و پنیک در دهه‌ی ۹۰ میلادی توسط وینیک و همکارانش ارائه شد. در SVM از اصول کمینه‌سازی ریسک ساختاری (SRM) استفاده شده است، در حالی که سایر روش‌ها از اصول کمینه‌سازی ریسک تجربی (ERM) بهره می‌برند. ثابت شده است که عملکرد اصول SRM در مقایسه با ERM بهتر است.^[۲۵] به‌طور خلاصه، سازوکار اصلی SVM در حل مسئله‌ی رگرسیون عبارت است از:

۱. ماشین بردار پشتیبان، تابع رگرسیون را در به‌کارگیری یک دسته تابع خطی تخمین می‌زند.

۲. SVM عملیات رگرسیون را با تابعی که انحراف از مقدار واقعی در آن به‌میزان کم‌تر از ε مجاز است، انجام می‌دهد (تابع تلفات).

۳. روش SVM، با کمینه‌کردن ریسک ساختاری بهترین جواب را ارائه می‌دهد.^[۲۶]

در این قسمت به‌طور خلاصه رگرسیون بردار پشتیبان (SVR)^۲ که به‌منظور پیش‌بینی سری زمانی مورد استفاده قرار می‌گیرد، معرفی می‌شود. با توجه به داده‌های آموزشی $(x_1, y_1), \dots, (x_n, y_n)$ که x_i بردار ورودی و y_i مقدار خروجی مربوط به x_i است، SVR یک مسئله‌ی بهینه‌سازی است:

$$\min_{w, b, \xi_i, \xi_i^*} \frac{1}{2} w^T w + c \sum_{i=1}^l (\xi_i + \xi_i^*)$$

$$y_i - (w^T \phi(x_i) + b) \leq \varepsilon + \xi_i,$$

$$(w^T \phi(x_i) + b) - y_i \leq \varepsilon + \xi_i^*,$$

$$\xi_i, \xi_i^* \geq 0, \quad i = 1, 2, \dots, l \quad (2)$$

که در آن x_i به فضایی با ابعاد بالاتر نگاهت می‌شود، ξ_i محدوده‌ی بالای خطا و ξ_i^* محدوده‌ی پایین خطاست، c هزینه خطا، ε عرض محدوده و ϕ تابع نگاهت

در فصل تابستان، باید دقت کرد آن است که در این فصل به دلیل تغییرات ناگهانی دما در شمال کشور و همچنین به دلیل مسافرخیز بودن این منطقه در این فصل از سال، پیش‌بینی بسیار پیچیده‌تر می‌شود و نیازمند توجه بیشتر است. به همین منظور ما این فصل را به صورت جداگانه مورد تجزیه و تحلیل قرار می‌دهیم.



از نتایج حاصل از شکل‌های ۶ و ۷ و سایر نتایج به دست آمده می‌توان نتیجه گرفت در اکثر مواقع قبل از اعمال PCA به داده‌ها، نتایج حاصل از SVR بهتر از نتایج حاصل از NN بوده است. از سوی دیگر زمان اجرای SVR بسیار کم‌تر از NN بوده است. هنگامی که PCA روی داده‌های خود اعمال شدند و مجدداً با دو الگوریتم NN و SVR داده‌ها مورد بررسی قرار گرفتند، تغییرات نتایج حاصل از NN و SVR بسیار واضح است و مشاهده می‌شود که نتایج بهبود یافته‌اند (شکل‌های ۸ و ۹).

همان‌طور که گفته شد یکی دیگر از رده‌ها، مربوط به روزهای تعطیلات ملی و

از مجموعه‌ی اعتبارسنجی استفاده شده است. در شکل ۵ نتیجه‌ی حاصل از روش شبکه‌ی عصبی بعد از اعمال PCA بر مجموعه داده‌ی روزهای یکشنبه تا چهارشنبه در مرحله‌ی آموزش نشان داده شده است. این نمودار نشان می‌دهد که با توجه به ساختار ورودی‌ها و همچنین روند خطای به دست آمده در مجموعه‌ی اعتبارسنجی، بیش‌برازشی اتفاق نمی‌افتد.

در جدول ۲ مقایسه‌ی بین نتایج رده‌های مختلف مربوط به داده‌های آزمون در یک فصل از سال آمده است و هر یک از رده‌ها با روش‌های مختلف مورد آزمون قرار گرفته و براساس معیار R^2 با یکدیگر مقایسه شده‌اند. در جدول ۳ همین مقایسات با توجه به معیار RMSE آمده است. باید متذکر شد که نتایج مشاهده شده حاصل از داده‌های نرمال است.

در شکل ۶ میانگین R^2 برای چهار رده‌ی مختلف در چهار فصل با یکدیگر مقایسه شده‌اند و می‌توان اختلافات را مشاهده کرد. در شکل ۷ نیز براساس معیار RMSE مقایسه شده‌اند. نکته‌ی که در این سیستم برای کشور ما، به خصوص



شکل ۶. مقایسه‌ی میانگین ضریب تعیین برای رده‌های مختلف در فصل‌های مختلف.

شکل ۵. نمودار مربوط به خطای آموزش در استفاده از تحلیل مؤلفه‌ی اصلی و شبکه‌ی عصبی در فصل بهار.

جدول ۲. مقایسه‌ی معیار ضریب تعیین کلاس‌های مختلف در فصل بهار سال ۹۰ با روش‌های پیشنهادی.

کلاس‌های مختلف	ضریب تعیین			
	شبکه‌ی عصبی + شبکه‌ی عصبی	تحلیل مؤلفه‌ی اصلی + شبکه‌ی عصبی	ماشین بردار پشتیبان + ماشین بردار پشتیبان	تحلیل مؤلفه‌ی اصلی
شنبه	۰٫۶۷۳	۰٫۷۴۳	۰٫۸۳۲	۰٫۹۵۳
یکشنبه تا چهارشنبه	۰٫۷۲۱	۰٫۸۴۱	۰٫۸۸	۰٫۹۱
پنج‌شنبه	۰٫۷۳۴	۰٫۸۵۴	۰٫۷۷۵	۰٫۹۳۴
جمعه	۰٫۵۳۲	۰٫۸۹۸	۰٫۸۲۳	۰٫۸۶۴

جدول ۳. مقایسه‌ی مجذور میانگین مربع خطا در رده‌های مختلف در فصل بهار سال ۹۰ با روش‌های پیشنهادی.



کلاس‌های مختلف	مجذور میانگین مربع خطا			
	شبکه‌ی عصبی + شبکه‌ی عصبی	تحلیل مؤلفه‌ی اصلی + شبکه‌ی عصبی	ماشین بردار پشتیبان + ماشین بردار پشتیبان	تحلیل مؤلفه‌ی اصلی
شنبه	۰٫۰۲۶	۰٫۰۰۷۴۹	۰٫۰۲۴۵	۰٫۰۱۳۸
یکشنبه تا چهارشنبه	۰٫۰۳۲۶۷	۰٫۰۱۴۳	۰٫۰۲۰۴	۰٫۰۱۵۸
پنج‌شنبه	۰٫۱۰۸۹	۰٫۰۰۹۰۶	۰٫۰۱۷۶	۰٫۰۱۹۸
جمعه	۰٫۰۲۱۵۶	۰٫۰۱۰۰۸	۰٫۰۲۱۹	۰٫۰۲۰۴

جدول ۴. مقایسه‌ی معیار ضریب تعیین برای تعطیلات خاص ملی و مذهبی.

تعطیلات خاص ملی و مذهبی	ضریب تعیین		
	شبکه‌ی عصبی	تحلیل مؤلفه‌ی اصلی + شبکه‌ی عصبی	ماشین بردار پشتیبان + تحلیل مؤلفه‌ی اصلی
۱۴ خرداد	۰٫۹۸۴۸	۰٫۹۸۱۹	۰٫۹۰۱۶
۲۹ اسفند	۰٫۹۴۲۹	۰٫۹۸۹۲	۰٫۸۹۳۴
اربعین	۰٫۹۷۳۹	۰٫۸۲۸۴	۰٫۸۹۱۹
مبعث	۰٫۹۶۲۶	۰٫۸۷۵۷	۰٫۹۴۹۵

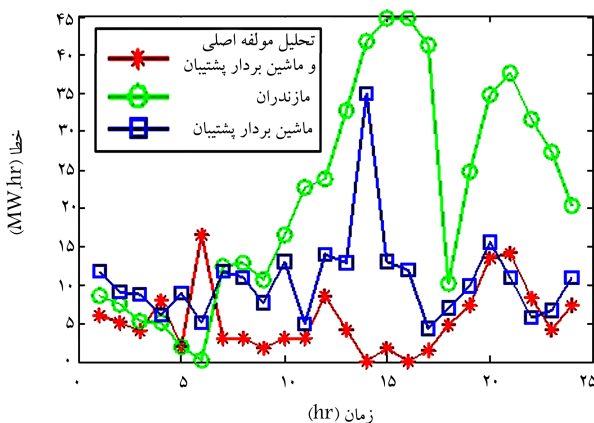
جدول ۵. مقایسه معیار مجذور میانگین مربع خطا برای تعطیلات خاص ملی و مذهبی.

تعطیلات خاص ملی و مذهبی	مجذور میانگین مربع خطا		
	شبکه‌ی عصبی	تحلیل مؤلفه‌ی اصلی + شبکه‌ی عصبی	ماشین بردار پشتیبان + تحلیل مؤلفه‌ی اصلی
۱۴ خرداد	۰٫۰۰۶۲	۰٫۰۰۵۹	۰٫۰۰۲۱
۲۹ اسفند	۰٫۰۱۳۳	۰٫۰۰۵۶	۰٫۰۰۲۲۱
اربعین	۰٫۰۳۳۵	۰٫۰۱۴۲	۰٫۰۰۲۹۱
مبعث	۰٫۰۰۵۸	۰٫۰۰۳۸	۰٫۰۰۴۵۱



شکل ۸. بهبود خطای پیش‌بینی یکی از روزها بعد از اعمال تحلیل مؤلفه‌ی اصلی به داده‌ها در شبکه‌ی عصبی.

شکل ۷. مقایسه‌ی میانگین مجذور میانگین مربع خطا برای رده‌های مختلف در فصل‌های مختلف.



شکل ۹. بهبود خطای پیش‌بینی یکی از روزها بعد از اعمال تحلیل مؤلفه‌ی اصلی به داده‌ها در ماشین بردار پشتیبان.

مذهبی بوده است. نتایج حاصل از برخی از تعطیلات خاص نیز در جدول‌های ۴ و ۵ آمده است.

با توجه به نتایج مشاهده شده در جدول‌های ۴ و ۵، نتایج حاصل از اعمال PCA روی داده‌ها و سپس آموزش توسط شبکه‌ی عصبی نتایج بهتری در برداشته است.

۱.۵. بررسی فصل تابستان

یکی از دلایل انتخاب سال ۹۰ برای تجزیه و تحلیل، وجود ماه رمضان در یکی از ماه‌های فصل تابستان است که بسیار پیش‌بینی را سخت می‌کند. با تحلیل پیش‌بینی‌های انجام شده بیشترین خطاهای موجود در کل سال برای متخصصین مازندران در این فصل است و چالش اصلی این سیستم نیز به دست آوردن یک مدل بسیار قوی (Robust) برای این فصل از سال است. در شکل ۱۰ یکی از روزهای بد استان مازندران (تاریخ ۱۳۹۰/۴/۲) نشان داده شده که سیستم پیش‌بینی

جدول ۶. مقایسه‌ی معیار ضریب تعیین رده‌های مختلف در فصل تابستان سال ۹۰ با روش‌های پیشنهادی.

کلاس‌های مختلف	ضریب تعیین			
	شبکه‌ی عصبی + تحلیل مؤلفه‌ی اصلی	ماشین بردار پشتیبان + تحلیل مؤلفه‌ی اصلی	ماشین بردار پشتیبان + شبکه‌ی عصبی	تحلیل مؤلفه‌ی اصلی
شنبه	۰٫۷۶۱	۰٫۷۰۱	۰٫۷۹۸	۰٫۹۳
یکشنبه تا چهارشنبه	۰٫۷۵۶	۰٫۸۲۱	۰٫۸۲	۰٫۸۵۲
پنج‌شنبه	۰٫۷۱	۰٫۸۲۸	۰٫۷۰۲	۰٫۸۶۱
جمعه	۰٫۵۶۳	۰٫۸۳۱	۰٫۶۹۲	۰٫۷۱

جدول ۷. مقایسه‌ی مجذور میانگین مربع خطای رده‌های مختلف در فصل تابستان سال ۹۰ با روش‌های پیشنهادی.

کلاس‌های مختلف	مجذور میانگین مربع خطا			
	شبکه‌ی عصبی + تحلیل مؤلفه‌ی اصلی	ماشین بردار پشتیبان + تحلیل مؤلفه‌ی اصلی	ماشین بردار پشتیبان + شبکه‌ی عصبی	تحلیل مؤلفه‌ی اصلی
شنبه	۰٫۰۵۳	۰٫۰۲۳	۰٫۰۱۲۳	۰٫۰۴۲۱
یکشنبه تا چهارشنبه	۰٫۰۴۵۲	۰٫۰۲۱۲	۰٫۰۳	۰٫۰۳۱۴
پنج‌شنبه	۰٫۲۲	۰٫۰۱۳	۰٫۰۲۰۸	۰٫۰۳۴۵
جمعه	۰٫۰۳۴	۰٫۰۲۳۶	۰٫۰۳۴۲	۰٫۰۴۵۲


با متخصصین استان مازندران مقایسه شده و خطای بالایی را از خود نشان داده است؛ دلیل این امر تغییر ناگهانی دما بوده است. اما چنان‌که در شکل ۱۰ مشاهده می‌کنید نتایج حاصل از روش پیشنهادی به دلیل وابسته بودن به ساعت‌های قبل و این‌که فقط به مدل‌های روزهای گذشته وابسته نیست عملکرد بسیار خوبی داشته و بهترین نتیجه را PCA+NN از خود نشان می‌دهد.

یکی دیگر از نمونه‌های بررسی شده برای فصل تابستان ۹۰ روز ۲۴ مرداد است، با توجه به مصادف بودن فصل تابستان و همچنین در ماه رمضان پیش‌بینی بسیار دشوار خواهد بود. در شکل ۱۱ نتایج حاصل از مقایسه و عملکرد سیستم پیشنهادی با متخصصین استان مازندران نشان داده شده است.


در جدول‌های ۶ و ۷ نتایج حاصل از روش‌های پیشنهادی در فصل تابستان ارائه شده است. چنان‌که مشاهده می‌شود نتایج خطای نسبتاً بالاتر نسبت به فصول دیگر سال به دلیل ماهیت این فصل در این استان کشور است.

۶. نتیجه‌گیری

در این نوشتار به منظور پیش‌بینی بار کوتاه‌مدت مصرف انرژی الکتریکی روش جدیدی با استفاده از تکنیک‌های یادگیری ماشین معرفی شده است که در آن داده‌های ورودی با نگرش متفاوتی نسبت به کارهای پیشین، به عنوان ورودی به سیستم پیش‌بینی داده شده است. در این روش جدید، وابستگی ساعتی داده‌ها با توجه به دمای ساعتی در نظر گرفته شده است. در ابتدا با استفاده از یک روش غربال‌سازی، داده‌های ورودی استخراج شده است. به همین منظور ابتدا داده‌های هر فصل به صورت جدا در نظر گرفته شد و روزها با توجه به شباهت آن به دسته‌های متفاوت دسته‌بندی شد. در ادامه، به منظور استفاده از بهترین داده‌های موجود با استفاده از روش



شکل ۱۰. پیش‌بینی بار مصرفی روز ۱۳۹۰/۴/۲.



شکل ۱۱. پیش‌بینی بار مصرفی روز ۱۳۹۰/۵/۲۴.

این فصل به صورت جداگانه مورد تجزیه و تحلیل قرار گرفته است که نتایج نشان می‌دهد بعد از اعمال PCA به داده‌های این فصل، عملکرد سیستم پیشنهادی بین روش‌های SVM و NN همواره ثابت نبوده است. نکته‌ی قابل تأمل در این قسمت، مقایسه‌ی روش پیشنهادی با پیش‌بینی‌های متخصصین در سازمان توزیع برق است؛ نتایج روش پیشنهادی با نگرش جدید در داده‌های ورودی با هر دو روش بهبود قابل ملاحظه‌ی یافته‌است. براین اساس می‌توان به این موضوع اشاره کرد که این روش می‌تواند به‌عنوان یک روش قابل اطمینان جایگزین روش‌های سنتی شود.

تجزیه و تحلیل مؤلفه‌های اصلی، بهترین ویژگی‌ها با ورودی‌ها استخراج شد. در ادامه به‌منظور پیش‌بینی بار مصرفی کوتاه‌مدت به‌صورت ساعتی، از دو روش بسیار قدرتمند ماشین‌بردار پشتیبان و شبکه‌ی عصبی بهره گرفته شد. نتایج به دست آمده از روش پیشنهادی نشان‌دهنده‌ی این نکته است که استفاده از ماشین‌بردار پشتیبان بدون استفاده از روش PCA، در روزهای معمولی هفته در فصل‌های بهار، پاییز و زمستان جواب‌های مطلوب‌تری نسبت به شبکه‌ی عصبی از خود نشان می‌دهد. در ادامه، اعمال PCA به داده‌های ورودی سبب بهبود قابل ملاحظه‌ی این دسته از داده‌ها شده است. در این مقاله همچنین داده‌های فصل تابستان به‌دلیل ماهیت

پانویس‌ها

1. knowledge based expert system
2. support vector regression

منابع (References)

1. Ranaweera, D., Karady, G. and Farmer, R. "Economic impact analysis of load forecasting", *IEEE Trans Power Syst*, **12**(3), pp. 1388-92 (1997).
2. Bunn, D.W. "Forecasting loads and prices in competitive power markets", *Proc. IEEE*, **88**(2), pp. 163-169 (2000).
3. Douglas, A.P., Breipohl, A.M., Lee, F.N. and Adapa, R. "Risk due to load forecast uncertainty in short term power system planning", *IEEE Trans. Power Syst.*, **13**(4), pp. 1493-1499 (1998).
4. Chen, H. Canizares, C.A. and Singh, A. "ANN-based short-term load forecasting in electricity markets", *Power Engineering Society Winter Meeting*, **2**, pp. 411-415 (2001).
5. Rothe, J.P., Wadhwani, A.K. and Wadhwani, S. "Short term load forecasting using multi parameter regression", *International Journal of Computer Science and Information Security*, **6**(2), pp. 303-306 (2009).
6. Deng, J. and Jirutitijaroen, P. "Short-term load forecasting using time series analysis: A case study for singapore", *International Conference on Cybernetics and Intelligent System* (2010).
7. Hong, W.-C. "Electric load forecasting by support vector model", *Applied Mathematical Modelling*, **33**(5), pp. 2444-2454 (2009).
8. Park, D.C., El-Sharkawi, M.A., Marks, R.J., Ltlas, E.A. and Damborg, M.J. "Electric load forecasting using an artificial neural network", *IEEE Trans. Power Syst.*, **6**(2), pp. 442-449 (1991).
9. Novak, B. "Superfast autoconfiguring artificial neural networks and their application to power systems", *Electric Power Syst. Res.*, **35**(1), pp. 11-16 (1995).
10. Darbellay, G.A. and Slama, M. "Forecasting the short-term demand for electricity – do neural networks stand a better chance?", *Int J. Forecast.*, **16**(1), pp. 71-83 (2000).
11. Abdel-Aal, R.E. "Short-term hourly load forecasting using abductive networks", *IEEE Trans. Power Syst.*, **19**(1), pp. 164-173 (2004).
12. Hsu, C.C. and Chen, C.Y. "Regional load forecasting in Taiwan – application of artificial neural networks", *Energy Convers. Manage*, **44**(12), pp. 1-1949 (2003).
13. Azadeh, A., Asadzadeh, S.M. and Ghanbari, A. "An adaptive network-based fuzzy inference system for short-term natural gas demand estimation: Uncertain and complex environments", *Energy Policy*, **38**(3), pp. 1529-1536 (2010).
14. Saini, L.M. "Peak load forecasting using bayesian regularization, resilient and adaptive backpropagation learning based artificial neural networks", *Electric Power Syst. Res*, **78**(7), pp. 1302-1310 (2008).
15. Lauret, P., Fock, E., Randrianarivony, R.N. and Manicom-Ramsamy, J.-F. "Bayesian neural network approach to short time load forecasting", *Energy Convers. Manage.*, **49**(5), pp. 156-1166 (2008).
16. Cao, J. and Lin, X. "tudy of hourly and daily solar irradiation forecast using diagonal recurrent wavelet neural networks", *Energy Convers. Manage.*, **49**(6), pp. 1396-1406 (2008).
17. Tai, N., Stenzel, J. and Wu, H. "echniques of applying wavelet transform into combined model for short-term load forecasting", *Electric Power Syst. Res.*, **76**(6-7), pp. 525-533 (2006).
18. El-Telbany, M. and El-Karmi, F. "hort-term forecasting of Jordanian electricity demand using particle swarm optimization", *Electric Power Syst. Res.*, **78**(3), pp. 425-433 (2008).
19. Dibike, Y.B., Velikov, S., Solomatine, D. and Abbot, M.B. "Model induction with support vector machines-introduction and applications", *Journal of Computing in Civil Engineering, ASCE*, **15**(3), pp. 208-216 (2001).
20. Cao, L. "Upport vector machines experts for time series forecasting", *Neurcomputing*, **51**, pp. 321-339 (2003).
21. Chen, B.J., Chang, M.W. and Lin, C.J. "Load forecasting using support vector machines: A study on EUNITE competition 2001", *IEEE Trans. Power Syst.*, **19**(4), pp. 1821-1830 (2004).

22. Pai, P.F. and Hong, W.C. "Support vector machines with simulated annealing algorithms in electricity load forecasting", *Energy Convers. Manage.*, **46**(17), pp. 2669-2688 (2005).
23. Mishra, S. and Patra, S.K. "Short term load forecasting using neural network trained with genetic algorithm & particle swarm optimization", *First International Conference on Emerging Trends in Engineering and Technology* (2008).
24. Kandil, N., Wamkeue, R., Saad, M. and Georges, S. "An efficient approach for short term load forecasting using artificial neural networks", *Electrical Power and Energy Systems*, **28**, pp. 525-530 (2006).
25. Hayati, M. and Shirvany, Y. "Artificial neural network approach for short term load forecasting for Illam region", *International Journal of Electrical, Computer, and Systems Engineering*, **1**(2), pp. 659-663 (2007).
26. Božić, M., Stojanović, M. and Stajić, Z. "Short term load forecasting using least square support vectore machines", *Facta Universitatis, Series: Automatic Control and Robotics*, **9**(1), pp. 141-150 (2010).
27. Ma, L., Zhou, S. and Lin, M. "Support vector machine optimized with genetic algorithm for short-term load forecasting", *International Symposium on Knowledge Acquisition and Modeling*, pp. 654-657 (2008).
28. Ye, N., Liu, Y. and Wang, Y. "Short-term power load forecasting based on SVM", *Proceedings of 2010 Conference on Dependable Computing (CDC'2010)*, Yichang, China (20-22 November 2010).
29. Jain, A. and Satish, B. "Clustering based short term load forecasting using support vector machines", *IEEE Bucharest Power Tech Conference*, Bucharest, Romania (28 June - 2 July 2009)
30. Shayeghi, H., Shayanfar, H.A. and Azimi, G. "Intelligent neural network based STLF", *International Journal of Computer, Electrical, Automation, Control and Information Engineering*, **3**(4), pp. 1105-1115 (2009).
31. Chen, H., Canizares, C.A. and Singh, A. "ANN-based short-term load forecasting in electricity markets", *Power Engineering Society Winter Meeting*, **2**, pp. 411-415 (2001).
32. Barzamini, R., Menhaj, M.B., Kamalvand, Sh. and Fasihi, M.A. "A new neuro-nased Method for short term load forecasting of Iran national power system", *Proceedings of International Joint Conference on Neural Networks*, Montreal, Canada (2005).
33. Lauret, P., Fock, E., Randrianarivony, R.N. and Manicom-Ramsamy, J.-F. "Baysian neural network approach to short time load forecasting", *Energy Conversion and Management*, **49**, pp. 156-1166 (2008).
34. Subbaraj, P. and Rajasekaran, V. "Evolutionary techniques based combined artificial neural networks for peak load forecasting", *International Journal of Electrical Computer, Energetic, Electronic and Communication Engineering*, **2**(9), pp. 1944-1950 (2008).
35. Rui, Y. and El-Keib, A.A. "A review of ANN-based short-term load forecasting models", *Proceedings of the Twenty-Seventh Southeastern Symposium on System Theory*, pp. 78-82 (1995).
36. Kim Y.S. "An intelligent system for customer targeting: A data mining approach", *Decision Support System*, **37**(2), pp. 215-228 (2004).
37. Mahdavi Tabatabaei, N., Mortezaeei, S.R., Taghizadegan, N. and Nayir, A. "Short term load forecasting by neural network in Mashhad (Iran) power system", *University of Pitesti-Electronics and Computers Science, Scientific Bulletin*, Romania, **2**(8), pp. 12-18 (2008).
38. Spearman, C. "General intelligence: Objectively determined and measured", *American Journal of Psychology*, **15**, pp. 92-201 (1904).
39. Kline, P., *An Easy Guide to Factor Analysis*, London, New York, Routledge (1994).
40. Dibike, Y.B., Velikov, S., Solomatine, D. and Abbot, M.B. "Model induction with support vector machines-introduction and applications", *Journal of Computing in Civil Engineering, ASCE*, **15**(3), pp. 208-216 (2001).
41. Samui, P. "Support vector machine applied to settlement of shallow foundations on cohesionless soils", *Computers and Geotechnics*, **35**, pp. 419-427 (2008).
42. Chang, M.-W., Chen, B.-J. and Lin, C.-J. "EUNITE network competition: Electricity load forecasting", Winner of EUNITE Worldwide Competition on Electricity Load Prediction, pp. 1-8 (2002).
43. Chang, M.-W., Chen, B.-J. and Lin, C.-J. "EUNITE network competition: Electricity load forecasting", Winner of EUNITE Worldwide Competition on Electricity Load Prediction, pp. 1-8 (2002).