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، مدل نهایی 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.

واژه های 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

[Downloaded from ieijqp.ir on 2026-11-06]

[DOR: 20.1001.1.23222344.1398.8.1.7.8]

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 سازمان ها 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 می باشد. 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 شده‌است [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 [۷] 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 استناج عصبی-فازی تطبیقی در پیش‌بینی است. مرجع[۸] در پژوهش خود با استخراج داده های 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 می شوند را براساس شباهت رفتاری در خوشه های متعدد دسته بندی کرده و در نهایت بر اساس میزان تاثیر در بروز خاموشی اولویت بندی کردند. درمرجع[۹] با استفاده از تکنیک‌های داده کاوی یک سیستم تصمیم‌یار طراحی شده است که روابط معنادار بین ویژگی هایی که حسگرها همه روزه در نیروگاه برق آبی آرشیو می‌کنند را می‌یابد. این روابط در تصمیم گیری دقیق و سریع کارشناسان کمک شایانی نموده و از آسیب به تجهیزات در تصمیمات اشتباه یا دیرهنگام جلوگیری می کند. مرجع[۱۰] پیش بینی قیمت تسویه بازار برای هر خوشه رقابتی بازار ایران را با کارگیری الگوریتم ژنتیک جهت انجام فرایند آموزش شبکه‌عصبی مورد مطالعه قرار داده است. در نهایت مرجع [11] به مدلسازی و پیش بینی تقاضای ساعتی برق مصرفی به کمک مدل های 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 می-شوند ارائه نشده‌است. 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

[Downloaded from ieijqp.ir on 2026-11-06]

[DOR: 20.1001.1.23222344.1398.8.1.7.8]

نظارت جنوب شرق) و به کارگیری الگوهای سری زمانی و شبکه عصبی مصنوعی، مدل‌هایی جهت پیش‌بینی نرخ خرابی این تجهیز به تفکیک هر منطقه ارائه دهیم تا هریک از مناطق، آمادگی‌های لازم برای روبرو شدن با این خرابی‌ها را داشته باشد. مضاف بر آنکه عملکرد دو تکنیک پیشنهادی به منظور پیش‌بینی تعداد خرابی‌ها با هم مقایسه و رویکرد برتر انتخاب می‌شود.

۲- تکنیک های پیش بینی

۲-۱- مدل های سری زمانی

یک سری‌زمانی، دنباله‌ای مرتب شده از مشاهدات است. گرچه معمولا برحسب زمان، به ویژه در فواصل زمانی مساوی، مرتب می‌شود؛ ولی مرتب شدن، ممکن است که با توجه به ابعاد دیگری همچون فاصله نیز باشد. از آنجا که وقایع گذشته می‌توانند روی وقایع آینده اثر گذاشته و وجود وقفه‌ها در رفتار، موضوعی رایج در علوم مختلف هستند، عامل زمان یک عامل تعیین کننده بسیار مهم در مجموعه داده‌های سری زمانی است. یک خصوصیت کلیدی داده‌های سری زمانی که تحلیل آن را نسبت به داده‌های مقطعی دشوارتر می‌کند، این واقعیت است که مشاهدات طی زمان معمولا با همدیگر همبستگی دارند. منظور از این بحث آن است که اکثر داده‌های سری زمانی ارتباط نزدیکی با مشاهدات خود در گذشته نزدیک دارند. یک خصوصیت مهم دیگر داده‌های سری زمانی که از تناوب معینی تبعیت می‌کنند آن است که احتمالا الگوهای فصلی قوی از خود به نمایش بگذارند. این خصوصیت عمدتا در داده‌های سری زمانی هفتگی، ماهانه یا فصلی اتفاق می‌افتد. مدل‌های باکس-جنکینز[۱۲]، به طور گسترده در مدلسازی سری‌های 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 می‌شود:

$$\left(1-\emptyset_1 B-\emptyset_2 B^2-\cdots-\emptyset_p B^p\right)X_t=a_t \qquad (1)$$

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

$$X_t=\left(1-\theta_1 B-\theta_2 B^2-\cdots-\theta_q B^q\right)a_t \qquad (۲)$$

در فرایندهای اتورگرسیو-میانگین متحرک، تابع خودهمبستگی و همچنین تابع خودهمبستگی جزئی هر دو به صفر نزدیک می‌شوند. متعاقبا، 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 می‌شود:

$$\emptyset_p(B)(1-B)^d X_t=\theta_q(B)a_t \qquad (۳)$$

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 $SARIMA(p,d,q)\times(P,D,Q)_s$ به قرار زیر می باشد:

$$\Phi_P(B^s)\emptyset_p(B)(1-B)^d(1-B^s)^D X_t=\theta_q(B)\Theta_Q(B^s)a_t \qquad (۴)$$

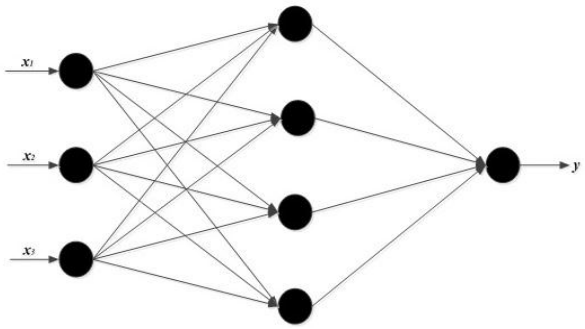
مدلسازی سری‌های زمانی، یک روش تکراری است که با شناخت الگو و برآورد پارامترها شروع می‌شود. بعد از برآورد پارامترها باید کفایت الگو را با بررسی اینکه آیا فرضهای الگو برقرار هستند، مورد ارزیابی قرار دهیم.

۲-۲- شبکه های عصبی

شبکه‌های عصبی یکی از پویاترین حوزه‌های تحقیق در دوران معاصر می‌باشد که افراد متعددی از رشته‌های گوناگون علمی را به خود جلب کرده است. شبکه‌های عصبی مصنوعی در واقع سیستم‌ها و روش‌های محاسباتی نوین برای یادگیری ماشینی، نمایش دانش و در انتها اعمال دانش به دست آمده در جهت بیش‌بینی پاسخ‌های خروجی از سامانه‌های پیچیده هستند. یک شبکه عصبی مصنوعی، از سه لایه ورودی، خروجی و پردازش تشکیل می‌شود. هر لایه شامل گروهی از سلول‌های عصبی(نرون) است که عموماً با کلیه نرون‌های لایه‌های دیگر در ارتباط هستند. شبکه‌های پرسپترون از آن جهت که توانایی مناسبی جهت تکامل یافتن به وسیله بردارهای ورودی را دارند، بسیار شایان توجه می‌باشند. 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 می‌باشد. در این مقاله، از یک شبکه عصبی پرسپترون چندلایه با یادگیری رو به جلو استفاده می‌کنیم. یادگیری رو به جلو به این معنی است که مقدار پارامتر خروجی براساس پارامترهای ورودی و یک سری وزن های اولیه تعیین می‌گردد. 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 می‌شوند. به هر بار اجرای این الگوریتم برای تمام داده های موجود در بانک یک دوره گفته می‌شود. این دوره ها آنقدر ادامه می‌یابد که دیگر مقدار خطا تغییر نکند. از آنجایی که تعداد پارامترها در شبکه‌های عصبی زیاد می باشد محاسبات این شبکه‌ها می تواند وقت گیر باشد. ولی اگر این شبکه ها به مدت کافی اجرا گردند معمولا موفقیت آمیز خواهند بود. شکل ۱، نمای کلی از یک شبکه عصبی پرسپترون با ۳ ورودی و ۱ خروجی برای مساله مورد نظر را نشان می دهد.

[Downloaded from ieijqp.ir on 2026-11-06]

[DOR: 20.1001.1.23222344.1398.8.1.7.8]



شکل (۱): شبکه عصبی پرسپترون چندلایه

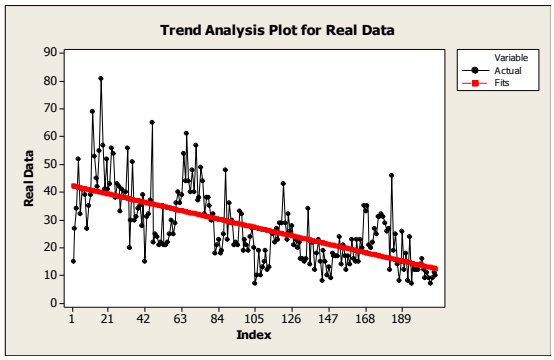
۳- مدلسازی و تجزیه و تحلیل داده ها

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 می کنیم. 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 سیاست های این شرکت داده های دو منطقه کلیدی مورد تجزیه و تحلیل قرار گرفته است که از آوردن نام تجهیز و نام منطقه ها خودداری شده است و این مناطق با A و B نمایش داده شده اند.

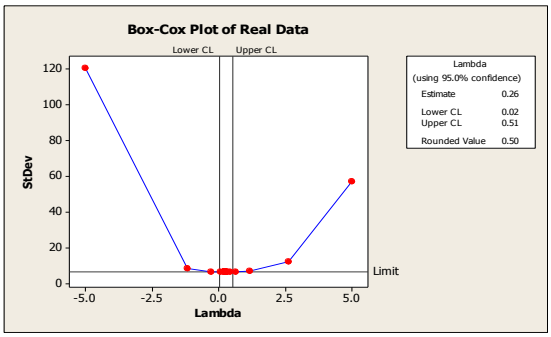
۳-۱- تحلیل داده ها با مدل های سری زمانی

۳-۱-۱ منطقه A

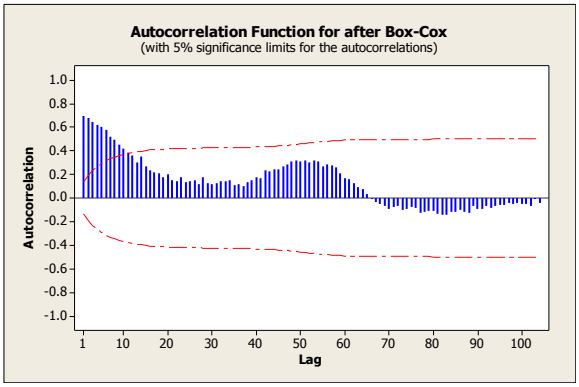
در این زیربخش به بررسی و مدلسازی داده‌های سری زمانی منطقه A می‌پردازیم. قدم اول بررسی ثبات میانگین و واریانس در طول زمان می‌باشد که به کمک نمودار سری زمانی، نمودار باکس- کاکس و توابع خودهمبستگی و خودهمبستگی جزئی صورت می‌پذیرد. شکل‌های ۲ تا ۵ نمایانگر قدم اول پیاده‌سازی برای مدلسازی می‌باشد.



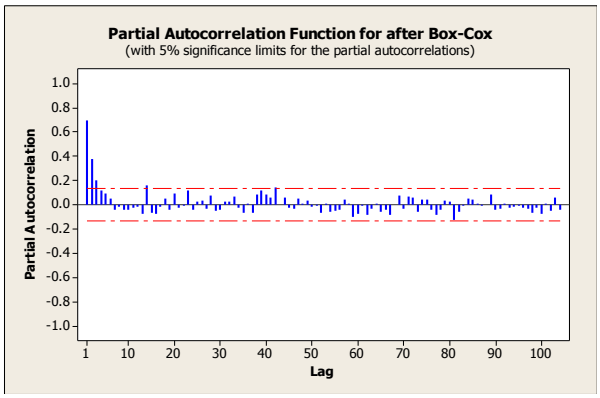
شکل (۲): نمودار نرخ خرابی تجهیز بصورت هفتگی در منطقه A



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



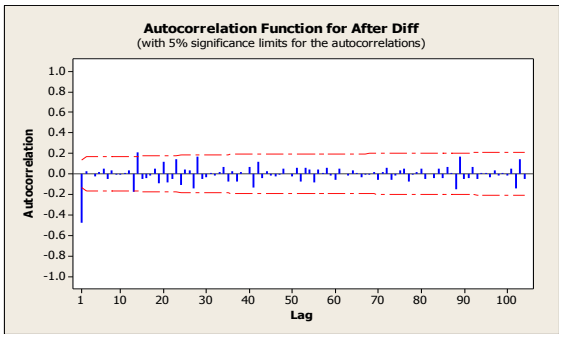
شکل (۴): نمودار تابع خودهمبستگی پس از اعمال پارامتر تبدیل بر روی داده های منطقه A



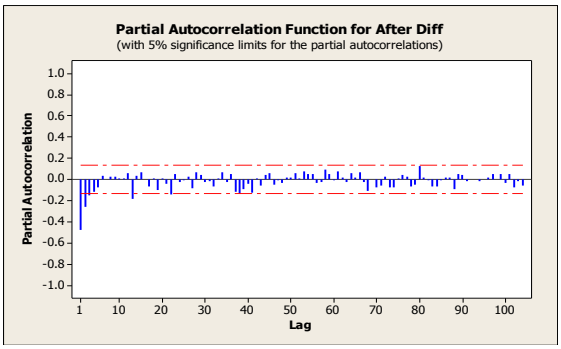
شکل (۵): نمودار تابع خودهمبستگی جزئی پس از اعمال پارامتر تبدیل بر روی داده های منطقه A

[Downloaded from ieijqp.ir on 2026-11-06]
[DOR: 20.1001.1.23222344.1398.8.1.7.8]

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 نرم- افزار Minitab در شکل ۳ مقدار ۰/۵ 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 آزمودن 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 تفاضلی‌کردن انجام شود؛ بعبارتی دیگر هر داده را از داده‌ی بعدی خود کم کنیم و مجددا تابع خودهمبستگی و خودهمبستگی جزئی آن را ترسیم کنیم. در صورت نزول سریع تابع خودهمبستگی، عملیات تفاضلی‌کردن را متوقف می‌کنیم. این عملیات با استفاده با نرم‌افزار Minitab انجام پذیرفت و نتایج آن در شکلهای ۶ و ۷ گزارش شده است. نمودارها نشان می‌دهند که تعداد خرابی ها 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 مثلا برای پیش‌بینی تعداد خرابی برای هفته‌ای در مردادماه، 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



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 می تواند 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	**0.6934**	0.0501	13.84	**0.000**
SMA 51	**-0.2320**	0.0782	-2.97	**0.003**
Constant	**-0.01028**	0.02066	-0.50	**0.619**
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 ۰.۰۵، 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 می باشد:

$$(1-B)X_t=(1-0.6934B)(1+0.2320B^{51})a_t$$

در ادامه به منظور بررسی کفایت مدل از آزمونی به نام لی جانگ- باکس استفاده می‌شود. این آزمون برای ارزیابی استقلال مقادیر باقی مانده های مدل استفاده می شود. نتیجه این آزمون نیز همراه با مقدار P-Value بیان شده‌است. از آنجا که مقادیر P-Value بزرگتر از مقدار ۰/۰۵ 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

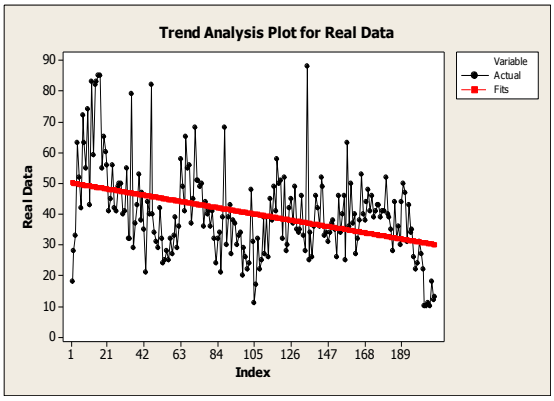
Lag	12	24	36	48
Chi-Square	2.1	19.4	26.6	40.1
DF	9	21	33	45
P-Value	0.989	0.556	0.778	0.681

۳-۱-۲ منطقه B

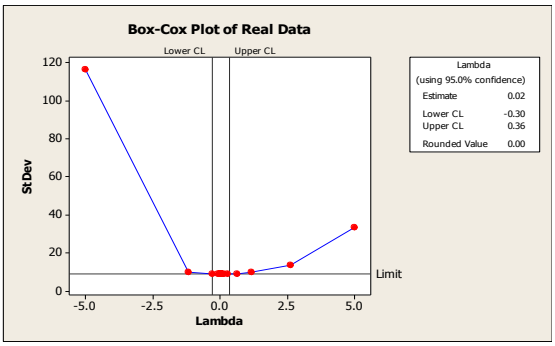
در این زیربخش به بررسی و مدلسازی داده‌های سری زمانی منطقه B می‌پردازیم. مجددا قدم اول بررسی ثبات میانگین و واریانس در طول زمان می‌باشد که در شکل‌های ۸ تا ۱۱ گزارش شده است.

[Downloaded from ieijqp.ir on 2026-11-06]

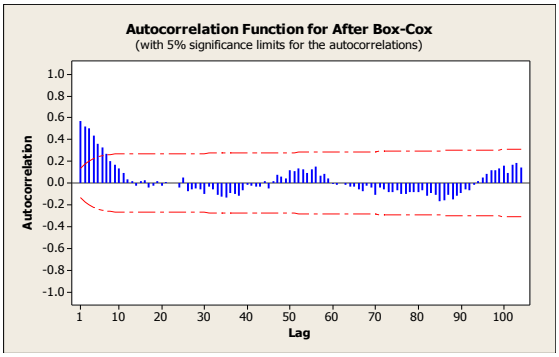
[DOR: 20.1001.1.23222344.1398.8.1.7.8]



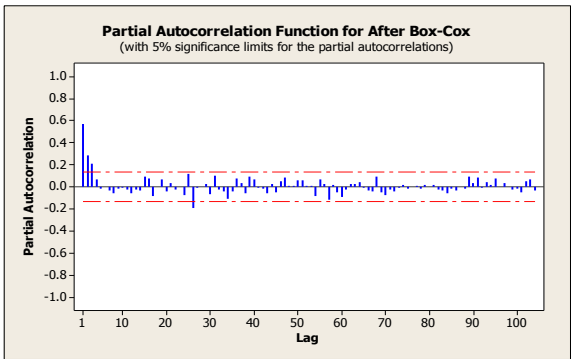
شکل (۸): نمودار نرخ خرابی تجهیز بصورت هفتگی در منطقه B



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

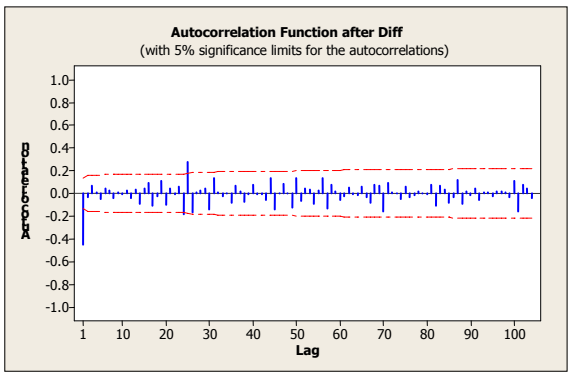


شکل (۱۰): نمودار تابع خودهمبستگی پس از اعمال پارامتر تبدیل بر روی داده های منطقه B

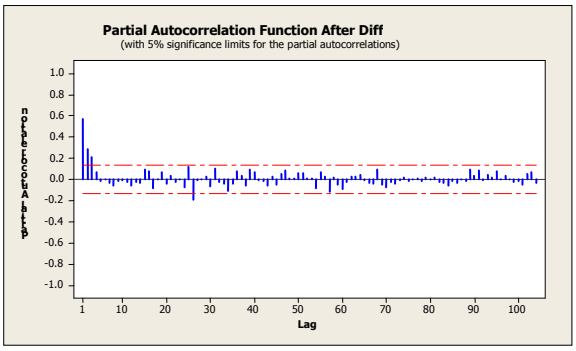


شکل (۱۱): نمودار تابع خودهمبستگی جزئی پس از اعمال پارامتر تبدیل بر روی داده های منطقه B

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 می کند. با توجه به شکل های ۱۰ و۱۱ 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 می گردند (شکلهای ۱۲ و ۱۳).



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



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

بر اساس روند موجود در شکلهای ۱۲ و ۱۳ و بعد از دو بار تفاضل گیری، بهترین گزینه ممکن می تواند 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				

[Downloaded from ieijqp.ir on 2026-11-06]

[DOR: 20.1001.1.23222344.1398.8.1.7.8]

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 باقی‌مانده‌ها 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 پیش‌بینی نرخ خرابی تجهیز مورد نظر از یک شبکه عصبی پرسپترون چندلایه با یادگیری رو به جلو استفاده می‌کنیم. برای این مسئله یک شبکه عصبی با یک و دو لایه پنهان ساخته می شود. تعداد نرون‌های 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 نرون‌ها 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 نرون‌ها 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 مدل‌های شبکه‌های عصبی نیز با معیار میانگین مربعات خطاها سنجیده می‌شود.

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.

۴-۱- پیش بینی با مدل های سری زمانی

براساس نتایج اولیه و مدل $SARIMA(0,1,1) \times (0,0,1)_{51}$ به $(1+0.8120B^{50})(1-B)(1-B^{51})X_t = (1-0.6886B)a_t$ دست آمده در منطقه A، نرخ خرابی شش هفته ابتدایی سال ۱۳۹۵ پیش‌بینی شد که نتایج آن در جدول ۵ گزارش شده است.

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

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

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 پیش‌بینی ۶ هفته ابتدایی سال ۱۳۹۵ نرخ خرابی در منطقه B براساس مدل سری زمانی

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

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 بهره‌گیری از میانگین مربعات خطاها میزان انحراف پیش‌بینی انجام شده با مقادیر واقعی سنجیده می شوند. جداول ۷ و ۸ نتایج حاصل را نشان می دهند.

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

[Downloaded from ieijqp.ir on 2026-11-06]

[DOR: 20.1001.1.23222344.1398.8.1.7.8]

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

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

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

در ادامه می بایست به مقایسه دو رویکرد به کار گرفته شده بپردازیم. نتایج بیانگر عملکرد بهتر مدل‌های سری زمانی در مقایسه با شبکه عصبی با عنایت به شاخص میانگین مربعات خطاها است، بدین مفهوم که مدل‌های 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 لایه‌های به کار رفته و بطور کلی عدم بهینه بودن شرایط توقف در شبکه عصبی انتخابی بوده باشد. همچنین در بین مدل‌های سری زمانی، مدل برازش شده بر روی داده‌های منطقه A دارای کمترین مقدار خطاست.

۵- نتیجه

شرکت های توزیع برق به منزله پیشانی صنعت برق در خط مقدم ارتباط با مردم می‌باشند و از حیث اینکه آینه بیرونی عملکرد صنعت برق می‌باشند و در روند بازتاب‌های اجتماعی موثر خواهند بود، از اهمیت خاصی برخوردارند. نتایج بررسی‌ها نشان می‌دهد که خاموشی-های حوزه توزیع، یکی از عمده‌ترین دلایل خاموشی‌های برق مشتریان هستند که متاثر از اتفاقات فنی و غیرفنی در شبکه‌های توزیع برق از جمله خرابی تجهیزات می باشند. در این راستا تکنیک‌های مختلفی وجود دارند که می‌توانند به منظور مدل سازی و پیش بینی تعداد خرابی‌های تجهیزات در آینده به کار آید. در این مقاله، از تکنیک تحلیل و آنالیز سری‌های 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 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 پیش‌بینی و کسب آمادگی لازم اکیپ‌های عملیاتی برای روبروشدن با خاموشی‌های بی‌برنامه و لذا تصمیم‌گیری به موقع به مسئولان شرکت توزیع نیروی برق تهران بزرگ خواهد کرد. در نهایت به‌عنوان 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", Internationl 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] Kutyłowska, 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 وفا.ح. "پیش بینی تقاضای بلندمدت انرژی الکتریکی با استفاده از الگوریتم ترکیبی عصبی-فازی و انبوه ذرات"، تحقیقات مدلسازی اقتصادی، شماره۱۰، ص ۲۱-۵۶، ۱۳۹۱.

[۸] سرورطاهرآبادی 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

[Downloaded from ieijqp.ir on 2026-11-06]

[DOR: 20.1001.1.23222344.1398.8.1.7.8]

کیفیت و بهره وری صنعت برق ایران ،جلد ۷، شماره۱۳، ص ۱۵-۲۷، ۱۳۹۷.

[۱۰] استادی، ب.، معتمدی. الف.، حسین زاده کاشان.، ع، امین ناصری، 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، شماره۱۳، 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 روش‌های یک متغیری و چند متغیری**. ترجمه نیرومند، ح. انتشارات دانشگاه فردوسی مشهد، ۱۳۸۶.

[۱۳] منهاج، م. **مبانی شبکه‌های عصبی**، ، انتشارات دانشگاه صنعتی امیرکبیر، ۱۳۹۶.

[Downloaded from ieijqp.ir on 2026-11-06]

[DOR: 20.1001.1.23222344.1398.8.1.7.8]