



مدل سازی و پیش بینی تولید و مصرف برق در ایران

محمد رضا امیدی

دانشجوی دکتری تحقیق در عملیات و مهندسی سیستم، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران

نبی امیدی

مریی، گروه مدیریت، دانشگاه پیام نور، ایران.

حشمت اله عسگری

دانشیار، دانشکده ادبیات و علوم انسانی، دانشگاه ایلام، ایران. (نویسنده مسئول)

he.asgari@gmail.com

میثم جعفری اسکندری

استادیار، گروه صنایع، دانشگاه پیام نور، ایران.

تاریخ دریافت: ۹۴/۷/۱۶ تاریخ پذیرش: ۹۴/۱۰/۲۹

چکیده

با توجه به رشد نسبتاً بالای مصرف انرژی در کشور، آینده پژوهی در حوزه انرژی الکتریکی به عنوان یک نهاده واسطه‌ی مهم در تولیدات صنعتی و به عنوان یک کالای نهایی و ضروری در بخش خانگی و تجاری، از الزامات نهادهای اجرایی کشور در زمینه تولید و مصرف برق می‌باشد. بررسی و پیش بینی تقاضا و تولید برق فاکتوری ارزشمند در دست مدیران صنعت برق برای اخذ تصمیمات راهبردی است. در این تحقیق با استفاده از سری زمانی تولید و مصرف برق بین سال‌های ۱۳۴۶-۱۳۹۲ و به کارگیری مدل‌های پیش‌بینی باکس جنکینز، شبکه عصبی مصنوعی و سیستم خاکستری که از پرکاربردترین روش‌های استفاده شده در مطالعات برای پیش‌بینی تقاضا و مصرف انرژی می‌باشند، علاوه بر میزان پیش‌بینی برای سال‌های آتی با استفاده از معیار میانگین درصد خطا دقت روش‌های پیش‌بینی نیز مورد مطالعه قرار گرفت. نتایج تحقیق نشان داد که روش باکس جنکینز بالاترین دقت را در پیش‌بینی تولید برق در کشور و شبکه عصبی مصنوعی بالاترین دقت در پیش‌بینی مصرف برق در کشور دارد. مقادیر پیش‌بینی شده نشان داد که نسبت تولید به مصرف برق در سال‌های آتی تقریباً ثابت با میل کاهنده خواهد بود، میزان تولید برق در ایران در سال ۱۳۹۸ به ۳۱۸۸۴۳ میلیون کیلووات بر ساعت و مصرف برق نیز به ۲۶۰۶۴۵ میلیون کیلووات بر ساعت خواهد رسید، که می‌توان با اصلاح الگوهای مصرف و استفاده از روش‌های نوین تولید نسبت تولید به مصرف را افزایش داد.

واژه‌های کلیدی: برق، پیش‌بینی، سری زمانی، شبکه عصبی، سیستم خاکستری.

مقدمه

امروزه انرژی الکتریکی به عنوان یکی از مهم ترین بخش های انرژی کشور ضمن داشتن نقش موثر در تولید و مصرف، اهمیت ویژه ای در فرایند تصمیم گیری اقتصادی دارد. آگاهی از میزان تقاضای انرژی الکتریکی در هر دوره به منظور برنامه ریزی دقیق، جهت اعمال سیاست گذاری های، امری ضروری می باشد. صنعت برق در جهان بیش از صد سال قدمت دارد. به طور کلی در سرتاسر جهان، این صنعت در حال حرکت به سمت بازارهای رقابتی و فرایند تجدید ساختار است، صنعت برق در ایران نیز در حال گذار از ساختار انحصار طبیعی به بازارهای رقابتی و ساختار جدیدی است که تولید کنندگان برای فروش انرژی به رقابت با یکدیگر میپردازند. مدل های اقتصاد سنجی تقاضای و تولید انرژی، قانونمندی حاکم بر روابط بین متغیرهای مدل را به آینده تسری می دهند. بنابراین، به کارگیری این مدل ها مستلزم وجود ثبات در رفتار مصرف کنندگان انرژی و در دسترس بودن تعداد زیادی مشاهدات تاریخی است. سیاست گذاران بخش های عرضه انرژی برای تامین تقاضا شده از حامل های انرژی نیازمند کسب اطلاعات و آگاهی از رفتار مصرف کنندگان این حامل ها می باشند. با توجه به اهمیت استراتژیک برق در میزان تقاضا شده، اطلاعات اکتسابی می بایست تا حد امکان دقیق و مطابق با واقعیت های آینده باشد. این اطلاعات می تواند براساس روند مشاهدات در دوره های زمانی گذشته به دست آید. یکی از مزایای پیش بینی، آگاهی از رفتار و تغییرات رفتاری متقاضیان در دوره های زمانی خاص می باشد که احتساب این موارد در داده های پیش بینی شده آینده، مفید است (صادقی و همکاران، ۱۳۸۸). آگاهی از رفتار مصرف کنندگان نسبت به تقاضای آن ها برای انرژی برق در آینده عاملی مهم در سیاستگذاری ها می باشد، به طوری که با آگاهی و از اطلاعات درست در این مورد می توان تعادل بین عرضه و تقاضا را در آینده ایجاد کرد. در این تحقیق با استفاده از آمار تولید و مصرف برق در ایران به پیش بینی برای آینده پرداخته میشود. روش های پیش بینی شامل سری زمانی باکس جنکینز، شبکه عصبی مصنوعی و سیستم های خاکستری است، که

علاوه بر پیش بینی دقت روش ها نیز با استفاده از شاخص های اندازه گیری دقت مورد ارزیابی قرار می گیرد.

مروری بر ادبیات پژوهش


کشورهای مختلف با برنامه ریزی و اعمال سیاست های حمایتی از انرژی های تجدید پذیر، سهم مشارکت منابع تجدید پذیر انرژی در بازار برق را بیشتر کرده اند (سامر^۱ و همکاران، ۲۰۰۱). تکنیک های متداول در پیش بینی تولید و مصرف برق مدل های متعددی برای بهبود کارایی سیستم پیشگو را به کار می گیرند. برخی مدل های پیش بینی توسط سری های زمانی ارائه شده است. مطالعات بسیاری در رابطه با تولید، مصرف برق در جهان صورت پذیرفته است. هاروی^۲ و کوپمن (۱۹۹۲) با استفاده از رویکرد سری زمانی ساختاری و در نظر گرفتن پارامترهای متغیر در زمان، تقاضای ساعتی برق برای شمال غرب آمریکا را بررسی کردند، آنگ^۳ (۱۹۸۸) تابع تقاضای برق را برای چهار کشور جنوب شرق آسیا شامل مالزی، سنگاپور، تایلند و تایوان برآورد کرد. نتایج این تحقیق نشان داد در کشورهای که درآمد سرانه بالاتری وجود دارد ضریب کشش درآمدی برق کوچکتر است. داربلای^۴ و همکاران (۲۰۰۰) به پیش بینی کوتاه مدت تقاضای برق در کشور چک می پردازد. در این مقاله ابتدا به پیش بینی تقاضای برق با استفاده از یک مدل غیر خطی یعنی شبکه های عصبی مصنوعی و سپس به پیش بینی همان تقاضا با استفاده از یک مدل خطی یعنی آریمای می پردازد. نتایج این تحقیق نشان داد که تقاضا کوتاه مدت از یک مدل خطی پیروی می کند و در نتیجه نمی توان از شبکه عصبی به عنوان یک مدل بهتر در پیش بینی تقاضای برق در کشور چک نام برد. هیپرت^۵ و همکاران (۲۰۰۰) به بررسی کاربرد شبکه های عصبی در پیش بینی تقاضای برق می پردازد. این تحقیق در واقع یک مرور و ارزیابی کلی نسبت به تحقیقات انجام شده در مورد پیش بینی تقاضای برق از سال ۱۹۹۱ تا ۱۹۹۹ می باشد و همچنین به مشکلات، نقاط ضعف و قوت شبکه های عصبی مصنوعی نسبت به مدل های دیگر نیز اشاره میکند. اتستول^۶ (۲۰۰۲) به کمک داده های سال های

برای کره جنوبی و اندونزی در سطح کلان و بخش خانگی را با استفاده از رویکرد سری زمانی ساختاری انجام داد. وی با استفاده از این رویکرد اقدام به برآورد روند ضمنی تقاضای انرژی که نه تنها پیشرفت فنی بلکه سلیقه و ساختار اقتصاد را نشان می‌دهد، نمود.


روش‌شناسی پژوهش

این پژوهش از نوع تحلیلی گذشته نگر است که با استفاده از اطلاعات پس رویدادی که به روش کتابخانه ای جمع آوری شده است به پیش بینی برای آینده می‌پردازد. جامعه مورد نیاز از طریق آمار رسمی وزارت نیرو اخذ گردیده‌اند. برآورد حجم نمونه به صورت قضاوتی بوده است. داده‌های آماری که در این تحقیق مورد مطالعه قرار گرفته‌اند میزان تولید و مصرف برق بین سال‌های ۱۳۴۶ تا ۱۳۹۲ بوده است. داده‌های تولید برق شامل میزان تولید وزارت نیرو و سایر نهادها در نیروگاه‌های گازی، بخاری، چرخه ترکیبی، دیزلی، برقابی و اتمی تجدید ناپذیر می‌باشد. مصرف برق شامل میزان مصرف در بخش‌های خانگی، عمومی، روشنایی معابر، کشاورزی، صنعتی، و سایر مصارف بوده و شامل مصرف‌های غیر قانونی و ناشی از اتلاف در شبکه‌های توزیع نیست. در سرتاسر تحقیق میزان تولید و مصرف برحسب میلیون کیلووات بر ساعت می‌باشد. نمودارهای ۱ و ۲ سری زمانی تولید و مصرف برق را نشان می‌دهد.

۱۹۷۰ تا ۱۹۹۹ تقاضای برق خانگی نیروژ را تخمین می‌زند. متغیرهای مستقل در این بخش عبارتند از: قیمت واقعی برق، قیمت واقعی نفت و مخارج مصرفی خانوار. نتایج به دست آمده حاکی از کم‌کشش بودن تقاضای برق نسبت به قیمت و با کشش بودن آن نسبت به درآمد است. ژانگ^۷ (۲۰۰۳) ترکیب مدل‌های شبکه عصبی مصنوعی و آریمای را به عنوان یک راهکار بهینه در پیش بینی سری‌های زمانی عنوان می‌کند که ترکیب مدل‌های شبکه عصبی مصنوعی به عنوان یک مدل غیر خطی، با مدل آریمای به عنوان یک مدل خطی در پیش بینی سری‌های زمانی عملکرد بهتری نسبت به پیش بینی صورت گرفته با استفاده از هریک از مدل‌ها به تنهایی دارد. در نهایت با استفاده از چند داده تجربی فرضیه خود را به اثبات می‌رساند. دمیتروپولس^۸ و همکاران (۲۰۰۵) با استفاده از داده‌های سالانه برای دوره ۱۹۶۷ تا ۲۰۰۲ تقاضای انرژی بخش‌های مختلف بریتانیا را برآورد کردند جیمز^۹ و همکاران (۲۰۰۶) به مطالعه تطبیقی روش شبکه عصبی مصنوعی و آریمای برای ایرلند و ولز پرداخته‌اند که نتایج مطالعه آن‌ها بیانگر قدرت بالای شبکه عصبی در پیش بینی کوتاه مدت بوده است. هامزچی^{۱۰} (۲۰۰۷) مصرف برق ترکیه را بر پایه داده‌های فصلی تا سال ۲۰۲۰ با به کارگیری مدل شبکه عصبی پیش بینی نمود. فرانک^{۱۱} و همکاران (۲۰۰۸) با به کارگیری شبکه عصبی مصنوعی و سری‌های فوری، تقاضای ماهیانه برق اسپانیا را برآورد کرده‌اند. در این مطالعه سری فوریه نتایج مناسب تری نسبت به مدل‌های شبکه عصبی مصنوعی و آریمای ارائه کرده‌ست. بنودا^{۱۲} و همکاران (۲۰۰۹) با استفاده از مدل تجزیه‌ی چندمقیاسی غیرخطی موجک به پیش بینی برق استرالیا پرداخته‌اند. در این مطالعه یک روش خودرگرسیو پیشنهاد شده است که بر پایه تجزیه چندمقیاسی موجک به پیش بینی ۱ ساعت به جلو بر اساس داده‌های گذشته می‌پردازد. آن‌ها نتایج تولید شده به وسیله متد خودرگرسیو چندمقیاسی را در دو حالت خطی و غیر خطی همراه با اتورگرسیون و شبکه عصبی پرسپترون چند لایه بر اساس معیارهای دقت پیش بینی بررسی کرده‌اند. سالیمان^{۱۳} (۲۰۱۱) تخمین توابع تقاضای انرژی



نمودار ۱- سری زمانی میزان تولید برق (میلیون کیلو وات ساعت)



نمودار ۲- سری زمانی مصرف برق (میلیون کیلو وات ساعت)

مدلهای پیش بینی

مدل سری زمانی باکس و جنکینز

در تحلیل باکس و جنکینز، پیش بینی سری زمانی تک متغیره با مدل بندی آماری صورت می گیرد. پیش بینی با استفاده از روش باکس و جنکینز در چهار مرحله تشکیل شده است که شامل تشخیص، تخمین، کنترل و پیش بینی می باشد (نیکوکار، ۱۳۸۶). مدل های باکس و جنکینز شامل فرآیند خودرگرسیون (AR^{14}) فرآیند میانگین متحرک (MA^{15}) فرآیند خودرگرسیون میانگین متحرک ($ARMA^{16}$) و فرآیند خودرگرسیون میانگین متحرک انباشته ($ARIMA^{17}$) می باشد.

فرآیند خودرگرسیون (AR): این الگو در واقع یک الگوی رگرسیون چندگانه است با این تفاوت که متغیر

وابسته Z روی متغیرهای مستقل (X_1, X_2, \dots, X_N) رگرسیون نشده بلکه روی مقادیر گذشته خود رگرسیون شده است و به این دلیل است که این فرآیند را اتورگرسیون نامیده اند. یک فرآیند اتورگرسیون مرتبه P را با نماد اختصاری $AR(P)$ نمایش میدهند. اگر a_t یک فرآیند تصادفی محض با میانگین صفر و واریانس ثابت باشند فرآیند Z اتورگرسیون مرتبه P به شکل معادله زیرمی باشد.

$$Z_t = \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_p Z_{t-p} + a_t \quad (1)$$

فرآیند میانگین متحرک (MA): فرآیند میانگین متحرک در بیان پدیده ای به کار می روند که در آن

در این روش تنها تعیین تعداد وقفه های میزان تولید و مصرف برق و همچنین تشخیص ساختار متغیر تصادفی در مدل میباشد. برای این کار از روش استاندارد و متداول در این زمینه یعنی متدلوژی باکس و جنکینز استفاده خواهیم کرد. در این روش، تعداد وقفه ها و ساختار متغیر تصادفی بر اساس توابع خود همبستگی^{۱۸} و خود همبستگی جزئی^{۱۹} بین خطاهای مدل تعیین میگردند.

شبکه های عصبی مصنوعی

امروزه به موازات مدل های قبلی روش های جدید تری برای پیش بینی ابداع شده است. در این روش ها که شبکه عصبی مصنوعی نامیده می شوند با استفاده از هوش مصنوعی روابط پیچیده بین متغیرها فراگرفته می شود. شبکه های عصبی مصنوعی در حقیقت مدل ساده شده ای از سیستم عصبی مرکزی هستند و مانند مغز با پردازش داده های تجربی، قانون داده ها را به ساختار شبکه منتقل میکنند (شایگان و همکاران، ۱۳۸۶). مغز به عنوان یک سیستم پردازش اطلاعات از عناصر اصلی ساختاری به نام نرون تشکیل شده است. در حقیقت نرون ها ساده ترین واحد ساختاری سیستم های عصبی هستند. شبکه های عصبی علیرغم تنوع، از ساختار مشابهی برخوردار می باشند. یک شبکه عصبی معمولاً از سه لایه ورودی، پنهان و خروجی تشکیل شده است. لایه ورودی فقط اطلاعات را دریافت میکند و مشابه متغیر مستقل عمل میکند. لذا تعداد نرون های لایه ورودی بر اساس طبیعت مسئله تعیین می شود و بستگی به تعداد متغیرهای مستقل دارد. لایه خروجی نیز همانند متغیر وابسته عمل کرده و تعداد نرون های آن بستگی به تعداد متغیرهای مستقل دارد. لایه خروجی نیز همانند متغیر وابسته عمل کرده و تعداد نرون های آن بستگی به تعداد متغیر وابسته دارد. اما برخلاف لایه های ورودی و خروجی لایه پنهان هیچ مفهومی را نشان نمی دهد و صرفاً یک نتیجه میانی در فرایند محاسبه ارزش خروجی هستند. به منظور طراحی و آموزش شبکه عصبی مصنوعی، داده ها به دو مجموعه داده های آزمایشی و آموزشی تقسیم شدند. مانند روش های معمول پیش بینی ۹۰ درصد داده های تولید و مصرف برق به عنوان

پیشامدها یک اثر آنی را به وجود می آورند که فقط برای مدت کوتاهی باقی می ماند. اگر a_t فرآیند تصادفی محض با میانگین صفر و واریانس ثابت باشد در این صورت فرآیند Z_t را فرآیند میانگین متحرک تا مرتبه q میگوییم هرگاه معادله زیر (معادله شماره ۲) برقرار باشد. که در آن θ_i ثابت و θ_0 برابر یک در نظر گرفته میشود. یک فرآیند میانگین متحرک از مرتبه q را با نماد اختصاری $MA(q)$ نمایش می دهند.

$$Z_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2)$$

فرآیند خودرگرسیون میانگین متحرک (ARMA):
در این فرایند احتمال اینکه سری زمانی Z دارای ویژگی های هر دو فرآیند AR و MA باشد زیاد است به همین دلیل به این فرآیند ARMA گفته میشود. بنابراین Z را یک فرآیند $ARMA(p, q)$ گویند که شامل p مرتبه جمله خودرگرسیون و q مرتبه میانگین متحرک باشد (معادله شماره ۳).

$$Z_t = \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (3)$$

فرآیند خودرگرسیون میانگین متحرک انباشته (ARIMA): مدل هایی قبلی برای فرض استوار می باشند که سری های زمانی ساکن هستند. به طوریکه میانگین و واریانس سری های زمانی ثابت می باشند و کوواریانس آنها در طی زمان بدون تغییر است. اما بسیاری از سری های زمانی غیر ساکن هستند بنابراین این سری ها انباشته میباشند اگر یک سری زمانی پس از d مرتبه تفاضل گیری مرتبه اول ساکن شود و سپس آن را توسط فرآیند $ARMA(p, q)$ مدل سازی کنیم در این صورت سری زمانی اصلی سری زمانی $ARIMA(p, d, q)$ می باشد که در آن p تعداد جمله خودرگرسیون q تعداد جمله میانگین متحرک و d تعداد دفعات تفاضل گیری مرتبه اول برای ساکن شدن سری زمانی می باشد. سوال اساسی در این پژوهش این است که در بین الگوهای مختلف سری زمانی باید کدام الگو انتخاب شود و بر چه اساسی انتخاب صورت میگیرد. بنابراین مهمترین مسئله

روش پیش بینی خاکستری

تئوری سیستم های خاکستری در سال ۱۹۸۲ توسط دنگ معرفی شد. کارآمدی این روش ها در مواجهه با عدم قطعیت و اطلاعات ناکافی اثبات شده است. نظریه سیستم های خاکستری شامل پنج بخش اصلی است که عبارت اند از: پیش بینی خاکستری، رابطه خاکستری، تصمیم خاکستری، برنامه ریزی خاکستری و کنترل خاکستری. مدل پیش بینی خاکستری را می توان به عنوان هسته اصلی نظریه خاکستری دانست. کاربرد اصلی نظریه خاکستری در شرایط عدم قطعیت با داده های کم و اطلاعات ناکافی است. مزیت نظریه خاکستری بر نظریه فازی در این است که نظریه خاکستری شرایط فازی بودن را در برمیگیرد، به عبارت بهتر نظریه خاکستری می تواند به خوبی در شرایط فازی عمل کند. به کارگیری نظریه فازی مستلزم تشخیص تابع عضویت مربوطه بر اساس تجربه خبرگان است. اما نظریه خاکستری بدون در نظر داشتن تابع عضویت و بر اساس محدوده اطلاعات در دسترس به خوبی عمل می کند (کورلینیوس^{۲۱} و همکاران، ۲۰۰۷). تحلیل رابطه ای خاکستری نیز به عنوان روش برای حل مسائل مختلف تصمیم گیری چند شاخصه تا کنون در حوزه های متعدد تخصصی و عمومی به کار گرفته شده است. مزیت اصلی نظریه سیستم های خاکستری نیاز به حجم داده های کم است. در واقع نظریه های سیستم های خاکستری به عنوان یک روش بسیار موثر برای داده های گسسته است (لیو^{۲۲} و همکاران، ۲۰۰۴). در مدل های پیش بینی خاکستری، مقادیر آینده را برای سری زمانی که در بازه های زمانی یکسان اندازه گیری شده اند، پیش بینی می کنند. اساس پیش بینی این مدل ها بر پایه جدیدترین مجموعه داده ها شکل می گیرد و تمامی داده ها مورد استفاده برای پیش بینی دارای مقادیر مثبت هستند و این دنباله داده ها ثابت هستند، وظیفه اصلی نظریه سیستم های خاکستری، استخراج قانون حاکم بر سیستم، با استفاده از دنباله سری داده های موجود است. این فرآیند به عنوان تولید دنباله خاکستری شناخته شده است. در نظریه سیستم های خاکستری مدل GM(n,m) به عنوان مدل پیش بینی خاکستری مشخص می شود که در آن n بیانگر

داده های آموزشی و از ۱۰ درصد باقی مانده به عنوان داده های آزمایشی استفاده شده است. اما پیش از آموزش و آزمایش شبکه داده ها بر اساس روش نرمال سازی آماری، نرمال سازی شدند. تحقیقات نشان داده است که نرمال سازی داده ها عموماً باعث بهبود شبکه می گردد، با این حال در مواردی که تعداد داده ها افزایش می یابد، نرمال سازی داده ها چندان مفید نمی باشد (شانکر^{۲۰} و همکاران، ۱۹۹۶). روش های زیادی برای نرمال سازی داده ها وجود دارد، اما یکی از روش های معمول در این زمینه نرمال سازی آماری می باشد. در صورت استفاده از این تبدیل، میانگین داده ها صفر و انحراف معیار آن ها برابر با یک خواهد شد. برای این منظور می توان از رابطه زیر استفاده نمود

$$X_n = (X_0 - \bar{X}) / S \quad (۴)$$

که در آن X_0, X_n, \bar{X} به ترتیب داده نرمال شده، داده اصلی و میانگین داده بوده و S انحراف معیار می باشد. در شبکه های عصبی پیش خور در هر مرحله داده ها وزن دار شده و بعد به لایه بعد فرستاده می شوند. در ابتدا هر نرون مجموع داده ها وزن دار شده را با توجه به تابع فعال سازی دسته بندی نموده و نتایج را به نرون لایه بعدی می فرستد. لذا نتیجه پروسه نرون ز به صورت زیر محاسبه میگردد:

$$O_j = F(\sum W_{ij}X_i + w_{j0}B_j) \quad (۵)$$

که در آن O_j : خروجی؛ F: تابع فعال سازی؛ X_i : ورودی i ام؛ W_{ij} : وزن بین ورودی i ام و نرون j ام w_{j0} وزن بین نرون اریب B_j و نرون j می باشد.

برای پیش بینی با دقت بالا در این تحقیق از شبکه پیشخور پرسپترون استفاده شده است. در شبکه عصبی پرسپترون با یک لایه مخفی از روش آزمون و خطا استفاده می شود. در نهایت با بهره گیری از الگوریتم پس انتشار خطا، شبکه آموزش داده شد و با استفاده معیار های دقت، بهترین شبکه برای میزان تولید و مصرف برق مشخص گردید که نتایج آن در جدول ۶ می باشد.

این روش هیچ اثبات ریاضی ندارد و آن را روش سفید سازی می نامند. در اینجا i یک نقطه زمانی است، a را ضریب بهبود و b را ضریب کنترل خاکستری گویند که با استفاده از روش حداقل مربعات به صورت زیر قابل محاسبه هستند بر طبق معادله ۶ چنانچه:

$$A = \begin{bmatrix} -Z^1(1) & 1 \\ -Z^1(2) & 1 \\ \vdots & \vdots \\ -Z^1(n) & 1 \end{bmatrix} \quad (12)$$

$$X_n = \begin{bmatrix} x^0(2) \\ x^0(3) \\ \vdots \\ x^0(n) \end{bmatrix} \quad (13)$$

$$\beta = \begin{bmatrix} a \\ b \end{bmatrix} \quad (14)$$

با استفاده از روش حداقل مربعات :

$$\sum e_i^2 = e'e = (X_n - A\beta)'(X_n - A\beta) \\ = X_n'X_n - X_n'A\beta - \beta'A'X_n + \beta'A'A\beta \\ = X_n'X_n - 2\beta'A'X_n + \beta'A'A\beta \quad (15)$$

$$\frac{\partial(e'e)}{\partial\beta} = -2A'X_n + 2A'A\beta = 0$$

$$\beta = \begin{bmatrix} a \\ b \end{bmatrix} = (A'A)^{-1}A'X_n'$$

پس از محاسبه ضرایب a ، b معادله پیش بینی خاکستری به ترتیب زیر به دست می آید، حال چنانچه از معادله ۵ تبدیل لاپلاس بگیریم معادله زیر را خواهیم داشت:

$$sx^1(s) - u(0) + ax^1(s) = \frac{b}{s} \quad (16)$$

$$x^1(s) = \frac{x^0(1) - \frac{b}{a}}{s+a} + \frac{b}{s} \quad (17)$$

چنانچه از معادله ۱۳ معکوس تبدیل لاپلاس بگیریم

$$x^1(i+1) = \left(x^0(1) - \frac{b}{a}\right)e^{-ai} + \frac{b}{s} \quad (18)$$

درجه معادله دیفرانسیل استفاده شده در مدل و m بیانگر تعداد متغیرهای موجود در مدل است. در این تحقیق برای پیش بینی تولید و مصرف برق از مدل $GM(1,1)$ استفاده شده و دلیل آن در سادگی مدل سازی، اجرای مدل و همچنین در استفاده از تعداد داده های زمانی کمتر است. مدل پیش بینی خاکستری دارای سه عملگر اپراتور جمع کننده، اپراتور معکوس جمع و مدل خاکستری می باشد مراحل اجرای یک مدل پیش بینی خاکستری به شرح زیر است:

- اپراتور جمع

اگر $x^{(0)}$ سری زمانی با n نمونه به شکل زیر باشد:

$$x^0 = \{x^0(1), x^0(2), \dots, x^0(n)\} \quad (6)$$

با استفاده از اپراتور جمع، سری نامنظم $x^{(0)}$ را به صورت یکنواخت افزایشی به سری زمانی زیر تبدیل می شود:

$$x^{(1)}(j) = \sum_{i=1}^j x^{(0)}(i) \quad (7)$$

(۳)

$$x^{(1)} = \{\sum_{i=1}^1 x^{(0)}(i), \sum_{i=1}^2 x^{(0)}(i), \dots, \sum_{i=1}^n x^{(0)}(i)\}$$

- اپراتور معکوس جمع

با استفاده از اپراتور معکوس جمع، $x^{(0)}(i)$ به شکل زیر قابل محاسبه است:

$$x^{(0)}(i) = x^{(1)}(i) - x^{(1)}(i-1) \quad (8)$$

- مدل خاکستری

مدل خاکستری با استفاده از معادله دیفرانسیل خاکستری درجه ۱ زیر تشکیل داده می شود:

$$\frac{dx^1}{dt} + ax^{(1)} = b \quad (9)$$

معادله سفید شده معادله (۳) به صورت زیر است:

$$x^{(0)}(i) + az^{(1)}(i) = b \quad (10)$$

که در آن :

$$z^{(1)}(i) = \frac{1}{2}(x^1(i) + x^1(i+1)) \quad (11)$$

بنابراین مطابق معادله (۴) خواهیم داشت:

(۱۹)

$$\begin{aligned} \hat{x}^1(i+1) &= \hat{x}(i+1) - \hat{x}(i) \\ &= \left(x^0(1) - \frac{b}{a}\right)(1 - e^a)e^{-ai} \end{aligned}$$

به دین ترتیب داده های $\{x^0(1), x^0(2), \dots, x^0(n)\}$ سری هموار شده و سری داده های $\{\hat{x}^0(n+1), \hat{x}^0(n+2), \dots, \hat{x}^0(n+k)\}$ (سری پیش بینی خواهند بود).


نتایج حاصل از پیش بینی با استفاده از مدل‌های باکس جنکینز

مدل باکس جنکینز برای پیش بینی سری های زمانی شامل چهار مرحله تشخیص، تخمین، کنترل و پیش بینی است.

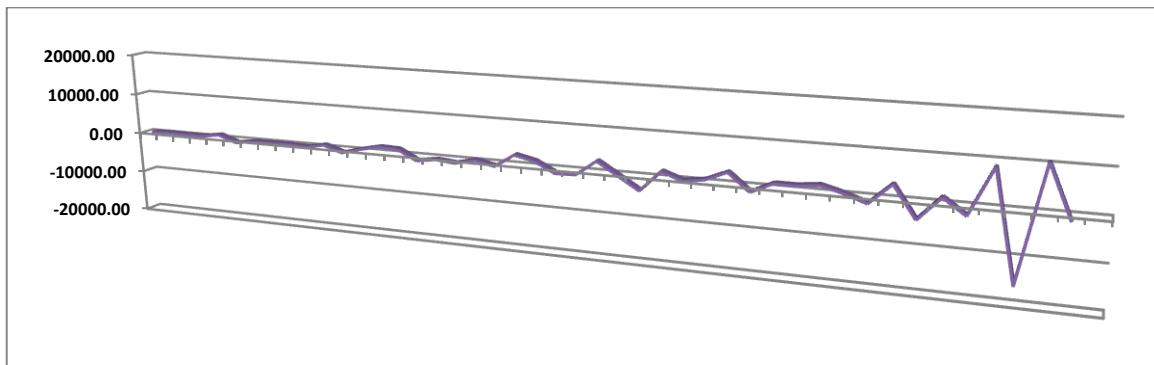
مرحله اول (تشخیص یا شناسایی) (۲۳): در این مرحله باید مقادیر واقعی p, q, d مدل ARIMA مشخص شود که برای این منظور از ابزار نمودار همبستگی (ACF) و همبستگی جزئی (PACF) استفاده میشود. خودهمبستگی جزئی همبستگی بین مشاهدات را اندازه گیری می کند

به عبارت دیگر همبستگی بین Z_t و Z_{t-k} بعد از حذف تاثیر Z های میانی، هدف باکس - جنکینز شناسایی و تعیین مدل آماری است، که میتوان آن را مدل تولید کننده داده های نمونه واقعی از فرایند تصادفی تعبیر کرد. اگر بخواهیم از این مدل برای پیش بینی استفاده نماییم می باست ویژگی های این مدل در طی زمان ثابت باشد اگر سری مشاهده شده نسبت به میانگین نایستا باشد در این صورت می توان سری را تفاضلی کرده تا سری مورد نظر به یک سری ایستا تبدیل شود. برای ایستا کردن داده های مربوط به میزان تولید و مصرف برق، از داده های مربوط به تولید و مصرف دو بر تفاضل گیری می کنیم. نمودارهای ۳ و ۴ نتیجه این تفاضل گیری را نشان می دهد.



بعد از ایستا کردن داده ها با استفاده از شکل توابع ACF و PACF مدل مناسب برای داده ها شناسایی میگردد. نمودار ۵ و ۶ مقادیر توابع ACF و PACF تفاضل مرتبه دوم تولید و مصرف برق را نشان می دهد.





نمودار ۳- تفاضل مرتبه دوم تولید برق



نمودار ۴. تفاضل مرتبه دوم میزان مصرف برق



نمودار ۵- توابع ACF و PACF تفاضل مرتبه دوم تولید برق



نمودار ۶- توابع ACF و PACF تفاضل مرتبه دوم مصرف برق

میزان مصرف در برق مدل $ARIMA(3.2.0)$ است یعنی با دوبار تفاضل گیری می توان از طریق فرایند $AR(2)$ میزان مصرف برق را مدل سازی کرد. مرحله دوم (تخمین^{۲۴}) : بعد از تشخیص مدل به تخمین پارامترهای مدل می پردازیم. برای تخمین ضرایب مدل از روش حداقل مربعات استفاده شده است ولی

تحلیل و بررسی تابع خودهمبستگی و خود همبستگی جزئی نشان میدهد مناسب ترین مدل برای میزان تولید برق $ARIMA(1.2.0)$ است بدین معنا که سری زمانی تولید برق باید دو بار برای ایستا شدن تفاضل گیری شود ($d=2$) سپس توسط یک فرایند $AR(2)$ مدل سازی گردد، همچنین مناسب ترین مدل برای

است یک مدل ARIMA دیگر برازش بهتری از داده‌ها ارائه نماید یک آزمون ساده برای بررسی این نکته آن است که می‌بایست باقی مانده‌های حاصل از این مدل اختلال سفید باشند^{۲۶} یعنی دارای توزیع نرمال، واریانس ثابت و میانگین صفر باشند نتایج نشان داد که باقی مانده‌های حاصل برای تعداد تولید و مصرف اختلال سفید هستند. همچنین در جدول شماره ۲ و ۳ مقادیر محاسبه شده برای ضرایب مدل آورده شده است. که نشان می‌دهد با سطح اطمینان بالایی مدل ارائه شده، مناسب ترین مدل در بین الگوهی ARIMA برای روند تغییرات سری زمانی تولید و مصرف برق هستند. مرحله چهارم (پیش بینی^{۲۷}): مقادیر پیش بینی شده با استفاده از الگوهای سری زمانی در جدول ۴ نشان داده شده است.

زمانی که مدل نسبت به پارامترهای غیرخطی باشد به روش‌های غیرخطی متوسل می‌شویم. ضرایب مدل برای مدل ARIMA (2,1,0) و ARIMA(3,2,0) به شکل معادلات زیر به دست آمد.

(۲۰) معادله تولید برق

$$Z_t = -0.6223Z_{t-1} + a_t$$

(۲۱) معادله مصرف برق

$$Z_t = -1.094Z_{t-1} - 0.7672Z_{t-2} - 0.4718Z_{t-3} + a_t$$

مرحله سوم (کنترل تشخیصی^{۲۵}): پس از انتخاب یک مدل خاص ARIMA و تخمین پارامترهای آن به دنبال این هستیم که آیا مدل انتخاب داده‌ها به خوبی برازش می‌کنند؟ عبارت دیگر آیا مدل انتخاب مناسب ترین مدل برای توصیف داده‌ها می‌باشد. زیرا ممکن

جدول ۲- مقادیر محاسبه شده برای ضرایب مدل ARIMA میزان تولید برق

سطح معناداری	ضریب	انحراف معیار	T آماره	سطح معناداری
مقدار ثابت	۳۵۵,۲	۳۰۳,۲	۱,۱۷	۰,۲۴۸
AR(1)	-۰,۶۲۲۳	۰,۳۹۵۷	-۱,۵۷	۰,۰۰۰

جدول ۳- مقادیر محاسبه شده برای ضرایب ARMA میزان مصرف برق

سطح معناداری	ضریب	انحراف معیار	T آماره	سطح معناداری
مقدار ثابت	۶۳۲,۲	۳۲۷	۱,۹۳	۰,۰۰۶
AR(1)	-۱,۰۹۴	۰,۱۴۱۱	-۷,۷۵	۰,۰۳۱
AR(2)	-۰,۷۶۷۲	۰,۱۹۶۸	-۳,۸۹	۰۰۰
AR(3)	۰,۴۷۱۷	۰,۲۰۸۵	۲,۲۶	۰۰۰

جدول ۴- مقادیر پیش بینی شده با استفاده از الگوی سری زمانی باکس و جنکینز

MAPE	۱۳۹۸	۱۳۹۷	۱۳۹۶	۱۳۹۵	۱۳۹۴	۱۳۹۳	
میزان تولید برق	۲۶۵۴۵۲	۲۷۴۹۴۷	۲۸۶۲۳۱	۲۹۶۶۵۱	۳۰۷۸۶۵	۳۱۸۸۴۳	0.0292
میزان مصرف برق	۲۱۳۵۷۶	۲۱۹۰۲۱	۲۳۰۰۳۳	۲۳۸۷۲۶	۲۴۸۶۸۱	۲۵۷۰۴۰	۰,۰۴۵۱

پیش بینی شده از روش سیستم خاکستری را نشان می‌دهد.

نتایج پیش بینی با استفاده از شبکه عصبی و سیستم خاکستری

جدول شماره ۶ نتایج حاصل از پیش بینی با استفاده از روش شبکه عصبی مصنوعی و جدول هفت مقادیر

جدول ۶- نتایج پیش بینی با استفاده از شبکه عصبی مصنوعی

MAPE	۱۳۹۸	۱۳۹۷	۱۳۹۶	۱۳۹۵	۱۳۹۴	۱۳۹۳	
تولید برق	۰,۰۴۱۲	۳۱۸۹۹۴	۳۰۸۹۲۳	۲۹۷۱۵۵	۲۸۷۹۲۲	۲۷۵۳۱۳	۲۶۶۹۱۴
مصرف برق	۰,۰۳۰۰	۲۶۰۶۴۵	۲۴۷۸۶۲	۲۲۴۰۵۰	۲۲۲۲۷۳	۲۱۴۰۸۲	۲۰۴۱۱۲

جدول ۷- نتایج پیش بینی با استفاده از روش سیستم خاکستری

MAPE	۱۳۹۸	۱۳۹۷	۱۳۹۶	۱۳۹۵	۱۳۹۴	۱۳۹۳	
تولید برق	۰,۰۷۴۵	۳۳۲۴۱۰	۳۲۰۶۶۰	۲۹۷۶۴۰	۲۸۶۳۶۰	۲۷۵۲۴	۲۶۴۲۸
مصرف برق	۰,۰۹۴۱	۲۶۳۷۸۰	۲۵۵۵۹۰	۲۴۲۷۰۰	۲۳۴۹۲۰	۲۲۲۴۵۰	۲۱۵۰۷۰


مقایسه دقت مدل های پیش بینی

در تحقیقات مربوط به پیش بینی معیارهای ارزیابی متنوعی توسط مولفان مورد استفاده قرار گرفته است از قبیل: میانگین مربعات خطا (دسی و بهاراتی^{۲۸}، ۱۹۹۸)، میانگین مربعات خطای نرمالیزه شده و ریشه میانگین مربعات خطا (سیکمن و گبهارت^{۲۹}، ۲۰۰۱)، میانگین قدر مطلق خطا و میانگین قدر مطلق درصد خطا. در این تحقیق از معیار میانگین درصد خطا استفاده شده است به نحوی که هر یک از روش های پیش بینی که میانگین درص خطای کمتری در پیش بینی داشت دقت بیشتر در پیش بینی دارد و می تواند از آن برای پیش بینی برای


سال های آینده استفاده کرد. همانطور که در جدول ۸ نشان داده شده است درصد میانگین خطا برای میزان تولید برق در روش باکس جنکینز از دو روش دیگر کمتر است، همچنین روش شبکه عصبی مصنوعی نسبت به سایر روش ها دارای درصد میانگین خطای کمتری است. نمودار ۷ و ۸ میزان مقدار پیش بینی شده و واقعی در دوره های گذشته را برای روش های منتخب نشان می دهد و نسبت مقادیر تولید به مصرف در جدول ۹ نشان داده شده است.

جدول ۸- میزان درصد میانگین خطا برای مدل های پیش بینی

مدل باکس جنکینز	شبکه عصبی مصنوعی	سیستم خاکستری	
۰,۰۲۹۲	۰,۰۴۱۲	۰,۰۷۴۵	درصد میانگین خطا میزان تولید
۰,۰۴۵۱	۰,۰۳۰۰	۰,۰۹۴۱	درصد میانگین خطا میزان مصرف



نمودار (۷) - مقادیر پیش بینی شده و واقعی میزان تولید برق با استفاده از روش باکس جنکینز



نمودار (۸) مقادیر پیش بینی شده و واقعی میزان مصرف برق با استفاده از شبکه عصبی مصنوعی

جدول ۸. مقادیر پیش بینی شده با استفاده از روش های منتخب

۱۳۹۸	۱۳۹۷	۱۳۹۶	۱۳۹۵	۱۳۹۴	۱۳۹۳	
۳۱۸۸۴۳	۳۰۷۸۶۵	۲۹۶۶۵۱	۲۸۶۲۳۱	۲۷۴۹۴۷	۲۶۵۴۵۲	پیش بینی تولید برق با باکس جنکینز
۲۶۰۶۴۵	۲۴۷۸۶۲	۲۲۴۰۵۰	۲۲۲۲۷۳	۲۱۴۰۸۲	۲۰۴۱۱۲	پیش بینی مصرف برق با شبکه عصبی
۱,۲۲	۱,۲۴	۱,۳۲	۱,۲۸	۱,۲۸	۱,۳۰	نسبت تولید به مصرف

نتیجه گیری

حامل های انرژی بعد از انقلاب صنعتی به عنوان یکی از نهاده های مهم در راستای تحقق توسعه ی اقتصادی جوامع صنعتی، نقش به سزایی ایفا کرده اند. امروزه انرژی برق به دلیل ارتباط با سایر بخش ها و نهاد های اقتصادی، نقش قابل توجه ای در فرایند تصمیم گیری های اقتصادی و پیش برد اهداف توسعه ی کشورها ایفا می کند. در این تحقیق با استفاده از سه روش پیش بینی سری زمانی باکس جنکینز، شبکه عصبی مصنوعی و سیستم های خاکستری و با استفاده از آمار تولید و مصرف برق به پیش بینی برای سال های آتی پرداخته شد. نتایج این تحقیق نشان داد که سری زمانی باکس جنکینز دارای دقت بیشتری در پیش بینی تولید برق و شبکه عصبی مصنوعی دقت بیشتری در پیش بینی مصرف برق در کشور می باشند همچنین سیستم های خاکستری نسبت به دو روش دیگر دارای دقت کمتری است. بررسی مقادیر پیش بینی شده نشان می دهد که نسبت تولید به مصرف برق در سال های آتی تقریباً ثابت با میل کاهنده خواهد بود و در سال ۱۳۹۸ به ۱,۲۲ می رسد که می توان با اصلاح الگوی مصرف و استفاده از

روش های نوین تولید برق این نسبت را افزایش داد و موجب توسعه صادرات برق و ارز آوری برای کشور شد.

فهرست منابع

- ۱) صادقی، حسین؛ ذولفقاری، مهدی (۱۳۸۸)، طراحی مدلی نوین جهت پیش بینی تقاضای کوتاه مدت گاز طبیعی در بخش خانگی، فصلنامه مطالعات اقتصادی انرژی شماره ۲۳، ۷۸-۴۱.
- ۲) شایگان، محمد؛ محمدی، حمید؛ موسوی، سید نعمت اله (۱۳۸۶)، پیش بینی میزان واردات برنج و ذرت با استفاده از روش شبکه عصبی مصنوعی، فصلنامه پژوهش ها و سیاست های اقتصادی، سال پانزدهم، شماره ۴۴، صص: ۱۴۱-۱۵۹.
- ۳) نیکوکار، وهاب (۱۳۸۶)، طراحی محیط یادگیری برای پیش بینی بازار سهام با استفاده از شبکه عصبی، پایان نامه کارشناسی ارشد، دانشگاه تربیت مدرس.
- 4) Ang , B.W. (1988).Electricity-output Relation and Sectorial Electricity Use, The case of East and South East Asian Developing Countries, Energy Policy, 16(2), 115-121
- 5) Benaouda , F. Murtagh, J.-L. Starck and O. Renaud (2008). Short-Run Load Forecasting by Wavelet-Based Nonlinear Multiscale

- Indonesian Aggregate Whole Economy and Residential Sectors, *Energy Policy*, 39,40-46.
- 19) Shanker, M.; Hu, M. Y. & Hung, M.S. (1996). Effect of Data Standardization on Neural Network Training, *omega*, 24(1), 385-397.
- 20) Siekmann, S.; Kruse, R. and Gebhardt, J. (2001). Information fusion in the context of stock index prediction, *International Journal of Intelligent Systems*, Vol. 16, 1285-1289.
- 21) Zhang G Peter. (2003). Time series forecasting using a hybrid and neural network model. *Neurocomputing*, 61, 159-175.
- 6) Cornelius, Peter and Story, Jonathan (2007). Chin and Global Energy Markets, *Orbis*, Vol. 51, No. 1, 5-20.
- 7) Darbellay Georges A, Marek Slama (2000). Forecasting the short term demand for electricity do neural network stand a better chance. *International Journal of Forecasting*, 16, 171-83.
- 8) Desai, V.S and Bharati, R (1998). A comparison of linear regression and neural network methods for predicting excess returns on large stocks, *Annals of Operations Research*, Vol. 78, 127-163.
- 9) Dimitropoulos, John, Lester C. Hunt and Guy Judge (2005). Estimating Underlying Energy Demand Trends Using UK Annual Data, *Applied Economics Letters*, 12, 239-244.
- 10) Ettestol, I. (2002). Estimating Residential Demand for Electricity with Smooth Transition Regression, *Ntnu, Trondheim, Norway*, 275-296.
- 11) Frank, O., Louse, K. and K. James. (2008). Forecasting the electricity energy consumption of Spanish by Fourier Series and Neural Network Models, *forecasting*, Volume 23, 137-151.
- 12) Hamzaçebi, CoLkun. (2007). Forecasting of Turkey's Net Electricity Energy Consumption on Sectoral Bases, *Energy Policy* 35, Issue 3, 2009-2016.
- 13) Harvey, A.C. and S, J. Koopman. (1992). Diagnostic Checking of Unobserved-components Time Series Models. *Journal of Business and Economics Statistics*, 10, 377-389.
- 14) Hippert Henrique Steinherz, Pedreira Carlos Eduardo, Souza Reinaldo Castro. (2000). *Neural Networks for Short-Term Load Forecasting: A Review and Evaluation*. *IEEE Transactions on Power Systems*, vol 16, 245-266.
- 15) James, K., Louse, K. and F. Oliviera. (2006). Short Term Load Forecasting Using Double Seasonal ARIMA and neural network Model, *Mathematics and Computation*, 183(1), 1732-1751.
- 16) Liu, S.F., Dang, Y.G., & Fang, Z.G. Fang. (2004). *Grey system Theory and its application*. Third ed. Science press, Beijing. 375-396
- 17) Saab Samer, Badr Elie, Nasr George. (2001). Univariate modeling and forecasting of energy consumption: the case of electricity in Lebanon. *Energy* 26, 1-14.
- 18) Sa'ad, Suleiman. (2011). Underlying Energy Demand Trends in South Korean and

یادداشت‌ها

1. Samer
2. Harvey
3. Ang
4. Darbellay
5. Hippert
6. Ettestol
7. Zhang
8. Dimitropoulos
9. James
10. Hamzaçebi
11. Frank
12. Benaouda
13. Suleiman
14. Autoregressive models
15. Moving Average
16. Autoregressive Moving Average
17. Autoregressive Integrated Moving Average
18. Autocorrelation Function (ACF)
19. Partial Autocorrelation Function (PACF)
20. Shanker
21. Cornelius
22. Liu
23. Identification
24. Estimate
25. Diagnostic checking
26. White noise
27. Forecasting
28. Desai and Bharati
29. Siekmann and Gebhardt

- Decomposition Model. *Journal of Forecasting*, 30, 1984-1998.
- 6) Cornelius, Peter and Story, Jonathan (2007). Chin and Global Energy Markets, *Orbis*, Vol. 51, No. 1, 5-20.
- 7) Darbellay Georges A, Marek Slama (2000). Forecasting the short term demand for electricity do neural network stand a better chance. *International Journal of Forecasting*, 16, 171-83.
- 8) Desai, V.S and Bharati, R (1998). A comparison of linear regression and neural network methods for predicting excess returns on large stocks, *Annals of Operations Research*, Vol. 78, 127-163.
- 9) Dimitropoulos, John, Lester C. Hunt and Guy Judge (2005). Estimating Underlying Energy Demand Trends Using UK Annual Data, *Applied Economics Letters*, 12, 239-244.
- 10) Ettestol, I. (2002). Estimating Residential Demand for Electricity with Smooth Transition Regression, *Ntnu, Trondheim, Norway*, 275-296.
- 11) Frank, O., Louse, K. and K. James. (2008). Forecasting the electricity energy consumption of Spanish by Fourier Series and Neural Network Models, *forecasting*, Volume 23, 137-151.
- 12) Hamzaçebi, CoLkun. (2007). Forecasting of Turkey's Net Electricity Energy Consumption on Sectoral Bases, *Energy Policy* 35, Issue 3, 2009-2016.
- 13) Harvey, A.C. and S, J. Koopman. (1992). Diagnostic Checking of Unobserved-components Time Series Models. *Journal of Business and Economics Statistics*, 10, 377-389.
- 14) Hippert Henrique Steinherz, Pedreira Carlos Eduardo, Souza Reinaldo Castro. (2000). *Neural Networks for Short-Term Load Forecasting: A Review and Evaluation*. *IEEE Transactions on Power Systems*, vol 16, 245-266.
- 15) James, K., Louse, K. and F. Oliviera. (2006). Short Term Load Forecasting Using Double Seasonal ARIMA and neural network Model, *Mathematics and Computation*, 183(1), 1732-1751.
- 16) Liu, S.F., Dang, Y.G., & Fang, Z.G. Fang. (2004). *Grey system Theory and its application*. Third ed. Science press, Beijing. 375-396
- 17) Saab Samer, Badr Elie, Nasr George. (2001). Univariate modeling and forecasting of energy consumption: the case of electricity in Lebanon. *Energy* 26, 1-14.
- 18) Sa'ad, Suleiman. (2011). Underlying Energy Demand Trends in South Korean and

Modeling and forecasting electricity production and Consumption in Iran

Mohammadreza Omid

PhD Student in Operation Research and system Engineering Islamic Azad University, South Tehran Branch, Tehran, Iran

Nabi Omid

Mentor Department of Management, Payam Noor University, Iran

Heshmatolah Asgari

Associate Professor Faculty of Literature and Humanities, Ilam University, Ilam, Iran,
(Corresponding Author)
he.asgari@gmail.com

Meysam Jafari Eskandari

Assistant Professor Department of Industrial Engineering, Payam Noor University, Iran

Abstract

Due to the relatively high growth of energy consumption in the country, the future of research in the field of electrical energy as an important intermediate inputs in industrial production and as a final good And the necessary domestic and commercial sector, the requirements of law enforcement agencies in the field of production and consumption of electricity. Review and forecast electricity consumption and production managers a valuable factor in the power industry for strategic decision making. In this study, using time-series production and power consumption between the years 1967-2013 and deployment of predictive models Box Jenkins, artificial neural network and gray system in addition to the forecasts for the coming years using the standard average percentage of errors the accuracy of prediction methods were also studied villages. The results showed that the highest accuracy in the prediction of Box Jenkins methods and artificial neural network to predict the power consumption is the highest accuracy. The predicted values showed a decreasing ratio of production to consumption in Iran is relatively constant desire and The electricity production in Iran in 2019 to 318 843 million kW per hour and power consumption to be 260,645 million kWh, Which can be modified using modern methods of production and consumption patterns towards increased production to consumption.

Keywords: electricity, forecasting, time series, neural network, gray system