

مدلسازی و پیش‌بینی بهینه نرخ خرابی تجهیزات شبکه توزیع برق

شروین اسدزاده، استادیار

گروه مهندسی صنایع- دانشکده فنی و مهندسی- دانشگاه آزاد اسلامی واحد تهران شمال- تهران- ایران
sh_asadzadeh@iau-tnb.ac.ir

چکیده: به منظور کسب درک عمیق در زمینه برنامه‌ریزی تعمیر و نگهداری، بررسی نقاط ضعف شبکه توزیع و کشف رخدادهای غیرعادی، باید خاموشی‌های رخ داده در شبکه را ردگیری کرد. از سویی دیگر مهمترین وظیفه شرکت‌های توزیع برق، تأمین برق مطمئن و پایدار است که بایستی با حداقل خاموشی و با ولتاژ استاندارد همراه باشد. این پژوهش قصد دارد با بهره‌گیری از رویکردهای سری زمانی فصلی و شبکه عصبی مصنوعی، مدل‌هایی را به منظور پیش‌بینی نرخ خرابی یکی از تجهیزات به کار رفته در دو منطقه از مناطق تحت پوشش شرکت توزیع نیروی برق تهران بزرگ ارائه دهد. این داده‌ها بصورت هفتگی در بازه فروردین ۱۳۹۱ الی اسفند ۱۳۹۴ از نرم‌افزار ثبت حوادث ENOX استخراج شده‌است. بدین منظور پس از پیش پردازش داده‌ها، مدل‌نهایی مناسب به کمک نرم‌افزارهای Minitab و MATLAB ارائه شد. همچنین، میزان متوسط دمای هوا، میزان متوسط بارش باران و میزان متوسط سرعت باد بعنوان متغیرهای ورودی به شبکه عصبی انتخاب شدند. برای ارزیابی میزان خطای مدل‌های پیشنهادی، از میانگین مربعات خطا استفاده شده‌است. نتایج نشان می‌دهند مدل‌های سری زمانی نسبت به شبکه عصبی پرسپترون چند لایه‌ای عملکرد بهتری در پیش‌بینی نرخ خرابی تجهیز مورد نظر داشتند و می‌توان برای پیش‌بینی دوره‌های آتی از آنها استفاده کرد.

واژه‌های کلیدی: پیش‌بینی نرخ خرابی، مدل‌های سری زمانی فصلی، شبکه عصبی مصنوعی، شرکت توزیع نیروی برق

تاریخ ارسال مقاله : ۹۷/۱۱/۲۰

تاریخ پذیرش مقاله : ۹۸/۰۲/۱۳

نام نویسنده‌ی مسئول : شروین اسدزاده

نشانی نویسنده‌ی مسئول : تهران- حکیمیه- دانشگاه آزاد اسلامی واحد تهران شمال

۱- مقدمه

شرکت توزیع نیروی برق تهران بزرگ یکی از شرکت‌های خدماتی در حوزه کلان شهر تهران است. این شرکت بعنوان ارائه دهنده یکی از سرویس‌های حیاتی خدمات شهری نقش مهمی در اکوسیستم شهر، بازی می‌کند و بسیاری از الزامات و نیازهای کارکردی شرکت از این جایگاه بوجود می‌آید. مجموعه شرکت‌های توزیع برق با ۳۹ شرکت مستقل در یک هلدینگ بزرگ زیرنظر شرکت مادر تخصصی توانیر اداره می‌شوند. با توجه به طرح جامع فناوری اطلاعات و ارتباطات، خدمات این بخش بدان جهت که تمام اقشار جامعه و تمام منابع و مشاغل مختلف را در بر می‌گیرد و از طرفی لزوم برخورداری آحاد جامعه از برق مطمئن و مستمر به مشتریان که چرخ‌های اقتصادی صنایع و کلیه سازمان‌ها بدان وابسته است، از اهمیت زیادی برخوردار می‌باشد. مهمترین وظیفه شرکت‌های توزیع، تأمین برق مطمئن و پایدار است که بایستی با حداقل خاموشی و با ولتاژ استاندارد به مصرف‌کنندگان برسد. نتایج بررسی‌ها نشان می‌دهد که خاموشی‌های حوزه توزیع یکی از عمده‌ترین دلایل خاموشی‌های برق مشتریان هستند. خاموشی‌های حوزه توزیع بر دو دسته اند: خاموشی‌های برنامه-ریزی نشده (اتفاقی) و خاموشی‌های برنامه ریزی شده که دسته اول در اثر اتفاقات فنی و غیرفنی در شبکه‌های توزیع برق رخ می‌دهد و بدون اراده شرکت و پرسنل برق قطع می‌گردد و بسیار بحرانی می‌باشد. شرکت توزیع نیروی برق تهران بزرگ در چند سال اخیر با استقرار نرم‌افزار ثبت حوادث (ENOX)، ابزاری را جهت حفظ و نگهداری اطلاعات پایه شبکه، رخدادهای حادث شده و ... فراهم کرده‌اند که در نتیجه می‌توان اطلاعات جامعی از خطاهای رخ داده (شامل زمان وقوع، مدت زمان رفع، نوع، علت و ...) که به تفصیل در پایگاه داده مربوط به آن سیستم ذخیره شده، استخراج نمود. در این راستا تکنیک‌های مختلفی برای پیش‌بینی وجود دارد که می‌تواند به منظور تعیین تعداد خرابی‌های تجهیزات در آینده به کار آید. از این میان می‌توان به تکنیک تحلیل و آنالیز سری‌های زمانی و همچنین شبکه عصبی و درخت تصمیم اشاره کرد.

در مرجع [1] یک تحلیل آماری در خصوص علل اصلی خرابی در شبکه توزیع برق ارائه شده است. آنها براساس اطلاعات مانیتورینگ یک شرکت توزیع واقع در اسپانیا بین سالهای ۲۰۰۴ تا ۲۰۰۹ علل اصلی حوادث و خرابی را در شبکه‌های توزیع برق کشف کردند. همچنین یک مدل جامع برای پیش‌بینی قابلیت اطمینان سیستم توزیع برق ارائه شده است که از دو بخش جداگانه مدل‌های خرابی سیستم توزیع برق و خاموشی‌های برنامه ریزی شده، ساخته شده است [2]. این مدل جامع متشکل از شبکه عصبی سه لایه و تحلیل خاکستری می‌باشد. در مرجع [3] به منظور افزایش محصول و کاهش

هزینه‌های آن، مدل پیش‌بینی قابلیت اطمینان دقیقی با استفاده از ترکیب مدل‌های میانگین متحرک خودهمبسته یکپارچه فصلی و شبکه عصبی مصنوعی ارائه شده است. مرجع [4] با استفاده از شبکه عصبی مصنوعی چند لایه پرسپترون، مدلی را جهت پیش‌بینی نرخ خرابی در یک شرکت آبرسانی لهستانی ارائه کرده است. مرجع [5] با ارائه مدل ترکیبی رگرسیون بردار پشتیبان و میانگین متحرک خودهمبسته یکپارچه، قیمت برق را پیش‌بینی کرده‌اند. همچنین طی تحقیقی، الگوی سیستم استنباط عصبی-فازی تطبیقی در شبیه‌سازی و پیش‌بینی تقاضای انرژی الکتریکی کشورهای G8 تا سال ۲۰۱۵ بکار گرفته شده است [6]. صادقی و همکاران [7] در مطالعه‌ای از الگوریتم ترکیبی عصبی-فازی و انبوه ذرات برای پیش‌بینی تقاضای بلندمدت انرژی الکتریکی کشور جمهوری اسلامی ایران تا سال ۱۴۰۴ خورشیدی استفاده کرده‌اند. نتایج مطالعه ایشان، بیانگر قدرت بالای الگوریتم ترکیبی انبوه ذرات و سیستم استنتاج عصبی-فازی تطبیقی در پیش‌بینی است. مرجع [8] در پژوهش خود با استخراج داده‌های خاموشی ثبت شده در نرم افزار ثبت حوادث شرکت توزیع نیروی برق تهران بزرگ (ENOX) طی سالهای ۱۳۸۵ تا ۱۳۹۳ با استفاده از الگوریتم K-Means به عنوان یک ابزار خوشه بندی در تکنیک داده کاوی علل خطاهایی که منجر به خاموشی می‌شوند را براساس شباهت رفتاری در خوشه‌های متعدد دسته بندی کرده و در نهایت بر اساس میزان تاثیر در بروز خاموشی اولویت بندی کردند. در مرجع [9] با استفاده از تکنیک‌های داده کاوی یک سیستم تصمیم‌یار طراحی شده است که روابط معنادار بین ویژگی‌هایی که حسگرها همه روزه در نیروگاه برق آبی آرشیو می‌کنند را می‌یابد. این روابط در تصمیم‌گیری دقیق و سریع کارشناسان کمک شایانی نموده و از آسیب به تجهیزات در تصمیمات اشتباه یا دیر هنگام جلوگیری می‌کند. مرجع [۱۰] پیش‌بینی قیمت تسویه بازار برای هر خوشه رقابتی بازار ایران را با کارگیری الگوریتم ژنتیک جهت انجام فرایند آموزش شبکه عصبی مورد مطالعه قرار داده است. در نهایت مرجع [11] به مدلسازی و پیش‌بینی تقاضای ساعتی برق مصرفی به کمک مدل‌های میانگین متحرک خودهمبسته یکپارچه با در نظر گرفتن اثرات اصلی و متقابل پرداخته است.

همانطور که پیداست، به‌رغم فراگیر شدن شبکه‌های عصبی مصنوعی و مدل‌های سری زمانی در بسیاری از علوم، تاکنون با بهره‌گیری از این ابزارهای کارا هیچ‌گونه مدل عملیاتی جهت پیش‌بینی نرخ خرابی آن دسته از تجهیزات شبکه توزیع نیروی برق که منجر به خاموشی می‌شوند ارائه نشده است. لذا در این مقاله برآنیم تا با دریافت نرخ خرابی هفتگی تجهیز موردنظر از نرم‌افزار ثبت حوادث که موجب خاموشی اتفاقی شده است (در بازه زمانی ابتدای فروردین‌ماه ۱۳۹۱ تا پایان اسفندماه ۱۳۹۴ مربوط به دو منطقه متعلق به معاونت هماهنگی و

در نهایت با لحاظ کردن رابطه فصلی بین داده ها، مدل نهایی سری زمانی فصلی $ARIMA(p, d, q) \times ARIMA(P, D, Q)_s$ یا فصلی $SARIMA(p, d, q) \times (P, D, Q)_s$ به قرار زیر می باشد:

$$\Phi_p(B^s)\theta_q(B)(1-B)^d(1-B^s)^D X_t = \theta_q(B)\Theta_Q(B^s)a_t \quad (4)$$

مدلسازی سری های زمانی، یک روش تکراری است که با شناخت الگو و برآورد پارامترها شروع می شود. بعد از برآورد پارامترها باید کفایت الگو را با بررسی اینکه آیا فرضهای الگو برقرار هستند، مورد ارزیابی قرار دهیم.

۲-۲- شبکه های عصبی

شبکه های عصبی یکی از پویاترین حوزه های تحقیق در دوران معاصر می باشد که افراد متعددی از رشته های گوناگون علمی را به خود جلب کرده است. شبکه های عصبی مصنوعی در واقع سیستم ها و روش های محاسباتی نوین برای یادگیری ماشینی، نمایش دانش و در انتها اعمال دانش به دست آمده در جهت پیش بینی پاسخ های خروجی از سامانه های پیچیده هستند. یک شبکه عصبی مصنوعی، از سه لایه ورودی، خروجی و پردازش تشکیل می شود. هر لایه شامل گروهی از سلول های عصبی (نرون) است که عموماً با کلیه نرون های لایه های دیگر در ارتباط هستند. شبکه های پرسپترون از آن جهت که توانایی مناسبی جهت تکامل یافتن به وسیله بردارهای ورودی را دارند، بسیار شایان توجه می باشند. این نوع شبکه عصبی در حل مسائل، بسیار سریع و قابل اطمینان است [۱۳]. از مهم ترین انواع شبکه های عصبی، شبکه عصبی یادگیری رو به جلو می باشد. در این مقاله، از یک شبکه عصبی پرسپترون چندلایه با یادگیری رو به جلو استفاده می کنیم. یادگیری رو به جلو به این معنی است که مقدار پارامتر خروجی براساس پارامترهای ورودی و یک سری وزن های اولیه تعیین می گردد. مقادیر ورودی با هم ترکیب شده و در لایه های نهان استفاده می شوند و مقادیر این لایه های نهان نیز برای محاسبه مقادیر خروجی ترکیب می شوند. به هر بار اجرای این الگوریتم برای تمام داده های موجود در بانک یک دوره گفته می شود. این دوره ها آنقدر ادامه می یابد که دیگر مقدار خطا تغییر نکند. از آنجایی که تعداد پارامترها در شبکه های عصبی زیاد می باشد محاسبات این شبکه ها می تواند وقت گیر باشد. ولی اگر این شبکه ها به مدت کافی اجرا گردند معمولاً موفقیت آمیز خواهند بود. شکل ۱، نمای کلی از یک شبکه عصبی پرسپترون یا ۳ ورودی و ۱ خروجی برای مساله مورد نظر را نشان می دهد.

نظارت جنوب شرق) و به کارگیری الگوهای سری زمانی و شبکه عصبی مصنوعی، مدل هایی جهت پیش بینی نرخ خرابی این تجهیز به تفکیک هر منطقه ارائه دهیم تا هریک از مناطق، آمادگی های لازم برای روبرو شدن با این خرابی ها را داشته باشد. مضاف بر آنکه عملکرد دو تکنیک پیشنهادی به منظور پیش بینی تعداد خرابی ها با هم مقایسه و رویکرد برتر انتخاب می شود.

۲- تکنیک های پیش بینی

۱-۲- مدل های سری زمانی

یک سری زمانی، دنباله ای مرتب شده از مشاهدات است. گرچه معمولاً برحسب زمان، به ویژه در فواصل زمانی مساوی، مرتب می شود؛ ولی مرتب شدن، ممکن است که با توجه به ابعاد دیگری همچون فاصله نیز باشد. از آنجا که وقایع گذشته می توانند روی وقایع آینده اثر گذاشته و وجود وقفه ها در رفتار، موضوعی رایج در علوم مختلف هستند، عامل زمان یک عامل تعیین کننده بسیار مهم در مجموعه داده های سری زمانی است. یک خصوصیت کلیدی داده های سری زمانی که تحلیل آن را نسبت به داده های مقطعی دشوارتر می کند، این واقعیت است که مشاهدات طی زمان معمولاً با همدیگر همبستگی دارند. منظور از این بحث آن است که اکثر داده های سری زمانی ارتباط نزدیکی با مشاهدات خود در گذشته نزدیک دارند. یک خصوصیت مهم دیگر داده های سری زمانی که از تناوب معینی تبعیت می کنند آن است که احتمالاً الگوهای فصلی قوی از خود به نمایش بگذارند. این خصوصیت عمدتاً در داده های سری زمانی هفتگی، ماهانه یا فصلی اتفاق می افتد. مدل های باکس-جنکینز [۱۲]، به طور گسترده در مدلسازی سری های زمانی کاربرد دارند. در مدل های اتورگرسیو از درجه p یا $AR(p)$ تابع خودهمبستگی ترکیبی از توابع نمایی و سینوسی با دامنه نوسانات کاهنده است و تابع خودهمبستگی جزئی برای فرایند $AR(p)$ بعد از وقفه p صفر می شود:


$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) X_t = a_t \quad (1)$$

در مدل های میانگین متحرک از درجه q یا $MA(q)$ ، تابع خودهمبستگی بعد از وقفه q برابر صفر می شود و تابع خودهمبستگی جزئی ترکیبی از توابع نمایی و سینوسی با دامنه نوسانات کاهنده است:


$$X_t = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \quad (2)$$

در فرایندهای اتورگرسیو-میانگین متحرک، تابع خودهمبستگی و همچنین تابع خودهمبستگی جزئی هر دو به صفر نزدیک می شوند. متعاقباً، یک مدل کلی که توانایی مدلسازی طبقه گسترده ای از سری زمانی ناپایا را داشته باشد، مدل تلفیقی اتورگرسیو میانگین متحرک با درجه (p, d, q) می باشد که بصورت $ARIMA(p, d, q)$ خلاصه می شود:


$$\Phi_p(B)(1-B)^d X_t = \theta_q(B) a_t \quad (3)$$




شکل (۲): نمودار نرخ خرابی تجهیز بصورت هفتگی در منطقه A




شکل (۳): پارامتر تبدیل پیشنهادی آزمون Box-Cox برای ثبات واریانس داده های منطقه A



شکل (۴): نمودار تابع خودهمبستگی پس از اعمال پارامتر تبدیل بر روی داده های منطقه A



شکل (۵): نمودار تابع خودهمبستگی جزئی پس از اعمال پارامتر تبدیل بر روی داده های منطقه A



شکل (۱): شبکه عصبی پرسپترون چندلایه


۳- مدلسازی و تجزیه و تحلیل داده ها

در این بخش با بهره‌گیری از مدل‌های باکس-جنکینز و یک شبکه عصبی پرسپترون چندلایه، نرخ خرابی تجهیز مورد نظر شرکت توزیع نیروی برق تهران بزرگ را مدل‌سازی می‌کنیم. شرکت توزیع نیروی برق تهران بزرگ دارای ۴۰۹۹ هزار مشترک، چهار معاونت و ۲۲ منطقه برق است. این شرکت به علت دارا بودن بیشترین مشترکین مصرف برق در سطح کشور، در تأمین برق قابل اعتماد و مطمئن، وظیفه مهم و سنگینی بر عهده دارد. مبنای اطلاعات این پژوهش، اطلاعات ثبت شده در نرم‌افزار مدیریت خاموشی شرکت توزیع نیروی برق تهران بزرگ به نام ENOX است. برای شروع کار ابتدا برحسب نیاز، داده‌های مربوط به خاموشی‌های حادث شده از ابتدای فروردین ماه ۱۳۹۱ تا پایان اسفندماه ۱۳۹۴ از پایگاه داده استخراج گردید. با توجه به سیاست‌های این شرکت داده‌های دو منطقه کلیدی مورد تجزیه و تحلیل قرار گرفته است که از آوردن نام تجهیز و نام منطقه‌ها خودداری شده است و این مناطق با A و B نمایش داده شده‌اند.

۳-۱- تحلیل داده‌ها با مدل‌های سری زمانی

۳-۱-۱- منطقه A

در این زیربخش به بررسی و مدل‌سازی داده‌های سری زمانی منطقه A می‌پردازیم. قدم اول بررسی ثبات میانگین و واریانس در طول زمان می‌باشد که به کمک نمودار سری زمانی، نمودار باکس-کاکس و توابع خودهمبستگی و خودهمبستگی جزئی صورت می‌پذیرد. شکل‌های ۲ تا ۵ نمایانگر قدم اول پیاده‌سازی برای مدل‌سازی می‌باشد.



شکل (۷): نمودار تابع خودهمبستگی جزئی پس از اعمال تفاضل گیری بر روی داده های منطقه A

بر اساس روند موجود در شکل‌های ۶ و ۷، بهترین حدس می‌تواند به صورت مدل $SARIMA(0,1,1) \times (0,0,1)_{51}$ باشد. خروجی‌های نرم‌افزار Minitab حاصل از این حدس به شرح جدول ۱ است:

جدول (۱): برآورد ضرایب مدل $ARIMA(0,1,1) \times ARIMA(0,0,1)_{51}$

Type	Coef	SE Coef	T	P
MA 1	<u>0.6934</u>	0.0501	13.84	<u>0.000</u>
SMA 51	<u>-0.2320</u>	0.0782	-2.97	<u>0.003</u>
Constant	<u>-0.01028</u>	0.02066	-0.50	<u>0.619</u>

Differencing: 1 regular difference
 Number of observations: Original series 208, after differencing 207
 Residuals: SS = 125.315 (backforecasts excluded) MS = 0.614
 DF = 204

با توجه به سطح معنادار بودن 0.05 و این مهم که مقادیر P-value گزارش شده برای ضرایب برآورد شده کمتر از این مقدار هستند لذا هر دو ضریب معنادار بوده و مدل به صورت زیر می‌باشد:

در ادامه به منظور بررسی کفایت مدل از آزمون‌های نام لی جانگ-باکس استفاده می‌شود. این آزمون برای ارزیابی استقلال مقادیر باقی مانده‌های مدل استفاده می‌شود. نتیجه این آزمون نیز همراه با مقدار P-Value بیان شده‌است. از آنجا که مقادیر P-Value بزرگتر از مقدار 0.05 است لذا فرض صفر پذیرفته می‌شود و باقی‌مانده‌ها مستقل هستند که خود نشان از کفایت مدل برازش شده دارد.


جدول (۲): نتایج آزمون لی جانگ-باکس برای مدل برازش شده

منطقه A				
Lag	12	24	36	48
Chi-Square	2.1	19.4	26.6	40.1
DF	9	21	33	45
P-Value	0.989	0.556	0.778	0.681

۳-۱-۲ منطقه B


در این زیربخش به بررسی و مدلسازی داده‌های سری زمانی منطقه B می‌پردازیم. مجدداً قدم اول بررسی ثبات میانگین و واریانس در طول زمان می‌باشد که در شکل‌های ۸ تا ۱۱ گزارش شده است.

همانطور که مشاهده می‌شود، شکل ۲ مبین عدم پایایی سری زمانی است؛ چرا که روند نزولی در طی زمان وجود دارد. ولیکن به منظور بررسی دقیق‌تر ابتدا عدم پایایی در واریانس به کمک آزمون باکس-کاکس آنالیز می‌شود که پارامتر تبدیل پیشنهادی این آزمون در نرم‌افزار Minitab در شکل ۳ مقدار 0.5 است و این بدان معناست که مقادیر از واریانس ثابتی در گذر زمان برخوردار نبودند. لذا بایستی ریشه دوم داده‌ها محاسبه شود تا بتوان پایایی را در آن‌ها برقرار نمود. پس از آن تابع خودهمبستگی و خودهمبستگی جزئی داده‌هایی که تحت عملیات نتیجه آزمون باکس-کاکس قرار گرفتند به منظور آزمون پایایی/عدم پایایی در میانگین ترسیم شده‌است (شکل‌های ۴ و ۵). نتایج نشان می‌دهد که تابع خودهمبستگی به کندی در حال نزول کردن است؛ لذا به وضوح می‌توان دریافت که میانگین نیز ناپایاست. با این توصیفات مدل‌های $AR, MA, ARMA$ برای پیش-بینی نرخ خرابی این منطقه کنار گذاشته می‌شوند چراکه این سری از مدل‌ها تنها در مواقعی که سری زمانی پایا باشد به کار گرفته می‌شوند. برای رفع ناپایایی در میانگین، بایستی حداقل یک مرتبه از داده‌هایمان عملیات تفاضلی کردن انجام شود؛ عبارتی دیگر هر داده را از داده‌ی بعدی خود کم کنیم و مجدداً تابع خودهمبستگی و خودهمبستگی جزئی آن را ترسیم کنیم. در صورت نزول سریع تابع خودهمبستگی، عملیات تفاضلی کردن را متوقف می‌کنیم. این عملیات با استفاده از نرم‌افزار Minitab انجام پذیرفت و نتایج آن در شکل‌های ۶ و ۷ گزارش شده است. نمودارها نشان می‌دهند که تعداد خرابی‌ها نه تنها از هفته به هفته در یک ماه بهم وابسته‌اند، بلکه از هفته به هفته در همان ماه در سال‌های متمادی نیز وابسته می‌باشند. بنابراین مثلاً برای پیش‌بینی تعداد خرابی‌های هفتگی در ماه آینده، نه تنها باید تعداد خرابی‌ها را در هفته‌های مجاور بررسی کنیم؛ بلکه داده‌های مردادماه در سال‌های قبل را نیز مورد آزمایش قرار دهیم.




شکل (۶): نمودار تابع خودهمبستگی پس از اعمال تفاضل گیری بر روی داده های منطقه A


شواهد در این منطقه نیز حاکی از عدم پایایی سری زمانی است ولیکن به منظور بررسی دقیق، ابتدا عدم پایایی در واریانس به کمک آزمون باکس-کاکس آنالیز می‌شود که پارامتر تبدیل پیشنهادی با عنایت به شکل ۹ مقدار صفر است و لذا بایستی لگاریتم طبیعی داده‌ها محاسبه شود تا بتوان پایایی را در آن‌ها برقرار نمود. سپس بررسی توابع خودهمبستگی و خودهمبستگی جزئی، به عدم پایایی در میانگین اشاره می‌کند. با توجه به شکل‌های ۱۰ و ۱۱ و به منظور رفع ناپایایی در میانگین، یک بار تفاضل گیری معمولی و یک بار فصلی نیاز است و بعد از آن مجدد توابع خودهمبستگی و خودهمبستگی جزئی ترسیم می‌گردند (شکل‌های ۱۲ و ۱۳).




شکل (۸): نمودار نرخ خرابی تجهیز بصورت هفتگی در منطقه B




شکل (۱۲): نمودار تابع خودهمبستگی پس از اعمال تفاضل گیری بر روی داده‌های منطقه B



شکل (۹): پارامتر تبدیل پیشنهادی آزمون Box-Cox برای ثبات واریانس داده‌های منطقه B



شکل (۱۳): نمودار تابع خودهمبستگی جزئی پس از اعمال تفاضل گیری بر روی داده‌های منطقه B




شکل (۱۰): نمودار تابع خودهمبستگی پس از اعمال پارامتر تبدیل بر روی داده‌های منطقه B

بر اساس روند موجود در شکل‌های ۱۲ و ۱۳ و بعد از دو بار تفاضل گیری، بهترین گزینه ممکن می‌تواند به صورت مدل $SARIMA(0,1,1) \times (1,1,0)_{51}$ باشد. خروجی‌های نرم‌افزار Minitab حاصل به شرح جدول ۳ است:

جدول (۳): برآورد ضرایب مدل $ARIMA(0,1,1) \times ARIMA(1,1,0)_{51}$

Type	Coef	SE Coef	T	P
SAR 50	-0.8120	0.0659	-12.33	0.000
MA 1	0.6886	0.0598	11.52	0.000

Differencing: 1 regular, 1 seasonal of order 50
 Number of observations: Original series 208, after differencing 157
 Residuals: SS = 15.0676 (backforecasts excluded) MS = 0.0972
 DF = 155



شکل (۱۱): نمودار تابع خودهمبستگی جزئی پس از اعمال پارامتر تبدیل بر روی داده‌های منطقه B

۴-۱- پیش بینی با مدل های سری زمانی

بر اساس نتایج اولیه و مدل $SARIMA(0,1,1) \times (0,0,1)_{51}$ به دست آمده در منطقه A، نرخ خرابی شش هفته ابتدایی سال ۱۳۹۵ پیش بینی شد که نتایج آن در جدول ۵ گزارش شده است.

جدول (۵): مقادیر پیش بینی ۶ هفته ابتدایی سال ۱۳۹۵ نرخ خرابی در منطقه A براساس مدل سری زمانی

میانگین مربعات خطا (MSE)	نرخ خرابی پیش بینی شده	نرخ خرابی در شرایط واقعی
۴.۸۳	۱۰	۱۱
	۹	۶
	۱۱	۸
	۱۰	۱۰
	۹	۱۰
	۱۱	۱۴

همچنین پیش بینی نرخ خرابی شش هفته اول سال ۱۳۹۵ بر اساس مدل $SARIMA(0,1,1) \times (1,1,0)_{51}$ برازش شده در منطقه B به قرار جدول ۶ است:

جدول (۶): مقادیر پیش بینی ۶ هفته ابتدایی سال ۱۳۹۵ نرخ خرابی در منطقه B براساس مدل سری زمانی

میانگین مربعات خطا (MSE)	نرخ خرابی پیش بینی شده	نرخ خرابی در شرایط واقعی
۷.۶۶	۱۳	۱۶
	۱۸	۲۰
	۱۹	۲۱
	۲۱	۲۵
	۱۵	۱۸
	۲۴	۲۶

همانطور که واضح است مدل های سری زمانی برازش شده در هر دو منطقه A و B شرکت توزیع نیروی برق تهران عملکرد مناسبی در پیش بینی نرخ خرابی تجهیز داشته اند و دارای میانگین مربعات خطای قابل قبول و کوچکی هستند.

۴-۲- پیش بینی با شبکه عصبی مصنوعی

در این زیربخش، پیش بینی نرخ خرابی تجهیز در دو منطقه A و B در شش هفته ابتدایی سال ۱۳۹۵ با تکنیک شبکه عصبی مصنوعی صورت می پذیرد. همانند قبل، با بهره گیری از میانگین مربعات خطاها میزان انحراف پیش بینی انجام شده با مقادیر واقعی سنجیده می شوند. جداول ۷ و ۸ نتایج حاصل را نشان می دهند.

جدول (۷): مقادیر پیش بینی ۶ هفته ابتدایی سال ۱۳۹۵ نرخ خرابی در منطقه A براساس تکنیک شبکه عصبی مصنوعی

با توجه به سطح معنادار بودن ۰.۰۵، هر دو ضریب معنادار بوده و مدل به صورت زیر می باشد:

متعاقبا بررسی ارزیابی استقلال باقی مانده های مدل با آزمون لی جانگ- باکس در جدول ۴ حاکی از این است که باقی مانده ها مستقل هستند و لذا مدل برازش شده کفایت لازم را دارد.

جدول (۴): نتایج آزمون لی جانگ- باکس برای مدل برازش شده منطقه B

Lag	12	24	36	48
Chi-Square	11.5	21.4	33.7	59.1
DF	10	22	34	46
P-Value	0.319	0.493	0.482	0.092

۳-۲- تحلیل داده ها با شبکه عصبی مصنوعی

برای مسئله پیش بینی نرخ خرابی تجهیز مورد نظر از یک شبکه عصبی پرسپترون چندلایه با یادگیری رو به جلو استفاده می کنیم. برای این مسئله یک شبکه عصبی با یک و دو لایه پنهان ساخته می شود. تعداد نرون های ورودی با توجه به تعداد پارامترهای مورد بررسی سه تعیین گردید. همانطور که پیشتر بیان شد میزان متوسط دمای هوا، میزان متوسط بارش باران و میزان متوسط سرعت باد بعنوان متغیرهای ورودی به شبکه عصبی انتخاب شدند. همچنین به دلیل این که تنها یک خروجی مد نظر است، یک نرون در لایه خروجی در نظر گرفته می شود. تعداد نرون ها در لایه پنهان نیز با توجه به پایگاه داده مورد نظر تعیین شده است. مدل شبکه عصبی ابتدا با استفاده از داده های آموزشی ساخته می شود، به این صورت که در فاز آموزش، ورودی ها و خروجی از قبل مشخص هستند و داده های معلوم مسئله حساب می شوند و وزن های بین نرون ها که جزء مجهولات مسئله هستند، در این فاز بدست می آیند. در مرحله بعدی که فاز تست مدل می باشد، مدل شبکه عصبی ایجاد شده با استفاده از داده های آزمایشی مورد ارزیابی قرار می گیرد، به این صورت که ورودی ها و وزن هایی که در مرحله قبل بدست آوردیم جز معلومات مسئله هستند و این بار با استفاده از ورودی ها و وزن هایی که داریم، خروجی را بدست می آوریم و جواب بدست آمده را با خروجی هایی که از قبل داشتیم مقایسه می کنیم. اختلاف بین خروجی های حاصل شده و خروجی های واقعی میزان موفقیت ما را در ایجاد مدل مشخص می کند. در واقع کارایی مدل های شبکه های عصبی نیز با معیار میانگین مربعات خطاها سنجیده می شود.

۴- پیش بینی نرخ خرابی تجهیز

در این بخش هدف بر این است تا به کمک مدل های سری زمانی برازش شده و تکنیک شبکه عصبی مصنوعی به پیش بینی نرخ خرابی تجهیز مورد نظر در دو منطقه A و B بپردازیم.

سری زمانی فصلی $SARIMA(0,1,1) \times (0,0,1)_{51}$ و $SARIMA(0,1,1) \times (1,1,0)_{51}$ عملکرد بسیار خوب و مناسبی در جهت پیش بینی نرخ خرابی تجهیز مورد نظر در دو منطقه مورد مطالعه داشتند. همچنین این دسته از مدل ها می توانند در دیگر مناطق شرکت توزیع برق مورد استفاده قرار گیرند و لذا دستاوردهای این تحقیق کمک شایانی به پیش بینی و کسب آمادگی لازم اکیپ های عملیاتی برای روبروشدن با خاموشی های بی برنامه و لذا تصمیم گیری به موقع به مسئولان شرکت توزیع نیروی برق تهران بزرگ خواهد کرد. در نهایت به عنوان پیشنهادات برای مطالعات و تحقیقات آتی می توان به بهینه سازی تعداد لایه های پنهان و تعداد نرون های آن به کمک رویکرد متدولوژی سطح پاسخ پرداخت و عملکرد آن را با مدل های سری زمانی به منظور پیش بینی نرخ خرابی تجهیز مقایسه کرد.

مراجع

- [1] Quiroga, O. A., Meléndez, J., Herraiz, S. "Fault Causes Analysis in Feeders of Power Distribution Networks", Renewable Energies and Power Quality Journal, Vol. 1, No. 5, pp. 1269-1272, 2011.
- [2] Kaigui, X., Hua, Zh., Chanan, S. "Reliability Forecasting Models for Electrical Distribution Systems Considering Component Failures and Planned Outages", International Journal of Electrical Power and Energy Systems, Vol.79, pp. 228-234, 2016.
- [3] Tong, L., Liang, Y. "Forecasting Field Failure Data for Repairable Systems Using Neural Networks and SARIMA Model", International Journal of Quality and Reliability Management, Vol. 22, No. 4, pp. 410-420, 2016.
- [4] Kutylowska, M. "Neural Network Approach for Failure Rate Prediction", Engineering Failure Analysis, Vol. 47, pp.41-48, 2015.
- [5] Jinxing, C., Jianzhou, W. "Short-term Electricity Prices Forecasting Based on Support Vector Regression and Auto-Regressive Integrated Moving Average Modeling". Energy Conversion and Management, Vol.51, Issue.11, pp.1911-1917, 2010.
- [6] Azadeh, A., Tasaoudani, B., Anvarian, N., saberi, M. "An Adaptive-Network-Based Fuzzy Inference System for Long-Term Electricity Consumption Forecasting (2008-2015):A Case Study of the Group of Eight (G8). The 14th Asia Pacific Regional Meeting of International Foundation for Production Research, 2010.

[۷] صادقی، ح.، افضلیان، ع.، حقانی، م.، سهرابی و فاج. "پیش بینی تقاضای بلندمدت انرژی الکتریکی با استفاده از الگوریتم ترکیبی عصبی-فازی و انبوه ذرات"، تحقیقات مدل سازی اقتصادی، شماره ۱۰، ص ۲۱-۵۶، ۱۳۹۱.

[۸] سرورطهرآبادی م.، قره پتیان گ.، فریدونیان ع. "دسته بندی و تحلیل عوامل خطا بر اساس تکنیک خوشه بندی در شبکه توزیع برق"، بیستمین کنفرانس توزیع بر، زاهدان، ۱۳۹۴.

[۹] پروین نیا، الف.، فرداد، خ. "ارائه یک سیستم تصمیم یار جهت پیش بینی خاموشی اضطراری نیروگاه های برق آبی با استفاده از استخراج قوانین انجمنی مطالعه موردی: نیروگاه برق آبی مارون بهبهان"، نشریه

میانگین مربعات خطا (MSE)	نرخ خرابی پیش بینی شده	نرخ خرابی در شرایط واقعی
۹.۱۶	۱۴	۱۱
	۱۱	۶
	۱۰	۸
	۱۲	۱۰
	۸	۱۰
	۱۷	۱۴

جدول (۸): مقادیر پیش بینی ۶ هفته ابتدایی سال ۱۳۹۵ نرخ خرابی در منطقه B براساس تکنیک شبکه عصبی مصنوعی

میانگین مربعات خطا (MSE)	نرخ خرابی پیش بینی شده	نرخ خرابی در شرایط واقعی
۱۳.۸۳	۲۰	۱۶
	۲۳	۲۰
	۱۹	۲۱
	۳۰	۲۵
	۲۳	۱۸
	۲۸	۲۶

در ادامه می بایست به مقایسه دو رویکرد به کار گرفته شده بپردازیم. نتایج بیانگر عملکرد بهتر مدل های سری زمانی در مقایسه با شبکه عصبی با عنایت به شاخص میانگین مربعات خطاها است، بدین مفهوم که مدل های سری زمانی دارای شاخص میانگین مربعات خطا کوچکتری هستند. البته این برتری ممکن است از عدم استفاده از توابع آموزش مناسب و یا عدم انتخاب تعداد لایه های به کار رفته و بطور کلی عدم بهینه بودن شرایط توقف در شبکه عصبی انتخابی بوده باشد. همچنین در بین مدل های سری زمانی، مدل برازش شده بر روی داده های منطقه A دارای کمترین مقدار خطاست.

۵- نتیجه

شرکت های توزیع برق به منزله پیشانی صنعت برق در خط مقدم ارتباط با مردم می باشند و از حیث اینکه آینه بیرونی عملکرد صنعت برق می باشند و در روند بازتاب های اجتماعی موثر خواهند بود، از اهمیت خاصی برخوردارند. نتایج بررسی ها نشان می دهد که خاموشی های حوزه توزیع، یکی از عمده ترین دلایل خاموشی های برق مشتریان هستند که متاثر از اتفاقات فنی و غیر فنی در شبکه های توزیع برق از جمله خرابی تجهیزات می باشند. در این راستا تکنیک های مختلفی وجود دارند که می توانند به منظور مدل سازی و پیش بینی تعداد خرابی های تجهیزات در آینده به کار آید. در این مقاله، از تکنیک تحلیل و آنالیز سری های زمانی و همچنین تکنیک شبکه عصبی مصنوعی به منظور ارائه مدل بهینه و کشف الگوی نهفته در تعداد خرابی یک تجهیز خاص در دو منطقه کلیدی و حساس تحت پوشش شرکت توزیع نیروی برق تهران بزرگ استفاده گردید. نتایج بررسی ها بر اساس شاخص میانگین مربعات خطا حاکی از آن بود که مدل های

کیفیت و بهره وری صنعت برق ایران، جلد ۷، شماره ۱۳، ص ۱۵-۲۷، ۱۳۹۷.

[۱۰] استادی، ب.، معتمدی. الف.، حسین زاده کاشان.، ع. امین نصری، م.، "پیشبینی قیمت تسویه بازار برای خوشه های زمانی رقابت پذیری بازار با استفاده از شبکه عصبی بهبود یافته با الگوریتم ژنتیک: مطالعه بازار برق ایران"، نشریه کیفیت و بهره وری صنعت برق ایران، جلد ۷، شماره ۱۳، ص ۸۴-۹۲، ۱۳۹۷.

[11] Elamin, N., Fukushige, M. "Modeling and Forecasting Hourly Electricity Demand by SARIMAX with Interactions", Energy, Vol. 165, No. B, pp. 257-268, 2018.

[۱۲] وی، و.، تحلیل سری های زمانی روش های یک متغیری و چند متغیری. ترجمه نیرومند، ح. انتشارات دانشگاه فردوسی مشهد، ۱۳۸۶.

[۱۳] منهاج، م. مبانی شبکه های عصبی، انتشارات دانشگاه صنعتی امیرکبیر، ۱۳۹۶.