

بررسی تاثیر ادغام اطلاعات مناطق الکتریکی مختلف در پیش‌بینی بار شبکه قدرت با ارائه یک روش نوین پیش‌بینی سلسله‌مراتبی

زهره کاهه^۱ مرتضی شعبان‌زاده^۲

۱- دانشجوی دکتری، گروه پژوهشی برنامه‌ریزی و بهره‌برداری سیستم‌های قدرت- پژوهشگاه نیرو- تهران- ایران
zohreh.kaheh@modares.ac.ir

۲- دکتری، گروه پژوهشی برنامه‌ریزی و بهره‌برداری سیستم‌های قدرت- پژوهشگاه نیرو- تهران- ایران
mshabanzadeh@nri.ac.ir

چکیده: به منظور پیش‌بینی تقاضای مصرف انرژی الکتریکی یک شهر یا کشور، متداول است که داده‌های تاریخی بار مناطق مختلف آن شهر و یا شهرهای مختلف آن کشور جمع‌آوری و بر اساس آن تصمیمات راهبردی و یا راهبردی اتخاذ شود. با این حال، ممکن است استفاده از داده‌های تاریخی تمام مناطق و یا انواع مختلف بارهای مصرفی (مسکونی، تجاری و صنعتی) به یک میزان حائز اهمیت نباشد؛ بدین معنی که امکان دارد تنها میزان بار مصرفی بعضی از مناطق و یا تنها میزان مصرف یک نوع بار بیشترین تاثیر و اهمیت را در تصمیم‌گیری داشته باشد. از آنجایی که جمع‌گیری پیش‌بینی‌های تمام مناطق و یا انواع بار لزوماً پیش‌بینی مناسبی برای هدف مورد نظر ارائه نمی‌دهد، روش‌های مختلفی برای ادغام پیش‌بینی مناطق مختلف وجود دارد. در ساده‌ترین حالت ممکن، می‌توان به سادگی داده‌های مناطق مختلف را جمع‌گیری نمود و یک سری زمانی کلی به دست آورد و پیش‌بینی را بر اساس آن انجام داد. با این وجود، این روش ساده نه تنها همواره پیش‌بینی مناسبی ارائه نمی‌دهد بلکه نیازمند دسترسی به جزئیات داده‌های تاریخی بار و عوامل موثر آن به تفکیک هر منطقه نیز می‌باشد. از این رو، در این مقاله روش‌های ادغام مختلفی نظیر روش‌های ادغام پایین به بالا، بالا به پایین و همچنین رویکرد ترکیب بهینه با در نظر گرفتن همبستگی بین سری‌های زمانی زیرمجموعه معرفی شده است. با توجه به اینکه تاکنون به حوزه پیش‌بینی سلسله‌مراتبی در صنعت برق پرداخته نشده است؛ این مقاله با بررسی کاربرد این موضوع به طور خاص برای پیش‌بینی تقاضای بار الکتریکی در شبکه قدرت از تحقیقات پیشین متمایز شده است. با توجه به تمرکز اصلی پژوهش حاضر بر تاثیر روش‌های ادغام، در این مقاله از روش‌های کلاسیک پیش‌بینی نظیر روش خودهمبسته - میانگین متحرک یکپارچه (ARIMA) و هموارسازی نمایی استفاده شده است. در این مطالعه، پیش‌بینی سلسله‌مراتبی کوتاه‌مدت و بلندمدت برای داده‌های واقعی بازار برق استرالیا انجام گرفته است. نتایج به روشنی نشان می‌دهند که روش ترکیب بهینه بهترین نتیجه را ارائه می‌دهد.

واژه‌های کلیدی: پیش‌بینی سلسله‌مراتبی، ادغام اطلاعات، ARIMA، هموارسازی نمایی، برنامه نویسی R

نوع مقاله: پژوهشی

DOI: 10.52547/jiaee.19.1.307

تاریخ ارسال مقاله: ۱۳۹۷/۴/۲۵

تاریخ پذیرش مشروط مقاله: ۱۳۹۷/۰۷/۱۴

تاریخ پذیرش مقاله: ۱۳۹۷/۰۸/۲۶

نام نویسنده‌ی مسئول: دکتر مرتضی شعبان‌زاده

نشانی نویسنده‌ی مسئول: ایران - تهران - شهرک قدس - انتهای بلوار شهید دادمان - پژوهشگاه نیرو - گروه پژوهشی برنامه‌ریزی و

بهره‌برداری سیستم‌های قدرت - صندوق پستی: ۱۴۶۶۵۵۱۷

۱- مقدمه

ادغام (۱) پایین به بالا، (۲) بالا به پایین با در نظر گرفتن سهم داده‌های تاریخی، (۳) بالا به پایین با در نظر گرفتن سهم پیش‌بینی و (۴) رویکرد ترکیب بهینه با در نظر گرفتن همبستگی بین سری‌های زمانی زیرگروه بررسی و مقایسه شده‌اند و در نهایت بهترین رویکرد معرفی شده است. با توجه به تمرکز مقاله بر تاثیر روش‌های ادغام اطلاعات سری‌های- زمانی زیرگروه، استفاده از هر روش تحلیل سری‌زمانی امکان‌پذیر است که در این مقاله از روش‌های کلاسیک پیش‌بینی نظیر مدل خودهمبسته - میانگین متحرک یکپارچه (ARIMA)^۴ و هموارسازی نمایی^۵ استفاده شده است. همچنین به منظور ارزیابی روش‌های مختلف ادغام، با استفاده از داده‌های بار شبکه برق استرالیا یک پیش-بینی سلسله مراتبی کوتاه‌مدت انجام شده است.

مقاله حاضر در ساختاری بدین شرح ارائه خواهد شد. در بخش ۲، ادبیات موضوع بررسی می‌شود. در بخش ۳، روش پیشنهادی برای پیش‌بینی سلسله‌مراتبی سری‌زمانی به طور کامل تشریح می‌شود. در نهایت، نتایج عددی در بخش ۴ و نتیجه‌گیری و پیشنهاد کارهای آتی در بخش ۵ ارائه خواهد شد.

۲- مرور ادبیات

علی‌رغم مطالعات متعدد در حوزه پیش‌بینی و به طور ویژه پیش-بینی بار شبکه قدرت، مطالعات اندکی در حوزه پیش‌بینی گروهی، سلسله مراتبی و ادغام شده انجام شده است. در این مقاله ابتدا به صورت مختصر به مرور ادبیات پیش‌بینی بار پرداخته شده و در ادامه، ادبیات موضوع در حوزه پیش‌بینی گروهی، سلسله مراتبی و ادغام شده بررسی می‌شود.

پیش‌بینی بار به طور مرسوم در سه افق زمانی کوتاه‌مدت، میان‌مدت و بلند مدت انجام می‌پذیرد و بر این اساس، پژوهش‌های انجام گرفته در این حوزه مطالعاتی معمولاً بر مبنای افق زمانی مورد نظر طبقه-بندی می‌شوند. در پیش‌بینی کوتاه‌مدت، با توجه به تغییرات شدید و لحظه ای بار و همچنین حساسیت نسبت به لزوم دقت بالای پیش-بینی، عمده‌تاً از روش‌های هوش مصنوعی به ویژه از شبکه عصبی استفاده شده است؛ در این میان، مراجع [۸-۱۳] از جمله مطالعاتی هستند که به طور هدفمند به این حوزه پرداخته‌اند. در پیش‌بینی میان‌مدت به علت اهمیت توجه به متغیرهای تاثیرگذار بر بار و همچنین توجه به روابط غیرخطی بین آن‌ها، استفاده از روش رگرسیون بردار پشتیبان^۶ متداول است؛ مراجع [۱۴، ۱۵] از جمله مقالاتی هستند که به این حوزه پرداخته‌اند. در پیش‌بینی بلندمدت نیز به علت کمبود اطلاعات و عدم قطعیت ناشی از آن عمده‌تاً از روش‌های پیش‌بینی احتمالاتی استفاده می‌شود؛ مراجع [۱۶] از جمله مقالاتی است که به طور خاص به این حوزه توجه نموده است.

با این حال، در مواقعی که چندین سری زمانی زیرگروه (زیرمجموعه) در اختیار باشد بایستی یک روش ادغام اطلاعات مورد استفاده قرار گیرد فارغ از اینکه کدام یک از این روش‌ها برای پیش‌بینی سری زمانی

به منظور پیش‌بینی تقاضای الکتریکی در یک شهر یا کشور، متداول است که داده‌های تاریخی بار مناطق مختلف آن شهر و یا شهرهای مختلف کشور جمع‌آوری و مطابق با آنها تصمیم‌گیری انجام شود. با در نظر گرفتن این موضوع ممکن است استفاده از داده‌های تاریخی تمام مناطق و یا انواع بارها (بار صنعتی، بار مسکونی و بار تجاری) به یک میزان حائز اهمیت نباشد. حتی طبق اصل ۲۰-۸۰ پارتو [۱] این امکان وجود دارد که تنها میزان بار در بعضی از مناطق و میزان یک نوع بار بیشترین تاثیر را در تصمیم‌گیری داشته باشد. بدین ترتیب جمع جبری پیش‌بینی‌های هر یک از مناطق و یا انواع بار، ممکن است پیش‌بینی مناسبی برای هدف مورد نظر ارائه ندهد. این امر تنها منحصر به پیش‌بینی بار نمی‌باشد و عموماً داده‌های جمع‌آوری شده برای هر موضوعی به صورت ذاتی قابلیت قرار گرفتن در ساختارهای سلسله‌مراتبی را دارند؛ به طوری که مجموع پیش‌بینی‌های سطح پایین، پیش‌بینی دقیقی برای هدف کلی ارائه نمی‌دهند [۲]. یک روش پیش‌بینی برای این گونه داده‌ها، پیش‌بینی سلسله‌مراتبی^۱ است.

در ادبیات موضوع، واژه پیش‌بینی سلسله‌مراتبی به انواع مختلفی از پیش‌بینی اطلاق شده است [۲-۶]. به عنوان مثال در مرجع [۴] منظور از پیش‌بینی سلسله‌مراتبی، در نظر گرفتن سلسله‌مراتب تصمیم‌گیری استراتژیک، تاکتیکی و عملیاتی و یا به عبارتی در نظر گرفتن همزمان پیش‌بینی‌های بلندمدت، میان‌مدت و کوتاه‌مدت مدنظر بوده است. این نوع پیش‌بینی عمدتاً مورد استفاده در سازمان‌ها است که تصمیمات بلندمدت آنها از نوع تصمیمات کیفی و تصمیمات کوتاه-مدت آن‌ها از نوع تصمیمات کمی است و ارتباطی با پیش‌بینی بار شبکه با رویکرد کمی در تمام افق زمانی ندارد. با این حال، منظور از پیش‌بینی سلسله‌مراتبی در این مقاله، پیش‌بینی با کمک مجموعه‌ای از سری‌های زمانی زیرگروه است.

اصطلاح دیگری که برای این نوع پیش‌بینی استفاده می‌شود، پیش-بینی گروهی^۲ است [۲]. با این وجود در مرجع [۷] این روش تحت عنوان پیش‌بینی داده‌های زیرپروفیل‌ها^۳ نیز مطرح شده است. به این مفهوم که مجموعه اصلی از طریق روش‌های خوشه‌بندی به زیرگروه‌های مختلف تقسیم‌بندی می‌شود و پس از پیش‌بینی جداگانه‌ی هر یک از زیرگروه‌ها، پاسخ نهایی از جمع نتایج آن‌ها به دست می‌آید.

روش‌های مختلفی برای ترکیب پیش‌بینی مناطق مختلف وجود دارد [۲، ۵]. می‌توان به سادگی داده‌های مناطق مختلف را جمع نموده و یک سری زمانی کلی به دست آورد و پیش‌بینی را بر اساس آن انجام داد. به عنوان نمونه، مرجع [۷] به بهبود خوشه‌بندی زیرپروفیل‌ها توجه کرده است اما به منظور ادغام اطلاعات خوشه‌ها تنها از جمع عددی ساده‌ای استفاده نموده است. با این وجود، همان طور که بدان اشاره شد، این جمع جبری ساده همواره پیش‌بینی مناسبی ارائه نمی‌دهد. از این رو، در این مقاله روش‌های ادغام مختلفی نظیر روش‌های

به منظور انجام مطالعات پیش‌بینی بار، در گام اول لازم است صرف نظر از نوع سری زمانی، بررسی شود که آیا سری زمانی مورد نظر ایستا است یا غیرایستا که این بررسی می‌تواند به سادگی با آزمون Augmented Dickey Fuller انجام شود. اما روش شهودی و ساده‌تر بررسی نمودار خودهمبستگی^۷ و خودهمبستگی جزئی^۸ آن است. در واقع، در صورتی که نمودار خودهمبستگی سری زمانی با یک مقدار خودهمبستگی بزرگ در لگ اول شروع شود و به تدریج و خیلی آهسته کاهش یابد، سری زمانی غیرایستا است [۲۰]. در غیر این صورت یعنی هنگامی که به سرعت به صفر یا نزدیک صفر نزول کند، می‌توان گفت سری زمانی ایستا است [۲۱].

در گام دوم نیز صرف نظر از نوع سری زمانی می‌بایست بررسی شود که آیا سری زمانی فصلی یا غیرفصلی است. یک روش شهودی و تقریبی این است که اگر در نمودار خودهمبستگی، خودهمبستگی‌ها در ابتدا و انتهای چرخه فصلی نسبت به لگ‌های اطرافشان بسیار زیاد شود، سری زمانی فصلی است [۲۱].

پس از بررسی مقدماتی مدل‌های سری زمانی، در بخش بعد، مفهوم سری زمانی سلسله مراتبی از نظر ریاضی ارائه خواهد شد.

۳-۲- سری زمانی سلسله مراتبی

یک سلسله مراتب دو سطحی به صورت شکل (۱) را در نظر می‌گیریم. سری زمانی کاملاً ادغام شده در سطح صفر (به عنوان مثال کشور) قرار می‌گیرد و در سطح ۱ اولین مرتبه تجزیه (به عنوان مثال، استان‌ها)، در سطح ۲ دومین سطح تجزیه (به عنوان مثال، شهرها) و به همین ترتیب با توجه به مساله مورد نظر سری‌های زمانی زیرگروه می‌تواند تا سطح k (به عنوان مثال، نواحی یا مناطق) در نظر گرفته شوند. هر سری زمانی زیر گروه در یک گره قرار دارد. اگر فرض کنیم در سطح کاملاً ادغام شده (سطح ۰)، t آمین مشاهده با Y_t نشان داده شود در این صورت می‌توان مشاهده t ام در سری زمانی Y_x که مربوط به گره x در سلسله مراتب است را با $Y_{x,t}$ معرفی نمود. همچنین، اگر m_i تعداد کل سری‌های زمانی موجود در سطح i باشد آنگاه نشان‌دهنده تعداد کل سری‌ها در سلسله مراتب خواهد بود [۲].

حال فرض می‌کنیم $Y_{i,t}$ شامل تمام مشاهدات در سطح i در دوره زمانی t باشد. بنابراین، مشاهدات تمام سری‌های زمانی در دوره t را می‌توان به صورت زیر با یک بردار ستونی Y_t کنار یکدیگر قرار داد:

$$Y_t = [Y_t, Y_{1,t}^T, \dots, Y_{k,t}^T]^T \quad (1)$$

عبارت (۱) می‌تواند به صورت زیر نیز بازنویسی شود:

$$Y_t = S * Y_{k,t} \quad (2)$$

در این رابطه، S ماتریسی با رتبه $m \times m_k$ است که در آن تمام سری‌های سطح پایین موجود در سلسله مراتب ادغام شده‌اند. به عنوان

هر زیرگروه استفاده شده است. در مرجع [۱۷] برای ادغام اطلاعات از جمع جبری ساده استفاده نموده‌اند. همچنین مرجع [۷] با خوشه‌بندی زیر پروفیل‌های بار، آن‌ها را در زیرگروه‌های مختلف قرار داده و متناظر با هر زیرگروه یک پیش‌بینی جداگانه انجام داده است و در نهایت، جمع عددی آنها را به عنوان پاسخ در نظر گرفته است. مرجع [۲] نیز چندین روش مختلف ادغام را برای ترکیب اطلاعات سری‌های زمانی مربوط به داده‌های میزان گردشگری داخلی در استرالیا ارائه نموده است. به طور مشابه، نویسندگان همین مقاله اخیراً مطالعات خود در حوزه نحوه ادغام اطلاعات را به صورت روش ترکیب بهینه مبتنی بر مدل رگرسیونی ارائه نموده‌اند که این روش نیز مجدداً تنها بر روی داده‌های میزان گردشگری داخلی در استرالیا پیاده‌سازی شده است [۵].

با توجه به مرور ادبیات موضوع در حوزه روش‌های ادغام اطلاعات و بررسی کاربردهای آن، نه تنها مطالعات پیش‌بینی سری زمانی از طریق مجموعه‌ای از سری‌های زمانی زیرگروه بسیار محدود می‌باشند بلکه حتی عمدتاً در حوزه‌هایی غیر از سیستم‌های قدرت مطرح شده‌اند. به همین دلیل، بکارگیری و پیاده‌سازی روش ادغام اطلاعات در پیش‌بینی بار شبکه برق به دلیل کاربرد بارز آن در حوزه مطالعات بهره‌برداری و برنامه‌ریزی سیستم‌های قدرت، تاکید اصلی این پژوهش می‌باشد.

۳- سری‌های زمانی سلسله مراتبی

۳-۱- مدل‌های سری زمانی

مدل‌های سری زمانی همواره به عنوان ابزارهای مهمی برای تحلیل داده‌های جمع‌آوری شده طی زمان و پیش‌بینی آن‌ها مطرح می‌باشند. در بحث برآورد تقاضا، خطا را به صورت تفاوت میان مقدار پیش‌بینی شده و مقدار تحقق‌یافته بیان می‌کنند [۱۸] چرا که همواره پیش‌بینی با مقداری خطا همراه است. اصولاً بار مشاهده شده شامل دو مؤلفه اصلی می‌باشد که عبارت‌اند از (۱) مؤلفه‌های سیستماتیک (مقدار مورد انتظار) و (۲) مؤلفه‌های تصادفی (بخشی از پیش‌بینی که از مؤلفه سیستماتیک منحرف می‌شود). مؤلفه‌های سیستماتیک خود شامل سه بخش می‌شوند: ۱- سطح: میزان تقاضا بدون تأثیرات فصلی، ۲- روند: افزایش یا کاهش تقاضا و ۳- تأثیرات فصلی: تغییرات پیش‌بینی‌پذیر فصلی [۱۹].

یک متغیر سری زمانی وقتی مانا (ایستا) است که میانگین، واریانس و ضریب خودهمبستگی آن طی زمان ثابت باقی‌ماند. اصولاً مانایی به دو صورت مطرح می‌شود: مانایی ضعیف و مانایی قوی؛ که معمولاً در مطالعات پیش‌بینی، نوع ضعیف بیشتر مورد توجه است. روش تشخیص مانایی سری زمانی نیز بدین صورت است که اگر تمام گشتاورها طی زمان ثابت باشند، سری زمانی مانای قوی است و چنانچه گشتاورهای مرتبه اول و دوم ثابت باشند، سری‌زمانی مانای ضعیف خواهد بود [۲۰].

۳-۲-۲- رویکرد بالا به پایین با توجه به وزن داده‌های تاریخی

در این رویکرد مقادیر هر یک از سری‌های زمانی با یکدیگر جمع جبری می‌شوند سپس با توجه به وزن هر یک از سری‌های زمانی (هر منطقه یا هر یک از انواع بار) که طبق رابطه (۵) حاصل می‌شود، سری‌های زمانی ثانویه از سری زمانی کلی تجزیه می‌شوند. در نهایت مقادیر پیش‌بینی شده هر یک از سری‌های زمانی ثانویه با توجه به وزن‌های اختصاص‌یافته ادغام می‌شوند. در این روش، بردار وزن‌ها به صورت رابطه زیر بیان می‌شود:

$$P = [p | 0_{m_k \times (m-1)}] \quad (4)$$

در این رابطه، بردار $p = [p_1, p_2, \dots, p_{m_k}]^T$ معرف وزن سری‌های زمانی می‌باشد. هر درایه‌ی این بردار نشانگر وزن سری زمانی متناظر خود بوده و مطابق مرجع [۲] به صورت زیر قابل تعیین می‌باشد:

$$p_j = \frac{\sum_{t=1}^n Y_{j,t}}{\sum_{t=1}^n Y_t} \quad (5)$$

بدین معنی که هر درایه وزنی p_j به صورت نسبت مقدار متوسط داده‌های موجود در سری زمانی مورد نظر به مقدار متوسط کل داده‌های موجود در تمام سری‌های زمانی تعیین می‌گردد.

۳-۲-۳- رویکرد بالا به پایین با توجه به وزن مقادیر پیش‌بینی شده

در این رویکرد، مقادیر هر یک از سری‌های زمانی با یکدیگر جمع جبری می‌شود، سپس با توجه به وزن پیش‌بینی هر یک از سری‌های زمانی که طبق رابطه (۶) حاصل می‌شود، سری‌های زمانی ثانویه از سری زمانی کلی تجزیه می‌شوند. در نهایت پیش‌بینی هر یک از سری‌های زمانی ثانویه با توجه به وزن‌های اختصاص‌یافته ادغام می‌شوند. در این حالت بردار وزن‌ها نظیر حالت قبل است با این تفاوت که هر درایه بردار P به صورت زیر تعیین می‌شود:

$$p_j = \frac{\prod_{i=0}^{k-1} \hat{Y}_{j,n}^{(i)}(h)}{\sum \hat{Y}_{j,n}(h)} \quad (6)$$

به طوری که $\hat{Y}_{j,n}^{(i)}(h)$ پیش‌بینی h گام جلوتر سری زمانی مربوط به گره i در سطح j است. همچنین $\sum \hat{Y}_{j,n}(h)$ بیانگر مجموع تمام پیش‌بینی‌های h گام جلوتر سری‌های زمانی سطح پایین‌تر از گروه i که مستقیماً به گره i متصل هستند، می‌باشد [۲].

با فرض اینکه $\hat{Y}_{Total,n}(h)$ مقدار پیش‌بینی اولیه برای سری زمانی بالاترین سطح سلسله مراتب باشد، به منظور دستیابی به پیش‌بینی نهایی اصلاح شده از طریق تجزیه و سپس ادغام با توجه به وزن‌ها، وزن یک گره (یک سری زمانی زیرگروه) به صورت زیر محاسبه خواهد شد:

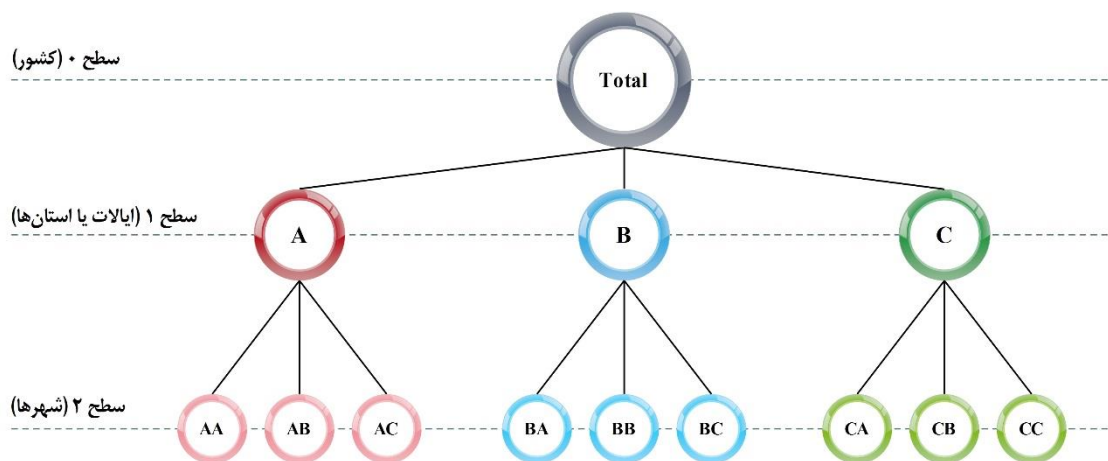
مثال، برای سلسله مراتب نشان داده شده در شکل (۱)، عبارت (۲) را می‌توان به صورت رابطه (۳) که در آن I_9 ماتریس یکبه با رتبه 9×9 است، تعیین نمود.

$$\begin{bmatrix} Y_t \\ Y_{A,t} \\ Y_{B,t} \\ Y_{C,t} \\ Y_{AA,t} \\ Y_{AB,t} \\ \vdots \\ Y_{CB,t} \\ Y_{CC,t} \end{bmatrix} = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 1 \end{bmatrix} \begin{bmatrix} Y_{AA,t} \\ Y_{AB,t} \\ Y_{AC,t} \\ Y_{BA,t} \\ Y_{BB,t} \\ Y_{BC,t} \\ Y_{CA,t} \\ Y_{CB,t} \\ Y_{CC,t} \end{bmatrix} \quad (3)$$

در پیش‌بینی سلسله‌مراتبی به دنبال پیشنهاد راه‌حلی هستیم که بر مبنای آن بتوان مشاهدات واقعی و یا پیش‌بینی‌های هر یک از سری‌های زمانی زیرمجموعه را به گونه‌ای ادغام نمود که در نهایت مقادیر پیش‌بینی تجمیع‌شده بیشترین دقت را داشته باشد. به منظور ادغام پیش‌بینی‌های سری‌های زمانی زیرمجموعه، ابتدا لازم است پیش‌بینی دوره آتی برای هر یک از سری‌های زمانی (Y_x) تولید شود که در اینجا با $\hat{Y}_{x,n}(h)$ نشان داده شده است. بر این اساس، $\hat{Y}_{AB,n}(h)$ نیز بیانگر پیش‌بینی h دوره آتی مربوط به سری زمانی Y_{AB} با داشتن n داده تاریخی خواهد بود. در ادامه، به منظور بررسی دقیق‌تر روش‌های ادغام اطلاعات، هر یک از روش‌های پیشنهادی معرفی و ارزیابی می‌شوند.

۳-۲-۱- رویکرد پایین به بالا

این رویکرد به عنوان متداول‌ترین روش ادغام اطلاعات مطرح است. در این روش، تمام پیش‌بینی‌های سری‌های زمانی سطوح پایین‌تر انجام شده و مقادیر پیش‌بینی (و نه مقادیر واقعی) به سادگی با هم جمع جبری می‌شوند تا در نهایت پیش‌بینی کلی حاصل شود. مزیت این روش این است که هیچ اطلاعاتی از دست نخواهد رفت؛ با این وجود، اگر داده‌های سطوح پایین اغتشاش داشته باشند و هر یک از سری‌های زمانی، نوسانات شدیدی به صورت متفاوت از یکدیگر داشته باشند (یعنی وجود نوسان در بازه‌های زمانی متفاوت)، به طور یقین، مقادیر پیش‌بینی ادغام شده مطمئن نبوده و دقت قابل قبولی برای آن به دست نخواهد آمد [۲].



شکل (۱): سلسله‌مراتب دوسطحی

بین سری‌های زمانی زیرمجموعه نیز در محاسبات در نظر گرفته می‌شوند.

ایده این روش مبتنی بر این است که پیش‌بینی h گام جلوتر یک سلسله مراتب را می‌توان مطابق رابطه (۱۱) به صورت یک مدل رگرسیون خطی در نظر گرفت [۵]:

$$\hat{Y}_n(h) = S * \beta_h + \varepsilon_h \quad (11)$$

که در آن $\beta_h = E\{\hat{Y}_{k,n}(h) | Y_1, \dots, Y_n\}$ میانگین پیش‌بینی h گام جلوتر سری‌های زمانی در سطح زیرین k است؛ ε نیز یک مقدار تصادفی با میانگین صفر و ماتریس واریانس کوارینانس ثابت $Var[\varepsilon_h] = \sigma_h$ می‌باشد. با فرض داشتن ماتریس واریانس کوارینانس می‌توان از طریق تخمین حداقل مربعات تعمیم‌یافته^۴، تخمین حداقل واریانس غیرآریب^{۱۱} را به دست آورد [۲]. همچنین، در مرجع [۵] اثبات شده است که با فرض $\varepsilon_h \approx S_{\varepsilon_{k,h}}$ بهترین تخمین گر غیرآریب خطی برای β_h به صورت زیر خواهد بود:

$$\hat{\beta}_h = (S^T S)^{-1} * S^T * \hat{Y}_n(h) \quad (12)$$

بنابراین بردار وزن‌های سری‌های زمانی زیرمجموعه در این رویکرد از رابطه زیر حاصل می‌شود:

$$P = (S^T S)^{-1} * S^T \quad (13)$$

در ادامه، روش‌های استفاده شده در این پژوهش جهت تحلیل و پیش‌بینی سری زمانی با تاکید بر برآورد بار شبکه قدرت تشریح می‌شود.

۳-۱- روش‌های تحلیل و پیش‌بینی سری

زمانی

به علت تمرکز مقاله بر تاثیر روش‌های ادغام اطلاعات سری‌های زمانی زیرگروه، استفاده از هر روش تحلیل سری‌زمانی امکان‌پذیر است با این حال، در این مقاله از روش‌های کلاسیک پیش‌بینی نظیر

$$\tilde{Y}_{A,n}(h) = \left(\frac{\hat{Y}_{A,n}(h)}{\hat{Y}_{A,n}(h) + \hat{Y}_{B,n}(h) + \hat{Y}_{C,n}(h)} \right) \times \hat{Y}_{Total,n}(h) \quad (7)$$

$$\tilde{Y}_{AA,n}(h) = \left(\frac{\hat{Y}_{AA,n}(h)}{\hat{Y}_{AA,n}(h) + \hat{Y}_{AB,n}(h) + \hat{Y}_{AC,n}(h)} \right) \times \tilde{Y}_{A,n}(h) \quad (8)$$

از ترکیب روابط (۷) و (۸) خواهیم داشت:

$$\tilde{Y}_{AA,n}(h) = \left\{ \begin{array}{l} \left(\frac{\hat{Y}_{AA,n}(h)}{\hat{Y}_{AA,n}(h) + \hat{Y}_{AB,n}(h) + \hat{Y}_{AC,n}(h)} \right) \\ \times \left(\frac{\hat{Y}_{A,n}(h)}{\hat{Y}_{A,n}(h) + \hat{Y}_{B,n}(h) + \hat{Y}_{C,n}(h)} \right) \\ \times \hat{Y}_{Total,n}(h) \end{array} \right\} \quad (9)$$

در نهایت، وزن گره ۱ طبق رابطه (۶) تعیین می‌گردد:

$$P_1 = \left\{ \begin{array}{l} \left(\frac{\hat{Y}_{AA,n}(h)}{\hat{Y}_{AA,n}(h) + \hat{Y}_{AB,n}(h) + \hat{Y}_{AC,n}(h)} \right) \\ \times \left(\frac{\hat{Y}_{A,n}(h)}{\hat{Y}_{A,n}(h) + \hat{Y}_{B,n}(h) + \hat{Y}_{C,n}(h)} \right) \end{array} \right\} \quad (10)$$

وزن سایر گره‌ها نیز به همین ترتیب قابل محاسبه است.

۳-۲-۴- رویکرد ترکیب بهینه

در این رویکرد، وزن‌هایی که بر اساس آن سری‌های زمانی سطح پایین با یکدیگر ترکیب می‌شوند از رابطه‌ای متفاوت با روش‌های قبل محاسبه می‌شود. در واقع در رویکرد ترکیب بهینه برخلاف روش‌های قبلی از تمام اطلاعات موجود در هر یک از سری‌های زمانی زیرمجموعه استفاده می‌شود ضمن اینکه همبستگی و ارتباط

مدل خودهمبسته - میانگین متحرک یکپارچه و هموارسازی نمایی استفاده شده است.

۳-۱-۳- هموارسازی نمایی

مرسوم‌ترین روش پیش‌بینی، مدل هموارسازی نمایی ساده است. در این روش برای محاسبه پیش‌بینی جدید از یک ضریب α استفاده می‌شود به طوری که مقدار برآورد شده به نسبت α برابر آخرین مشاهده (مشاهده در دوره قبل) و $(1-\alpha)$ برابر آخرین پیش‌بینی (پیش‌بینی برای دوره قبل) تعیین می‌گردد [۱۹]. بر این اساس، طبق رابطه (۱۴) پیش‌بینی برای دوره بعد برای دوره $t+1$ به دست می‌آید و مؤلفه سیستماتیک آن تنها شامل پارامتر سطح است:

$$L_{t+1} = \alpha \times D_t + (1-\alpha) \times L_t \quad (14)$$

در مدل فوق، D_t مقدار واقعی پیک بار در دوره t و L_t مقدار پیش‌بینی پیک بار در دوره t می‌باشد. α نیز ضریب ثابت هموارسازی است که مقداری بین ۰ و ۱ دارد؛ هر چه مقدار این ضریب بزرگ‌تر باشد تاثیر تقاضای واقعی بیشتر شده و هر چه مقدار آن کمتر باشد میزان توجه به پیش‌بینی دوره قبل افزایش می‌یابد. لازم به ذکر است که تخمین اولیه برای پارامتر سطح^{۱۱}، میانگین تمام داده‌های پیشین می‌باشد.

$$L_0 = \frac{\sum_{t=1}^n D_t}{n} \quad (15)$$

در روش هموارسازی نمایی با اصلاح روند^{۱۲} (روش Holt) [۱۹]، مؤلفه سیستماتیک شامل پارامتر سطح و روند است و تخمین اولیه برای پارامترهای سطح و روند از طریق رگرسیون طبق رابطه زیر انجام می‌شود.

$$D_t = T_0 \times t + L_0 \quad (16)$$

در این رابطه، T_0 بیانگر تخمین روند در دوره صفر می‌باشد. برای دوره‌های بعد، تخمین سطح و روند از طریق روابط زیر انجام می‌شود:

$$L_{t+1} = \alpha \times D_t + (1-\alpha) \times (L_t + T_t) \quad (17)$$

$$T_{t+1} = \beta \times (L_{t+1} - L_t) + (1-\beta) \times T_t \quad (18)$$

در روش هموارسازی نمایی با اصلاح روند و تأثیرات فصلی (روش Holt Winter)، مؤلفه سیستماتیک شامل پارامتر سطح، روند و مؤلفه فصلی است که تخمین سطح و روند برای دوره‌های بعد از طریق روابط (۱۹) الی (۲۱) و پیش‌بینی برای m دوره بعد از طریق رابطه (۲۲) انجام می‌شود:

$$S_{t+1} = \alpha \times \frac{D_t}{I_{t-L}} + (1-\alpha) \times (S_t + T_t) \quad (19)$$

$$T_{t+1} = \beta \times (S_{t+1} - S_t) + (1-\beta) \times T_t \quad (20)$$

$$S_{t+1} = \gamma \times \frac{D_t}{S_t} + (1-\gamma) \times I_{t-L} \quad (21)$$

$$F_{t+m} = I_{t-L+m} \times (S_t + T_t \cdot m) \quad (22)$$

پارامترها در روابط فوق به شرح زیر می‌باشند:

α : ثابت تعدیل سطح

β : ثابت تعدیل روند

γ : ثابت تعدیل مؤلفه فصلی

D_t : مقادیر واقعی پیک بار (مقادیری که در حال حاضر دارای عامل فصلی و روند می‌باشند)

S : مقدار هموار شده داده‌هایی که مؤلفه فصلی آن‌ها حذف شده‌اند.

T : مقدار هموار شده‌ی روند

I : مقدار هموار شده‌ی فصل

L : طول زمان فصل

F : پیش‌بینی مقادیر برای دوره‌های آتی

لازم به ذکر است، تابع ETS در پکیج $Forecast$ تمامی حالت‌های روش هموارسازی نمایی را اجرا می‌نماید.

۳-۲-۳- مدل ARIMA

در سایر مدل‌های تحلیل سری‌های زمانی فرض بر این است که اختلالات تصادفی از شوک‌های مستقل از هم در طی فرآیند ایجاد می‌شوند در حالی که معمولاً این فرض با واقعیت تناقض دارد و مشاهدات به یکدیگر وابسته هستند. به عبارت دیگر، هنگامی که مشاهدات آتی نوعی وابستگی سریالی از خود نشان دهند، مدل‌های دیگر ناکارآمد خواهند بود. به منظور رفع این مشکل، استفاده از مدل خودهمبسته - میانگین متحرک یکپارچه (ARIMA) پیشنهاد می‌شود [۲۰]. دو فرم کلی مدل ARIMA عبارت‌اند از:

۱. مدل غیرفصلی: $ARIMA(p,d,q)$

۲. مدل فصلی: $ARIMA(P,D,Q)(p,d,q)$

که در این دو مدل، p و q به ترتیب پارامترهای خودرگرسیو و میانگین متحرک غیرفصلی، P و Q به ترتیب پارامترهای خودرگرسیو و میانگین متحرک فصلی و در نهایت d و D پارامترهای تفاضلی برای ایستا کردن سری زمانی دارای روند هستند. در مدل ARIMA پارامتر p (خودرگرسیو) مشخص می‌کند که مقادیر مربوط به چند دوره گذشته در سری زمانی برای پیش‌بینی مقدار فعلی استفاده شده‌اند؛ پارامتر q (میانگین متحرک) مشخص می‌کند که انحراف از میانگین سری مربوط به چند دوره گذشته برای پیش‌بینی مقدار فعلی استفاده شده است ضمن اینکه q اثر شوک‌های تصادفی اخیر را نیز نشان می‌دهد. پارامتر d مقدار تفاضلی بوده و زمانی لازم است که در سری زمانی روند مشاهده

۲۰۱۱ تا ۲۰۱۶ برای پیش‌بینی و ارزیابی روش پیش‌بینی استفاده می‌شود. (۳) حالت ۲ با در نظر گرفتن GDP و جمعیت به عنوان متغیر مستقل.

به طور نمونه، در شکل (۳) میزان بار مصرفی در بازه‌های نیم ساعته برای ۵ روز جمعه متوالی در یکی از ایالت‌ها (ایالت کوئینزلند) نشان داده شده است. همچنین شکل (۴) اوج بار سالانه در یکی از ایالت‌ها (ایالت کوئینزلند) از سال ۲۰۰۱ الی ۲۰۱۶ و شکل (۵) اوج بار فصلی در یکی از ایالت‌ها (ایالت کوئینزلند) سال‌های ۲۰۰۷ الی ۲۰۱۶ را نشان می‌دهد.

همان‌طور که در قسمت‌های قبل اشاره شد، یک گام مقدماتی برای انتخاب مدل مناسب جهت تحلیل سری زمانی، بررسی ایستایی و یا غیرایستایی و همچنین بررسی فصلی یا غیرفصلی بودن سری زمانی است. به منظور آزمون وجود یا عدم وجود روند می‌توان از آزمون ناپارامتری Cox-stuart استفاده کرد. این آزمون به منظور آزمون دو فرضیه زیر انجام می‌شود [۲۳، ۲۴].

- فرض H_0 : هیچ روند (افزایشی یا کاهش) وجود ندارد.
- فرض H_1 : مؤلفه روند وجود دارد.

در صورتی که مقدار P-value کوچک‌تر از α (۰/۰۵) باشد، فرض H_0 رد می‌شود که نشان می‌دهد روند وجود دارد. این آزمون در برنامه R در بسته TStools، با بهره‌گیری از تابعی نام *Cox-stuart* فراخوانی می‌شود.

همچنین در بسته Tstools، به منظور بررسی فصلی بودن سری زمانی از دو دستور *seasonplot*() و *seasplot*() استفاده می‌شود. در دستور اول روند حذف می‌شود و آزمون آماری ناپارامتری Friedman به صورت زیر به منظور وجود یا عدم وجود مؤلفه فصلی انجام می‌شود [۲۳]:

- فرض H_0 : هیچ مؤلفه فصلی وجود ندارد.
- فرض H_1 : مؤلفه فصلی وجود دارد.

در صورتی که مقدار p-value کوچک‌تر از α (۰/۰۵) باشد، فرض H_0 رد می‌شود که نشان می‌دهد مؤلفه فصلی وجود دارد. در دستور دوم در بسته Forecast، آزمون آماری انجام نمی‌شود و تنها نمودار مؤلفه فصلی سری زمانی رسم می‌شود.

به عنوان نمونه، برای یکی از سری‌های زمانی زیرگروه در پیش-بینی کوتاه‌مدت (نوع ۱)، مطابق با تست آزمون ایستایی و یا غیرایستایی مقدار p-value برابر ۰/۰۰۰۱۶۵۲ محاسبه شده است، که این مقدار حاکی از آن است که برای این داده‌ها روند وجود دارد. نمودار خودهمبستگی جزئی این سری زمانی نیز در شکل (۶) نشان داده شده است. همچنین شکل (۷) نیز مؤلفه‌های فصلی مربوط به مقادیر مشاهده شده برای ۴۸ بازه زمانی در هر روز (هر نیم‌ساعت) را برای ۵ روز مورد نظر نشان می‌دهد. نزدیک بودن مقادیر هر خوشه به یکدیگر و پراکندگی خوشه‌ها بیانگر وجود مؤلفه فصلی است. مدل مناسب برای این سری زمانی یک مدل $ARIMA(2,0,3)(0,0,1)$ با

شود. بنابراین، از پارامتر d برای حذف اثرات روند استفاده می‌شود و مقدار آن مطابق درجه روند سری زمانی تعیین می‌گردد.

در این بخش روش‌های پیش‌بینی به کار رفته پیش از ادغام اطلاعات ارائه شد، در بخش بعد نتایج عددی پیش‌بینی‌های مورد نظر ارائه و ارزیابی می‌شود.

۴- نتایج عددی

در این بخش، مدل پیشنهادی برای پیش‌بینی کلی و ادغام اطلاعات سری‌های زمانی مربوط به بار شبکه برق در هر یک از ایالت‌های استرالیا مورد ارزیابی قرار گرفته است؛ بدین منظور از داده‌های بازار برق استرالیا [۲۲] استفاده شده است. کلیه تحلیل‌ها و پیش‌بینی‌ها در بسته‌های RStudio 3.4.2 انجام شده است.

در این مطالعه، به منظور ارزیابی روش‌های ادغام، دو دسته پیش-بینی کوتاه‌مدت و بلندمدت برای داده‌های ایالت‌های مختلف استرالیا انجام شده است. نمای تفکیک‌شده ایالت‌های استرالیا به منظور انجام پیش‌بینی بار سلسله‌مراتبی در شکل ۲ نشان داده شده است.



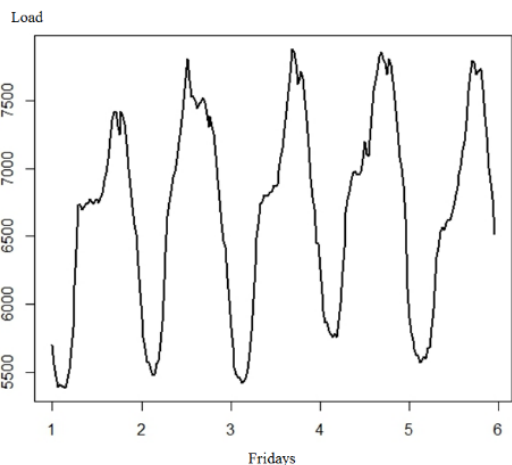
شکل (۲): نمای تفکیک‌شده ایالت‌های استرالیا به منظور انجام

پیش‌بینی بار سلسله‌مراتبی


پیش‌بینی‌های انجام شده در افق زمانی کوتاه‌مدت به صورت زیر هستند: (۱) پیش‌بینی کوتاه‌مدت برای یک روز مشخص با استفاده از داده‌های روز مشابه در ۵ هفته گذشته؛ بدین منظور داده‌های تقاضای هر یک از ایالت‌ها در بازه‌های نیم‌ساعته روزهای جمعه ۵ هفته متوالی ماه دسامبر ۲۰۱۷ جمع‌آوری شده‌اند و پیش‌بینی کوتاه‌مدت بار برای روز ۵ ژانویه ۲۰۱۸ انجام شده است. بنابراین داده‌های روز ۵ ژانویه به عنوان داده‌های آزمون در نظر گرفته شده‌اند. (۲) پیش‌بینی کوتاه‌مدت تنها با استفاده از داده‌های روز قبل و در نظر گرفتن روز مشابه در هفته گذشته به عنوان متغیر مستقل؛ این پیش‌بینی نیز برای روز ۵ ژانویه ۲۰۱۸ انجام شده است.

همچنین پیش‌بینی‌های انجام شده در افق زمانی بلندمدت به صورت زیر هستند: (۱) پیش‌بینی اوج بار فصلی به طوری که از اطلاعات اوج بار فصلی از سال ۲۰۰۷ تا سال ۲۰۱۴ جهت آموزش و از داده‌های سال ۲۰۱۵ تا ۲۰۱۶ برای ارزیابی روش پیش‌بینی استفاده می‌گردد. (۲) پیش‌بینی اوج بار سالانه به طوری که از اطلاعات اوج بار سالانه سالهای ۲۰۰۱ الی ۲۰۱۰ جهت آموزش تابع و از داده‌های سال


با بررسی کاربرد این موضوع به طور خاص برای پیش‌بینی تقاضای بار الکتریکی در شبکه قدرت از تحقیقات پیشین متمایز شده است.



شکل (۳): سری زمانی مربوط به تقاضا در بازه‌های نیم ساعته ایالت کوئینزلند (یک سری زمانی زیر گروه)



شکل (۴): اوج بار سالیانه از سال ۲۰۰۱ الی ۲۰۱۶



شکل (۵): اوج بار فصلی سال‌های ۲۰۰۷ الی ۲۰۱۶

میانگین غیر صفر است، که توسط تابع $auto.arima()$ در بسته Forecast به صورت خودکار انتخاب می‌شود. لازم به ذکر است که جهت به کارگیری ARIMA با متغیر مستقل کافی است در توابع $auto.arima$ و $forecast$ آرگومان $xreg$ را برابر متغیر مستقل مورد نظر قرار دهیم. در شکل (۸) پیش‌بینی مربوط به این سری زمانی زیر گروه به تنهایی و از طریق روش ARIMA نشان داده شده است. در این شکل توجه می‌شود که در انتهای نمودار، علاوه بر پیش‌بینی اصلی که با خط تیره نشان داده شده است، حدود اطمینان ۹۵ درصد و ۸۰ درصد نیز ترسیم شده‌اند. به منظور رسم این خطوط، پیش‌بینی به دست آمده (نقاط مربوط به خط تیره) به عنوان متغیر تصادفی در نظر گرفته شده و با توجه به توزیع احتمال آنها فواصل اطمینان ۹۵٪ و ۸۰٪ برای آنها محاسبه شده است. همچنین، لازم به ذکر است که نقاط دایره‌ای قرمز رنگ مربوط به داده‌های تست می‌باشند. برای سایر سری‌های زمانی زیر گروه نیز می‌توان این تحلیل را انجام داد، که در اینجا جهت اجتناب از تکرار، از بیان آن‌ها خودداری می‌شود.

در جدول (۱) ارزیابی هر یک از روش‌های مختلف تلفیق با در نظر گرفتن روش ARIMA و هموارسازی نمایی در تابع ETS به عنوان روش‌های پیش‌بینی برای پیش‌بینی تقاضای روز ۵ ژانویه در بازه‌های نیم‌ساعته به وسیله داده‌های روز مشابه طی ۵ هفته گذشته ارائه شده است. در جدول (۲) ارزیابی هر یک از روش‌های مختلف تلفیق با در نظر گرفتن روش "ARIMA با متغیر مستقل" به عنوان پیش‌بینی برای پیش‌بینی تقاضای روز ۵ ژانویه در بازه‌های نیم‌ساعته به وسیله داده‌های روز قبل و روز مشابه هفته گذشته به عنوان متغیر مستقل ارائه شده است.

در جدول (۳) ارزیابی هر یک از روش‌های مختلف تلفیق با در نظر گرفتن روش ARIMA و هموارسازی نمایی در تابع ETS به عنوان روش‌های پیش‌بینی برای پیش‌بینی اوج بار فصلی سال‌های ۲۰۱۵ و ۲۰۱۶ ارائه شده است. در جدول (۴) ارزیابی هر یک از روش‌های مختلف تلفیق با در نظر گرفتن روش ARIMA و هموارسازی نمایی در تابع ETS به عنوان روش‌های پیش‌بینی برای پیش‌بینی اوج بار سالانه در سال‌های ۲۰۱۱ تا ۲۰۱۶ ارائه شده است. در نهایت، در جداول (۵) و (۶) پیش‌بینی اوج بار سالانه با در نظر گرفتن متغیرهای مستقل GDP و جمعیت ارائه شده است.

نتایج حاصل برای تمامی موارد حاکی از آن است که روش "ادغام بهینه" برای ادغام اطلاعات سری‌های زمانی سلسله‌مراتبی کمترین میزان درصد میانگین مطلق خطا (MAPE) ^{۱۳} و یا به عبارتی بهترین نتیجه را ارائه می‌دهد.

۵- نتیجه‌گیری و پیشنهاد کارهای آینده

در این مقاله به بررسی تاثیر روش‌های ادغام اطلاعات سری‌های زمانی زیرمجموعه بر دقت پیش‌بینی نهایی با تمرکز بر پیش‌بینی بار الکتریکی پرداخته شده است. با توجه به اینکه تاکنون به حوزه پیش‌بینی سلسله‌مراتبی در صنعت برق پرداخته نشده است؛ این مقاله




خودهمبسته - میانگین متحرک یکپارچه و هموارسازی نمایی استفاده شده است. در مطالعات آتی به کارگیری سایر روش‌های پیش‌بینی نظیر روش‌های هوش مصنوعی و به‌ویژه روش شبکه عصبی و رگرسیون بردار پشتیبان به عنوان روش پیش‌بینی سری زمانی سلسله‌مراتبی توصیه می‌شود. ذکر این نکته حائز اهمیت است که علی‌رغم افزایش دقت از طریق روش‌های پیشنهادی، سری‌های زمانی زیرگروه ممکن است وضعیت‌های کاملاً متفاوتی از یکدیگر داشته باشند و این امر می‌تواند باعث کاهش دقت پیش‌بینی ادغام شده شود. این موضوع بایستی در مطالعات آتی مورد بررسی قرار گیرد. در نهایت، در نظر گرفتن متغیرهای مستقل نظیر دما برای پیش‌بینی کوتاه‌مدت و متغیرهای جمعیت و GDP برای پیش‌بینی بلندمدت در مطالعات آتی می‌تواند موجب افزایش دقت پیش‌بینی شود.

سپاسگزاری


کار تحقیقاتی ارائه شده در این مقاله، حاصل اجرای پروژه‌های پژوهشی تحت عنوان "مدل‌سازی بار در شبکه توزیع تهران با هدف برآورد بار در زمان اوج مصرف و تعیین عوامل موثر" (کد پروژه PONPN06) می‌باشد که توسط تیم تحقیقاتی گروه پژوهشی برنامه‌ریزی و بهره‌برداری سیستم‌های قدرت و با هم‌فکری سرکار خانم مهندس زهرا مدیحی بیدگلی و جناب آقای دکتر علی کیهانی و حمایت پژوهشگاه نیرو به انجام رسیده است. نویسندگان این مقاله صمیمانه از این عزیزان کمال سپاسگزاری را دارند.

مراجع:

- [1] R. Sanders, "The Pareto principle: its use and abuse," *Journal of Services Marketing*, vol. 1, pp. 37-40, 1987.
- [2] G. Athanasopoulos, R. A. Ahmed, and R. J. Hyndman, "Hierarchical forecasts for Australian domestic tourism," *International Journal of Forecasting*, vol. 25, pp. 146-166, 2009.
- [3] S. Moon, C. Hicks, and A. Simpson, "The development of a hierarchical forecasting method for predicting spare parts demand in the South Korean Navy—A case study," *International Journal of Production Economics*, vol. 140, pp. 794-802, 2012.
- [4] G. Athanasopoulos, R. J. Hyndman, N. Kourentzes, and F. Petropoulos, "Forecasting with temporal hierarchies," *European Journal of Operational Research*, vol. 262, pp. 60-74, 2017.
- [5] R. J. Hyndman, R. A. Ahmed, G. Athanasopoulos, and H. L. Shang, "Optimal combination forecasts for hierarchical time series," *Computational Statistics & Data Analysis*, vol. 55, pp. 2579-2589, 2011.
- [6] R. J. Hyndman and G. Athanasopoulos, *Forecasting: principles and practice*: OTexts, 2014.
- [7] Y. Wang, Q. Chen, M. Sun, C. Kang, and Q. Xia, "An Ensemble Forecasting Method for the Aggregated Load with Sub Profiles," *IEEE Transactions on Smart Grid*, 2018.




شکل (۶): نمودار خودهمبستگی جزئی مربوط به یکی از سری زمانی‌های زیرگروه



شکل (۷): مولفه‌های فصلی برای یک سری زمانی زیرگروه

Forecasts from ARIMA(2,0,3)(0,0,1)[48] with non-zero mean



شکل (۸): پیش‌بینی با روش ARIMA برای یکی از سری‌های زمانی زیرگروه

در این مقاله، چهار مساله پیش‌بینی متفاوت برای ارزیابی روش‌های ادغام در سری‌های زمانی سلسله‌مراتبی از جمله روش‌های "ادغام پایین به بالا"، "بالا به پایین" و همچنین "رویکرد ترکیب بهینه" مورد بررسی قرار گرفته است. نتایج نشان داده است که از میان روش‌های به کار گرفته شده، روش ادغام ترکیب بهینه بهترین نتیجه را ارائه می‌دهد.

به علت تمرکز مقاله بر تاثیر روش‌های ادغام اطلاعات سری‌های زمانی زیرگروه، استفاده از هر روش تحلیل سری‌زمانی امکان‌پذیر است؛ که در این مقاله از روش‌های کلاسیک پیش‌بینی نظیر مدل

جدول (۱): مقایسه MAPE روش‌های مختلف ادغام با در نظر گرفتن دو روش تحلیل سری زمانی برای پیش‌بینی تقاضای روز ۵ ژانویه در بازه‌های نیم‌ساعته به وسیله داده‌های روز مشابه طی ۵ هفته گذشته

روش پیش‌بینی	بدون در نظر گرفتن سلسله-مراتب	انواع روش‌های ادغام در حالت با در نظر گرفتن سلسله‌مراتب		
		پایین به بالا	بالا به پایین با توجه به سهم میانگین‌های داده‌های تاریخی	بالا به پایین با توجه به سهم پیش‌بینی
ARIMA	۳/۳۱	۱/۴۸	۴/۷۸	۱/۴۲
هموارسازی نمایی	۴/۸۴	۱/۵۶	۶/۶۴	۱/۴۹

جدول (۲): مقایسه MAPE روش‌های مختلف ادغام برای پیش‌بینی تقاضای روز ۵ ژانویه در بازه‌های نیم‌ساعته

به وسیله داده‌های روز قبل و روز مشابه هفته گذشته به عنوان متغیر مستقل

روش پیش‌بینی	بدون در نظر گرفتن سلسله-مراتب	انواع روش‌های ادغام در حالت با در نظر گرفتن سلسله‌مراتب		
		پایین به بالا	بالا به پایین با توجه به سهم میانگین‌های داده‌های تاریخی	بالا به پایین با توجه به سهم پیش‌بینی
ARIMA	۲/۶۵	۰/۷۴	۲/۳۹	۰/۶۳
				۰/۵۴

جدول (۳): مقایسه MAPE روش‌های مختلف ادغام با در نظر گرفتن دو روش تحلیل سری زمانی برای پیش‌بینی اوج بار فصلی

روش پیش‌بینی	بدون در نظر گرفتن سلسله-مراتب	انواع روش‌های ادغام در حالت با در نظر گرفتن سلسله‌مراتب		
		پایین به بالا	بالا به پایین با توجه به سهم میانگین‌های داده‌های تاریخی	بالا به پایین با توجه به سهم پیش‌بینی
ARIMA	۷/۴۳	۷/۱۳	۸/۳۴	۶/۴۹
هموارسازی نمایی	۶/۳۸	۵/۹۴	۷/۲۳	۵/۲۱
				۵/۶۹

جدول (۴): مقایسه MAPE روش‌های مختلف ادغام با در نظر گرفتن دو روش تحلیل سری زمانی برای پیش‌بینی اوج بار سالانه

روش پیش‌بینی	بدون در نظر گرفتن سلسله-مراتب	انواع روش‌های ادغام در حالت با در نظر گرفتن سلسله‌مراتب		
		پایین به بالا	بالا به پایین با توجه به سهم میانگین‌های داده‌های تاریخی	بالا به پایین با توجه به سهم پیش‌بینی
ARIMA	۹/۷۶	۹/۹۸	۱۰/۱۹	۹/۵۴
هموارسازی نمایی	۴/۶۳	۴/۳۲	۴/۸۹	۴/۱۱
				۹/۰۸

جدول (۵): مقایسه MAPE روش‌های مختلف ادغام برای پیش‌بینی اوج بار سالانه با در نظر گرفتن GDP به عنوان متغیر مستقل

روش پیش‌بینی	بدون در نظر گرفتن سلسله-مراتب	انواع روش‌های ادغام در حالت با در نظر گرفتن سلسله‌مراتب		
		پایین به بالا	بالا به پایین با توجه به سهم میانگین‌های داده‌های تاریخی	بالا به پایین با توجه به سهم پیش‌بینی
ARIMA	۷/۵۳	۷/۴۲	۸/۳۴	۷/۱۹
				۶/۴۸

جدول (۶): مقایسه MAPE روش‌های مختلف ادغام برای پیش‌بینی اوج بار سالانه با در نظر گرفتن جمعیت به عنوان متغیر مستقل

روش پیش‌بینی	بدون در نظر گرفتن سلسله-مراتب	انواع روش‌های ادغام در حالت با در نظر گرفتن سلسله‌مراتب		
		پایین به بالا	بالا به پایین با توجه به سهم میانگین‌های داده‌های تاریخی	بالا به پایین با توجه به سهم پیش‌بینی
ARIMA	۷/۲۱	۷/۱۳	۸/۲۳	۶/۴۹
				۶/۱۷

- [۱۷] م. کریمی، ج. کرمی، م. غلامی، ه. خطیبزاده و ن. مسلمی، "اولویت بندی روزهای مشابه جهت پیش‌بینی بار کوتاه مدت شبکه ایران با در نظرگیری دما و بخش‌بندی سیستم قدرت" نشریه انجمن مهندسی برق و الکترونیک ایران، سال چهاردهم، شماره سوم، ۱۳۹۶.
- [۱۸] برادران کاظم‌زاده و کاهه، مباحث ویژه در مدیریت زنجیره تأمین؛ با تمرکز بر مدل‌سازی مذاکره بین شرکتها: دانشگاه تربیت مدرس، ۱۳۹۴.
- [19] S. Chopra and P. Meindl, "Supply chain management. Strategy, planning & operation," *Das summa summarum des management*, pp. 265-275, 2007.
- [20] D. C. Montgomery, C. L. Jennings, and M. Kulahci, *Introduction to time series analysis and forecasting*: John Wiley & Sons, 2015.
- [21] S. Makridakis, S. C. Wheelwright, and R. J. Hyndman, *Forecasting methods and applications*: John Wiley & Sons, 2008.
- [22] <http://www.aemo.com.au/Electricity/National-Electricity-Market-NEM/Data-dashboard#price-demand> .
- [23] F. P. N. Kourentzes, "Forecasting with R," 2016.
- [24] O. N. W. Zucchini, "Time Series Analysis with R", 2014.
- [8] H. Mao, X.-J. Zeng, G. Leng, Y.-J. Zhai, and J. A. Keane, "Short-term and midterm load forecasting using a bilevel optimization model," *IEEE Transactions on Power Systems*, vol. 24, pp. 1080-1090, 2009.
- [9] L. Hernandez, C. Baladrón, J. M. Aguiar, B. Carro, A. J. Sanchez-Esguevillas, and J. Lloret, "Short-term load forecasting for microgrids based on artificial neural networks," *Energies*, vol. 6, pp. 1385-1408, 2013.
- [10] N. Amjady, F. Keynia, and H. Zareipour, "Short-term load forecast of microgrids by a new bilevel prediction strategy," *IEEE Transactions on smart grid*, vol. 1, pp. 286-294, 2010.
- [11] N. Kourentzes, "Intermittent demand forecasts with neural networks," *International Journal of Production Economics*, vol. 143, pp. 198-206, 2013.
- [12] O. Abedinia and N. Amjady, "Net demand prediction for power systems by a new neural network-based forecasting engine," *Complexity*, vol. 21, pp. 296-308, 2016.
- [13] O. Abedinia and N. Amjady, "Short-term load forecast of electrical power system by radial basis function neural network and new stochastic search algorithm," *International transactions on electrical energy systems*, vol. 26, pp. 1511-1525, 2016.
- [14] W.-C. Hong, Y. Dong, C.-Y. Lai, L.-Y. Chen, and S.-Y. Wei, "SVR with hybrid chaotic immune algorithm for seasonal load demand forecasting," *Energies*, vol. 4, pp. 960-977, 2011.
- [15] E. E. Elattar, J. Goulermas, and Q. H. Wu, "Electric load forecasting based on locally weighted support vector regression," *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 40, pp. 438-447, 2010.
- [16] R. J. Hyndman and S. Fan, "Density forecasting for long-term peak electricity demand," *IEEE Transactions on Power Systems*, vol. 25, pp. 1142-1153, 2010.

زیر نویس‌ها

- ¹ Hierarchical forecasting
- ² Ensemble
- ³ Subprofiles
- ⁴ Auto-Regressive Integrated Moving Average
- ⁵ Exponential smoothing
- ⁶ SVM
- ⁷ ACF
- ⁸ PACF
- ⁹ Generalized Least Squares Estimation
- ¹⁰ Unbiased
- ¹¹ Level
- ¹² Trend
- ¹³ Mean Absolute Percentage Error

