

ارائه مدل پیش بینی مصرف سالیانه برق در ایران با استفاده از شبکه عصبی نارکس و بررسی تاثیر هدفمندسازی یارانه ها بر آن

دکتر محمدرضا حمیدی زاده*

محمدجواد کارگر**

محمد حمیدیان***

تاریخ پذیرش
۹۴/۴/۸

تاریخ دریافت
۹۴/۲/۱۴

چکیده

در این پژوهش، مدلی برای پیش بینی مصرف برق سالیانه ایران بر اساس معیارهای اقتصادی و با استفاده از شبکه های عصبی مصنوعی ارائه و همچنین تاثیر اجرای طرح هدفمندسازی یارانه ها در اولین سال اجرای این طرح بر مصرف برق سالیانه ایران بررسی شده است. بدین صورت که شبکه عصبی نارکس متغیرهای جمعیت و تولید ناخالص داخلی را به عنوان ورودی دریافت کرده و خروجی آن مصرف برق سالیانه در ایران است. برای آزمون و آموزش شبکه طراحی شده، داده های سال های ۱۳۶۲ تا ۱۳۸۹ جمع آوری شده است که داده های چهار سال آخر برای آزمون عملکرد شبکه مورد استفاده قرار گرفته است. برای بررسی میزان دقت پیش بینی شبکه طراحی شده، دو مدل شبکه عصبی پرسپترون و مدل سری زمانی آریمما نیز طراحی گردیده است که مقایسه نتایج نشان می دهد که شبکه عصبی نارکس توانایی بالاتری در پیش بینی مصرف برق ایران دارد. در این مدل با لحاظ شدن عوامل کلیدی تاثیر گذار بر مصرف برق، مصرف برق سالیانه ایران در سال های قبل از اجرای هدفمندی یارانه ها با دقت بالایی پیش بینی می شود و بر این

m-hamidizadeh@sbu.ac.ir

mjkargar@gmail.com

hamidian@outlook.com

* استاد دانشکده مدیریت و حسابداری دانشگاه شهید بهشتی

** کارشناسی ارشد مهندسی فناوری اطلاعات دانشگاه تربیت مدرس (نویسنده مسئول).

*** دانشجوی دکتری مدیریت دانشگاه شهید بهشتی.

اساس میزان مصرف برق ایران در سال ۱۳۹۰ و بررسی این روند در سال‌های ۱۳۹۱ و ۱۳۹۲ بیانگر تاثیر اجرای طرح هدفمندی یارانه‌ها در اولین سال پس از اجرای آن بر مصرف برق سالیانه کشور است. کاهش نسبتاً محسوس مصرف برق در این سال نسبت به پیش‌بینی مدل ارائه شده موید این تاثیر است. نتایج پژوهش حاکی از آن است که با توجه به ساختار شبکه عصبی نارکس و تاثیر تدریجی عامل زمان بر آن از این مدل می‌توان برای پیش‌بینی مصرف برق سالیانه کشور استفاده نمود.

کلید واژه‌ها: پیش‌بینی مصرف برق، شبکه عصبی نارکس، شبکه عصبی پرسپترون، مدل آریم، هدفمندسازی یارانه‌ها.

طبقه‌بندی JEL: C45، C53، E27

۱- مقدمه

امروزه مدیریت انرژی یکی از مسائل مهم مورد توجه بسیاری از جوامع و دولت‌ها است تا جایی که دیگر اهمیت این موضوع بر کسی پوشیده نیست، مدیریت صحیح انرژی ارتباطی مستقیم با رفاه جامعه و توسعه اقتصادی کشورها دارد. در این میان انرژی برق نیز به عنوان یکی از مهمترین انرژی‌ها در زندگی مدرن امروزی در رفاه اجتماعی و همچنین بهره‌وری کار و تولید نقش بسیار موثری ایفا می‌کند با توجه به اهمیت انرژی برق، دولت‌ها در کشورهای توسعه یافته و در حال توسعه، مدیریت مصرف برق را از مهمترین وظایف خود در حوزه مدیریت انرژی قلمداد می‌کنند. برای تحقق این وظیفه پیش‌بینی صحیح مصرف برق یکی از الزامات قطعی برای اخذ تصمیمات صحیح و ارائه راهکارهای مناسب خواهد بود.

تقاضا و مصرف برق در ایران به سرعت در حال افزایش است. افزایش جمعیت، رشد اقتصادی و افزایش شهرنشینی از عوامل مهم در مصرف برق در ایران است. آمارها نشان می‌دهد که مصرف انرژی برق در ایران در طی سال‌های ۱۳۶۰ تا ۱۳۸۴ در حدود نه برابر افزایش یافته است. در این مدت، تولید برق، ظرفیت تولیدی، ظرفیت انتقال و طول خطوط برق به ترتیب ۹/۴، ۵/۳، ۶/۹ و ۷/۸ برابر شده‌اند. همچنین در این دوره، تعداد مشترکین مصرف برق، ۵/۵ برابر و جمعیت ایران ۲/۱ برابر شده است [۱].

با توجه به آمار ارائه شده، تعداد مشترکین مصرف برق در سال ۱۳۸۴، ۱۹،۵ میلیون نفر

بوده است. در همین سال، سرانه مصرف برق ۱۴۳ کیلو وات بر ساعت بوده که بسیار بیشتر از استانداردهای جهانی است و این در حالی است که سرانه تولید انرژی برق ۱۲۲ کیلو وات بر ساعت بوده است [۱]. بی تردید یکی از مهمترین طرح‌هایی که در حوزه مدیریت انرژی تاکنون در ایران به اجرا درآمده است طرح هدفمندسازی یارانه‌ها است که سیاست‌های آن در حوزه مدیریت مصرف برق نیز به طور همزمان با شروع این طرح یعنی از بیست و هفتم آذر ماه ۱۳۸۹ وارد فاز اجرایی خود شد، در این پژوهش قصد داریم با ارائه مدلی علاوه بر پیش‌بینی مصرف برق سالیانه ایران به تاثیر هدفمندسازی یارانه‌ها در اولین سال پس از اجرای آن یعنی سال ۱۳۹۰ بر مصرف برق در ایران بپردازیم.

۲- مبانی نظری و پیشینه تحقیق

[۷] روشی بر مبنای ترکیب الگوریتم ژنتیک و شبکه‌های عصبی برای پیش‌بینی مصرف برق ارائه کرده است. در این تحقیق، روش پیشنهادی برای پیش‌بینی مصرف برق سالانه ایران در بخش کشاورزی پیاده‌سازی شده است که از داده‌های سال‌های ۱۹۸۱ تا ۲۰۰۵ برای داده‌های آموزش و سال‌های ۲۰۰۵ تا ۲۰۰۸ برای آزمودن مدل پیشنهادی استفاده شده است. نتایج ارائه شده در این تحقیق، حاکی از آن است که در مقایسه با روش‌های رگرسیونی، شبکه عصبی عملکرد بهتری نشان داده است.

[۳] مدلی برای پیش‌بینی مصرف ماهیانه برق در ایران براساس شبکه‌های عصبی ارائه داده است. در این تحقیق از داده‌های ماهانه مصرف برق از سال ۱۹۹۴ تا ۲۰۰۴ استفاده شده است و ۱۲ داده آخر برای داده‌های آزمون استفاده شده است. شبکه عصبی پرسپترون با معماری ۱۲-۱۶-۶-۱ به عنوان بهترین شبکه انتخاب شده است و داده‌های مربوط به ۱۲ ماه قبل به عنوان داده‌های ورودی به شبکه تعیین شده است. در نهایت از روش تحلیل واریانس برای مقایسه روش پیشنهادی با داده‌های واقعی و داده‌های حاصل از رگرسیون استفاده شده است و نتایج ارائه شده در این تحقیق نشان می‌دهد که پیش‌بینی با شبکه عصبی دقیق‌تر می‌باشد.

[۴] روشی بر مبنای شبکه‌های عصبی برای پیش‌بینی مصرف سالیانه برق ایران در بخش

صنعت ارائه کرده است که برای پیش بینی از معیارهای قیمت برق، تعداد مصرف کننده، میانگین وزنی قیمت سوخت‌های فسیلی، ارزش افزوده و شدت قیمت برق استفاده شده است. در این تحقیق از داده‌های مربوط به سال‌های ۱۹۷۹ تا ۲۰۰۳ استفاده شده است که داده‌های ۴ سال آخر به عنوان داده‌های آزمون در نظر گرفته شده است. مقایسه نتایج حاصل از مدل پیشنهادی، با داده‌های واقعی و روش‌های رگرسیونی نشان دهنده عملکرد بهتر شبکه‌های عصبی می‌باشد.

در [۱۲]، پیش بینی مصرف ماهیانه برق در ایران با استفاده از شبکه‌های عصبی انجام گرفته است، که برای مقایسه آن از روش‌های شبکه‌های عصبی با داده‌های شبیه‌سازی شده و روش آریمما استفاده شده است. برای پیاده‌سازی روش پیشنهادی از داده‌های مصرف ماهیانه برق در ایران از سال ۱۹۹۴ تا ۲۰۰۵ استفاده شده است. در این مقاله، شبکه عصبی پرسپترون با معماری ۳-۲-۱ انتخاب شده است که داده‌های ورودی به شبکه شامل داده‌های دو ماه قبل و مصرف برق در ماه مشابه سال قبل می‌باشد. مقایسه روش پیشنهادی با داده‌های واقعی و دیگر روش‌ها نشان دهنده برتری شبکه‌های عصبی می‌باشد.

[۶] از یک شبکه عصبی با موتور استنتاج فازی برای پیش بینی مصرف ماهیانه برق در ایران استفاده کرده است. روش پیشنهادی قادر است تا پیچیدگی‌ها و عدم قطعیت موجود در داده‌ها را شناسایی کند زیرا روش پیشنهادی از ترکیب منطق فازی و شبکه‌های عصبی بهره برده است. داده‌های مربوط به مصرف ماهیانه برق در ایران از سال ۱۹۹۵ تا ۲۰۰۵ برای پیاده‌سازی مدل پیشنهادی استفاده شده است. برای اعتبار سنجی مدل، بهترین مدل آریمما، الگوریتم ژنتیک و شبکه عصبی پرسپترون بدست آمده است و مقایسه روش پیشنهادی با این روش‌ها بیانگر عملکرد بهتر شبکه عصبی با موتور استنتاج فازی در پیش بینی ماهیانه مصرف برق در ایران است.

[۱۶] روشی ترکیبی بر مبنای شبکه‌های عصبی مصنوعی، تحلیل مؤلفه‌های اصلی^۱، تحلیل پوششی داده‌ها^۲ و تحلیل واریانس برای پیش بینی مصرف ماهیانه برق ارائه کرده

-
1. Principal Component Analysis(PCA)
 2. Data Envelopment Analysis(DEA)

است. در روش پیشنهادی این مقاله، برای روش‌های مختلف پیش‌پردازش و پس‌پردازش داده‌ها، شبکه‌های عصبی پرسپترون مختلف طراحی شده است و سپس عملکرد هر شبکه توسط تحلیل پوششی داده‌ها بررسی شده است. همچنین در این مقاله، از روش تحلیل مؤلفه‌های اصلی برای انتخاب بهترین داده‌های ورودی بهره برده است. برای پیاده‌سازی روش پیشنهادی از داده‌های مصرف ماهیانه برق از سال ۱۹۹۲ تا ۲۰۰۴ استفاده شده است و مقایسه روش پیشنهادی با روش‌های الگوریتم ژنتیک، رگرسیون فازی، شبکه‌های عصبی و شبکه عصبی با موتور استنتاج فازی نشان داده است که روش پیشنهادی این تحقیق، نتایج بهتری ارائه می‌دهد.

شبکه عصبی نازکس

شبکه‌های عصبی بازگشتی ساده دسته‌ای از شبکه‌های عصبی بازگشتی هستند که همانند شبکه‌های پیش‌رو می‌باشند، اما دارای تعداد کمی حلقه‌های پس‌رو محلی/سراسری در معماری خود هستند. شبکه‌های پیش‌رو مانند پرسپترون را می‌توان با اعمال ورودی‌های تأخیر یافته برای حل مسائل پیش‌بینی سری‌های زمانی به کار برد. این دسته از شبکه‌ها، شبکه‌های عصبی با تأخیر زمانی نام دارند که به راحتی می‌توان آن‌ها را به شبکه‌های عصبی بازگشتی ساده با برگشت دادن خروجی‌های نرون‌های لایه پنهان و خروجی به لایه ورودی تبدیل کرد که به ترتیب به شبکه‌های عصبی المان و جردن معروف هستند، تبدیل کرد. شایان ذکر است که هنگامی که شبکه‌های عصبی پیش‌رو با تأخیر زمانی را برای پیش‌بینی‌های بلند مدت به کار می‌روند، این شبکه‌ها در نهایت مانند شبکه‌های عصبی بازگشتی عمل می‌کنند که یک حلقه سراسری برای وارد نمودن مقادیر خروجی شبکه در هر مرحله به ورودی‌های بعدی شبکه نیاز دارند [۱۷].

این گونه شبکه‌ها معمولاً به وسیله الگوریتم‌های پس انتشار خطا براساس گرادینان آموزش می‌بینند. اما آموزش این شبکه‌ها، هنگامی که وابستگی‌های بلند مدت زمانی بین ورودی‌ها و خروجی‌های وجود دارد، بسیار مشکل است [۱۸]. برخی از محققین اعلام کرده‌اند که آموزش شبکه‌ها توسط الگوریتم‌های کاهش گرادینان، برای این چنین

وابستگی‌های زمانی، در دسته‌ای از شبکه‌های عصبی بازگشتی به نام شبکه‌های خود برگشتی غیر خطی با ورودی خارجی (نارکس)، نسبت به شبکه‌های پیش‌رو بازگشتی بسیار مؤثرتر است. زیرا بردار ورودی این شبکه‌ها دارای دو خط تأخیر زمانی است: الف- تأخیر زمانی برای تمام ورودی‌ها ب- تأخیر زمانی برای خروجی‌های شبکه [۱۹].

شبکه عصبی نارکس، جزء دسته سیستم‌های غیر خطی ناپیوسته زمانی است که به صورت ریاضی به صورت رابطه (۱) نمایش داده می‌شود [۲۰]:

$$y(n+1) = f[y(n), \dots, y(n-d_y+1); u(n), u(n-1), \dots, u(n-d_u+1)] \quad (1)$$

که $y(n) \in \mathbb{R}$ و $u(n) \in \mathbb{R}$ به ترتیب بیانگر ورودی و خروجی‌های شبکه در زمان ناپیوسته n هستند. $d_u \geq 1$ و $d_y \geq 1$ ، به ترتیب نشانگر تأخیر زمانی در ورودی‌ها و خروجی‌هاست. شکل فشرده رابطه بالا به صورت زیر خواهد بود:

$$y(n+1) = f[y(n); u(n)] \quad (2)$$


که بردارهای $y(n)$ و $u(n)$ به ترتیب نمایانگر بردارهای خروجی و ورودی هستند.

در حالت کلی، دو فرم اصلی برای شبکه نارکس وجود دارد:

الف- سری- موازی: از این حالت، در مواقعی که قصد داریم تا پیش بینی یک مرحله‌ای انجام دهیم، استفاده می‌شود. در این شبکه پیش بینی مرحله زمانی بعدی توسط مقادیر واقعی مراحل زمانی پیشین انجام می‌گیرد. به عبارت دیگر، مقادیر خروجی واقعی مراحل زمانی پیشین به عنوان بردار ورودی به شبکه داده می‌شود که فرم ریاضی آن به صورت رابطه (۳) است:

$$\hat{y}(n+1) = \hat{f}[y_{sp}(n); u(n)] \\ = \hat{f}(y(n), \dots, y(n-d_y+1); u(n), u(n-1), \dots, u(n-d_u+1)) \quad (3)$$

معماری این شبکه نیز در شکل ۱ آورده شده است.



شکل ۱- معماری شبکه نارکس (سری- موازی)

ب- موازی: هنگامی که قصد داریم تا پیش بینی چند مرحله‌ای انجام دهیم، از این حالت شبکه استفاده می‌کنیم که معماری آن در شکل ۲ آورده شده است. در این حالت، پیش بینی در هر مرحله براساس خروجی‌های تخمین زده شده توسط شبکه در مراحل قبل صورت می‌گیرد. یعنی برای پیش بینی در هر مرحله، خروجی‌های شبکه در مراحل قبل به عنوان داده ورودی به شبکه داده می‌شود که فرم ریاضی آن به صورت رابطه (۴) است:


$$\begin{aligned} \hat{y}(n+1) &= \hat{f}[y_p(n); u(n)] \\ &= \hat{f}[\hat{y}(n), \dots, \hat{y}(n-d_y+1); u(n), u(n-1), \dots, u(n-d_u+1)] \end{aligned} \quad (4)$$

شبکه عصبی نارکس دارای دو حالت سری- موازی و موازی است که به ترتیب برای پیش بینی یک مرحله‌ای و چند مرحله‌ای کاربرد دارد. بدین صورت که در حالت سری- موازی مقادیر خروجی واقعی در هر مرحله بعنوان ورودی به شبکه برای پیش بینی مرحله زمانی بعدی داده می‌شود. اما در حالت موازی، شبکه دارای یک حلقه بسته است که مقادیر خروجی تخمین زده شده توسط شبکه در هر مرحله بعنوان ورودی به شبکه برای پیش بینی مرحله زمانی بعدی داده می‌شود. بنابراین در این تحقیق، ابتدا شبکه عصبی

نارکس در حالت سری- موازی

شکل ۲- معماری شبکه نارکس (موازی)

شکل ۳- معماری شبکه نارکس (موازی)




شکل ۴- معماری شبکه نارس موازی

توسط داده‌های موجود آموزش داده می‌شود. سپس برای آزمون عملکرد شبکه، آن را به حالت موازی تبدیل کرده و سپس پیش بینی توسط آن انجام می‌گیرد و خطای شبکه محاسبه می‌شود.

شبکه عصبی پرسپترون

شبکه‌های عصبی چند لایه پیشخور و بویژه شبکه‌های پرسپترون چند لایه، پرکاربردترین شبکه عصبی مصنوعی می‌باشد. این شبکه‌ها در صورت وجود تعداد لایه و تعداد نرون کافی در لایه‌های خود قادرند هر نگاشت غیر خطی را با هر تقریب دلخواه، تخمین بزنند. شبکه‌های زیادی برای استفاده در پیش بینی، پیشنهاد شده است، ولی این شبکه یکی از عمومی‌ترین و موفق‌ترین شبکه‌ها در پیش بینی بوده است [۴]. شکل عمومی شبکه‌های پرسپترون دارای سه لایه است: لایه ورودی، لایه پنهان و لایه خروجی. لایه‌های ورودی و خروجی به ترتیب بیانگر متغیرهای ورودی و خروجی مدل است و بین این دو لایه یک یا چند لایه پنهان قرار می‌گیرد که توانایی شبکه در یادگیری روابط غیرخطی بین ورودی و خروجی‌ها به آن وابسته است. جریان داده‌ها در این شبکه به صورت پیش‌رو و به سمت لایه خروجی است و ساختار کلی این شبکه در شکل ۳ آورده شده است. معماری این شبکه بدین صورت است که: ورودی هر نرون فقط از نرون‌های لایه قبل است. هر نرون به تمامی نرون‌های لایه بعد متصل بوده و ارتباطات کامل است. هر نرون می‌تواند دارای بایاس

مستقل باشد. شکل ریاضی شبکه پرسپترون به صورت زیر است:



شکل ۳- معماری شبکه عصبی پرسپترون

$$y_{t,j} = \alpha_0 + \sum_{i=1}^n \alpha_j f(\sum_{i=1}^m \beta_{ij} y_{t-i} + \beta_{0j}) + \varepsilon_t \quad (5)$$

که m تعداد نرون‌های لایه ورودی، n تعداد نرون‌های لایه پنهان، f تابع تبدیل نرون‌های لایه پنهان هستند. $\{\alpha_j, j = 0, 1, \dots, n\}$ بردار وزن بین نرون‌های لایه پنهان و لایه خروجی است و

$$\{\beta_{ij}, i = 1, 2, \dots, m; j = 0, 1, \dots, n\}$$

بردار وزن بین نرون‌های لایه ورودی و لایه پنهان است. همچنین α_0 و β_{0j} مقادیر بایاس هستند که مقدار آن‌ها ثابت و برابر با یک است. پرکاربردترین و محبوب‌ترین قاعده یادگیری شبکه‌های پرسپترون، الگوریتم «پس انتشار خطا» می‌باشد که جزء روش‌های یادگیری با نظارت محسوب می‌شود. در این روش، مقداردهی اولیه تمامی وزن‌های شبکه به صورت تصادفی انجام می‌گیرد. سپس، مجموعه داده‌های آموزش به شبکه داده می‌شود و خروجی شبکه با داده‌های واقعی مقایسه می‌شود. حال اگر بین خروجی‌های شبکه و داده‌های واقعی تفاوت وجود داشته باشد، خطای شبکه محاسبه می‌شود و وزن‌های شبکه

با استفاده از خطای حاصل، تصحیح می‌شوند تا مجموع مربعات خطا^۱ مابین خروجی‌های شبکه و داده‌های واقعی به حداقل برسد [۱۲].

معماری شبکه‌های عصبی یکی از موضوعات اساسی در تحقیقات مختلف است و به عوامل مختلفی بستگی دارد که عبارتند از:

الف) تعداد لایه‌های پنهان و نرون‌های آنها

ب) تابع فعالیت لایه‌های پنهان و خروجی

ج) الگوریتم یادگیری شبکه

اصولاً برای طراحی معماری شبکه، عوامل بیان شده به صورت سعی و خطا تعیین می‌شوند و شبکه با کمترین مجموع مربعات خطا به عنوان بهترین شبکه انتخاب می‌شود.

مدل آریما

باکس^۲ و جنکینز^۳ [۲۲] روشی را توسعه دادند، که اساس آن بر مبنای بررسی حوزه وسیعی از مدل‌های پیش‌بینی برای یک سری زمانی قرار گرفته است. این روش مدل خود را از میان مجموعه‌ای از مدل‌ها که به آن ARIMA می‌گویند، با روشی سیستماتیک انتخاب می‌کند. در مدل ARIMA فرض می‌شود که مقادیر آتی یک متغیر تابع خطی از چندین مشاهده گذشته و خطاهای تصادفی می‌باشد. مدل ریاضی آریما به صورت رابطه (۶) است:

$$\phi_p(L)y_t = \theta_q(L)\varepsilon_t \quad (6)$$

که:

$$\phi_p(L) = 1 - \phi_1L - \dots - \phi_pL^p$$

$$\theta_q(L) = 1 - \theta_1L - \dots - \theta_qL^q$$

خطای پیش ε_t تعریف می‌شود و $L^k y_t = y_{t-k}$ عملگری است که به صورت L که ARIMA(p,q) بینی است که دارای میانگین صفر و واریانس ثابت است. رابطه به مدل به ترتیب بیانگر پارامترهای خودبرگشتی و میانگین متحرک هستند. q و p مشهور است که

-
1. Sum Squared Error (SSE)
 2. Box
 3. Jenkins

این مدل‌ها و ابزارهای استفاده شده در آن تنها برای سری‌های زمانی ایستا (مانا) کاربرد دارد. بنابراین، پیش از تحلیل یک سری زمانی غیر ایستا به وسیله این مدل می‌بایست با استفاده از روش‌های تفاضل‌گیری به یک سری ایستا تبدیل شود.

مدل‌های آریمای سه مرحله ساخته می‌شوند: در مرحله اول تعدادی مدل از بین گروه عمومی مدل‌های ARIMA براساس معیارهای مربوط، بدون قواعد مشخص و براساس قضاوت و تجربه تحلیلگر شناسایی می‌شوند، که عموماً برای شناسایی نوع و مرتبه مدل از نمودارهای تابع خود همبستگی^۱ و تابع خود همبستگی جزئی سری^۲ استفاده می‌شود و برای سنجش ایستایی و حذف روند از آزمون تعمیم یافته دیکی-فولر استفاده می‌شود. مرحله دوم به تخمین و آزمون پارامترهای مدل‌های شناسایی شده می‌پردازد که در این تحقیق از روش حداقل مربعات خطی استفاده شده است. برای انتخاب مناسب‌ترین مدل از معیارهای اطلاعات آکائیک و معیار اطلاعات شوارتز بهره می‌بریم. مرحله سوم، مرحله بازبینی تشخیص مدل (آزمون پسماندها) می‌باشد. در این مرحله کارایی (بررسی تصادفی بودن خطاهای مدل مورد بررسی) سنجیده می‌شود که در این تحقیق از آزمون الجانگ-باکس استفاده می‌شود. در صورتی که مدل برآزش شده، کارا نباشد، مدل دیگری انتخاب می‌شود. نهایتاً بعد از تشخیص بهترین مدل، با استفاده از آن به پیش‌بینی مقادیر آینده سری زمانی می‌پردازیم.

۳- پیش پردازش داده‌ها

در برخی از مواقع در صورتی که بر روی داده‌های ورودی به شبکه و مقادیر هدف متناظر با آن، تبدیل (پیش پردازش) مناسبی انجام گیرد، شبکه از خود عملکرد بهتری نشان خواهد داد. در این صورت بعد از انجام تبدیل مورد نظر بر روی داده‌ها و آموزش شبکه با داده‌های تبدیل شده، هر زمان که قرار است داده جدیدی نظیر داده‌های آزمایش به شبکه وارد شود، باید تبدیل انجام شده مجدداً بر روی این داده‌ها نیز انجام شود یا اصطلاحاً

1. Autocorrelation function
2. Partial autocorrelation function

داده‌ها «مقیاس بندی مجدد» شوند. تبدیل‌های متفاوتی برای پیش پردازش داده‌ها در تحقیقات مختلف پیشنهاد شده است، اما از آنجا که داده‌های ورودی در این تحقیق دارای مقیاس‌های مختلفی هستند، نیاز است تا از روشی استفاده شود که بتواند داده‌های ورودی را هم مقیاس نماید. بنابراین از تبدیل‌های زیر استفاده می‌شود:

نرمال سازی خطی داده‌ها در فاصله $[L, H]$

در این روش، تبدیلی بر روی داده‌های ورودی به شبکه انجام می‌شود که داده‌ها در فاصله $[L, H]$ قرار گیرند. این کار با استفاده از رابطه (۷) انجام می‌شود:

$$X_n = (X_i - X_{min}) / (X_{max} - X_{min}) * (H - L) + L, i = 1, 2, \dots, N \quad (7)$$

در این رابطه X_i مقدار واقعی ورودی شبکه و X_n مقدار نرمال شده متناظر با آن است. X_{max} و X_{min} به ترتیب مقادیر کمینه و بیشینه X_i ها هستند.

نرمال سازی استاندارد داده‌ها به میانگین صفر و انحراف معیار یک

این روش نرمال سازی که کاربردهای فراوانی در آمار دارد، با استفاده از اختلاف داده‌ها با میانگین و تقسیم آن بر انحراف معیار به دست می‌آید:

$$X_n = \frac{X_i - \text{Mean}(X)}{\sigma_x} \quad (8)$$

در این روش مقادیر کمتر از میانگین مقدار منفی، میانگین صفر و بیشتر از میانگین مثبت می‌شوند. این داده‌ها را در فاصله (۴ و -۴) با میانگین صفر نگاشت خواهد کرد.

تبدیل لگاریتمی داده‌ها


رابطه تبدیل لگاریتمی به صورت رابطه (۹) است:

$$X_n = \log(X_t) - \log(X_{t-1}) \quad (9)$$

۴- پیش بینی مصرف برق سالیانه ایران

هدف اصلی این تحقیق، پیش بینی مصرف سالانه برق ایران با استفاده از عوامل جمعیت، و

تولید ناخالص داخلی است. بنابراین باید رابطه بین این عوامل را با مصرف برق را تخمین زد. شکل ۵، حالت کلی مسئله مورد بررسی در این تحقیق را نشان می‌دهد. از آنجا که رابطه بین عوامل ذکر شده و مصرف برق نامشخص و غیرخطی است و همچنین برای یافتن وابستگی‌های زمانی موجود در مصرف برق و عوامل تأثیر گذار بر آن، برای پیش‌بینی مصرف برق در زمان t (\hat{y}_t)، از داده‌های سال قبل ($X_{1,t-1}, X_{2,t-1}, X_{3,t-1}, X_{4,t-1}, y_{t-1}$) و دو سال قبل ($X_{1,t-2}, X_{2,t-2}, X_{3,t-2}, X_{4,t-2}, y_{t-2}$) استفاده می‌شود.



شکل ۵- حالت کلی مسئله پیش‌بینی مصرف برق

مصرف سالانه برق ایران از سال ۱۳۶۲ تا ۱۳۸۹ جمع‌آوری شده است. همچنین عوامل تأثیر گذار که شامل تولید ناخالص داخلی و جمعیت در ایران نیز در این بازه زمانی گردآوری شده است که به عنوان ورودی شبکه عصبی به منظور پیش‌بینی مصرف برق مورد استفاده قرار می‌گیرد. به منظور بررسی عملکرد شبکه، داده‌ها به دو دسته آموزش و آزمون دسته‌بندی می‌شوند که داده‌های آموزش برای آموزش شبکه و داده‌های آزمون برای بررسی درستی عملکرد مورد استفاده قرار می‌گیرند. اصولاً هنگامی که داده‌های کافی برای آموزش شبکه در دسترس باشد، مجموعه داده‌های آزمون به صورت تصادفی از بین آنها انتخاب می‌شوند. همچنین نیاز است تا بین اندازه مجموعه داده‌های آموزش و آزمون تعادل برقرار شود. اما از آنجا که در این تحقیق، داده به اندازه کافی برای آموزش شبکه در اختیار نیست، داده‌های مربوط به سال‌های ۱۳۶۲ تا ۱۳۸۵ (۲۴ سال) به عنوان داده‌های آموزش و سال‌های ۱۳۸۶ تا ۱۳۸۹ (چهار سال) به عنوان داده‌های آزمون در نظر گرفته می‌شود.

در ادامه قصد داریم تا دو شبکه عصبی برای پیش‌بینی مصرف برق سالیانه ایران طراحی

نماییم. همان‌طور که قبلاً بیان شد، سه عامل زیر در طراحی شبکه‌های عصبی باید مشخص گردند:

تعداد نرون و لایه‌های پنهان شبکه

تابع فعالیت لایه‌های پنهان و خروجی و شبکه


الگوریتم آموزشی شبکه

از این رو شبکه‌های عصبی نارکس مختلفی با توجه به تعداد لایه‌ها، و نرون‌ها و توابع تبدیل متفاوت تولید شد و خطای هر یک در پیش‌بینی داده‌های آزمون محاسبه گردید. همچنین تأثیر پیش‌پردازش داده‌ها بر روی عملکرد شبکه نیز محاسبه گردید. نتایج حاصل از بهترین شبکه‌ها در جدول ۱ آمده است. برای مقایسه عملکرد شبکه‌ها از دو معیار ضریب تعیین که با R^2 نمایش داده می‌شود و میانگین قدر مطلق خطا استفاده شده است. افزایش معیار ضریب تعیین و کاهش میانگین قدر مطلق خطا بهبود عملکرد شبکه را نشان می‌دهد. با استفاده از توابع تبدیل مختلف برای لایه‌های پنهان و خروجی، هنگامی که از تابع تانژانت هیپربولیک برای لایه‌های پنهان و تابع خطی برای لایه خروجی استفاده شود، نتایج بهتری حاصل می‌شود. همچنین در تکرارهای مختلف این نتیجه حاصل شد که استفاده از بیش از دو لایه پنهان برای شبکه‌ها باعث ایجاد مشکل «انطباق بیش از حد» می‌شود و شبکه توانایی پیش‌بینی داده‌های آزمون را ندارد. در ضمن، برای آموزش شبکه از الگوریتم «لونبرگ-مارکوآرت» استفاده شده است.

جدول ۱- نتایج حاصل از شبکه عصبی نارکس

پیش‌پردازش								تعداد نرون	
تبدیل لگاریتمی		تبدیل استاندارد		تبدیل خطی		ندارد		لایه پنهان دوم	لایه پنهان اول
MAPE	R^2	MAPE	R^2	MAPE	R^2	MAPE	R^2		
۰,۱۱۹	۹۶,۷۱	۰,۰۴۶۵	۴۸,۳۰	۰,۰۳۴۹	۵۲,۱۴	۰,۰۵۶۴	۵۶,۹۳	۰	۱
۰,۱۱۴	۹۶,۸۶	۰,۰۲۹۵	۷۹,۵۶	۰,۰۲۶۷	۶۸,۹۸	۰,۰۴۸۳	۶۵,۶۷	۱	۱
۰,۰۱۲۱	۹۶,۶۴	۰,۰۳۸۵	۶۶,۴۳	۰,۰۴۳۶	۵۷,۷۶	۰,۰۴۰۶	۷۲,۲۹	۲	۱
۰,۱۳۹	۹۴,۸۹	۰,۰۲۹۰	۸۵,۰۹	۰,۰۵۶۲	۶۴,۹۳	۰,۰۶۵۴	۵۶,۹۳	۰	۲
۰,۰۱۸۱	۹۱,۲۲	۰,۰۳۲۰	۶۵,۸۶	۰,۰۵۷۸	۷۱,۷۶	۰,۰۵۹۶	۸۱,۱۹	۱	۲


همان‌طور که نتایج نشان می‌دهد، شبکه‌عصبی نارکس با یک و دو نرون به ترتیب در لایه پنهان اول و دوم که دارای تابع تبدیل تانژانت هیپربولیک در لایه پنهان خود و تابع خطی در لایه خروجی خود است و با الگوریتم «لونبرگ-مارکوآرت» آموزش می‌بیند، در حالی که پیش‌پردازش لگاریتمی بر روی داده‌های ورودی انجام می‌گیرد، شبکه‌نارکسی است که کمترین خطا را داراست. شکل ۶ پیش‌بینی مصرف سالیانه برق در ایران که به کمک شبکه انتخاب شده انجام گرفته، نشان می‌دهد.



شکل ۶- پیش‌بینی مصرف برق سالیانه ایران با شبکه‌عصبی نارکس

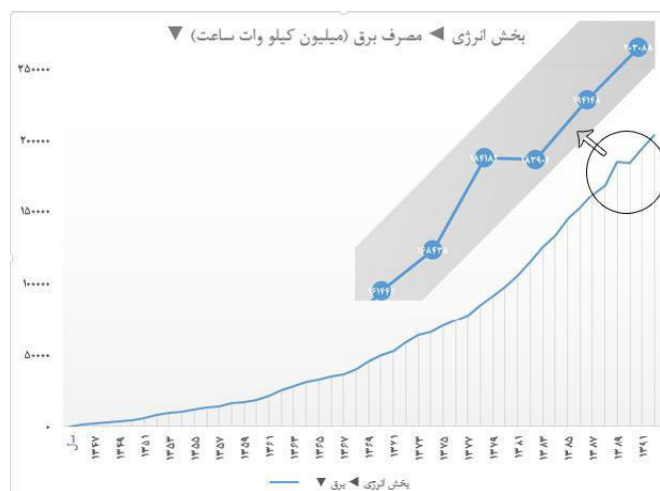
برای طراحی شبکه پرسپترون نیز با استفاده از سعی و خطا مشخص گردید که استفاده از بیش از دو لایه پنهان برای شبکه‌ها باعث ایجاد مشکل «انطباق بیش از حد» می‌شود و استفاده از توابع تبدیل تانژانت هیپربولیک برای لایه‌های پنهان و تابع خطی برای لایه خروجی بهترین نتیجه را داراست. برای شبکه پرسپترون نیز تأثیر پیش‌پردازش داده‌ها بر روی عملکرد شبکه و تعداد نرون‌های هر لایه محاسبه گردید. نتایج نشان می‌دهند که معماری بهترین شبکه پرسپترون به این صورت است: دو لایه مخفی با تابع تبدیل تانژانت هیپربولیک که هر کدام دارای یک نرون می‌باشند و لایه خروجی آن دارای تابع تبدیل خطی است. در حالی که نرمال‌سازی استاندارد بر روی داده‌های ورودی اعمال می‌شود.

همچنین از الگوریتم «لونبرگ-مارکوآرت» برای آموزش شبکه استفاده شده است. مقدار معیار ضریب تعیین و میانگین قدر مطلق خطا برای این شبکه به ترتیب ۹۴,۶۲ و ۰,۰۱۵۳ است. شکل ۷ پیش‌بینی مصرف برق سالیانه ایران را توسط شبکه عصبی پرسپترون نشان می‌دهد.

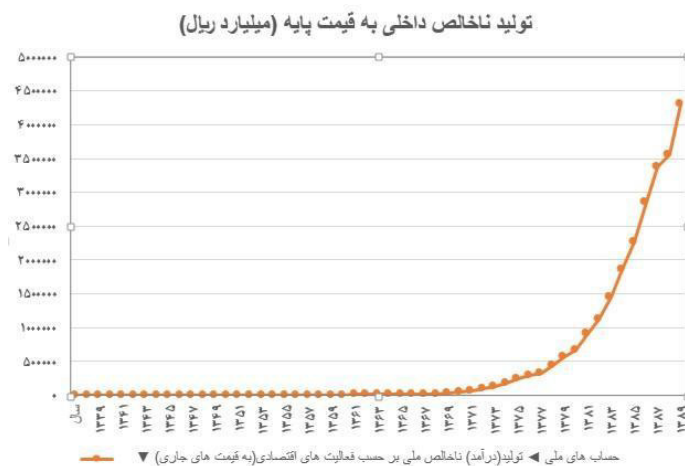


شکل ۷- پیش‌بینی مصرف برق سالیانه ایران با شبکه عصبی پرسپترون

برای ساختن مدل آریمای، از داده‌های مصرف سالیانه برق ایران از سال ۱۳۴۶ تا سال ۱۳۸۹ (در مجموع ۴۴ سال) استفاده شده است. داده‌های مربوط به ۹ سال آخر (۱۳۸۱ تا ۱۳۸۹) به عنوان داده‌های آزمون و بقیه داده‌ها به مدل‌سازی اختصاص می‌یابد. شکل ۸ نمودار داده‌های مربوط به مصرف برق ایران را نشان می‌دهد. همانطور که در شکل ۸ مشخص است، داده‌ها به صورت واضحی مانا (ایستا) نیستند و دارای روند افزایشی هستند. بنابراین نیاز است تا تبدیل بر روی آن انجام گیرد. بدین منظور دو تبدیل اولین تفاضل و لگاریتمی بر روی داده‌ها انجام می‌گیرد که نمودارهای زیر تابع خود همبستگی داده‌ها را برای بیست وقفه نشان می‌دهد. همانطور که شکل ۹ (الف) نشان می‌دهد، تابع خود همبستگی برای داده‌های با تبدیل لگاریتمی، به صورت نمایی کاهش می‌یابد. بنابراین به نظر می‌رسد که داده‌ها مانا هستند. برای اطمینان بیشتر از آزمون دیکی-فولر استفاده می‌شود.



الف




ب


شکل ۸- داده‌های مربوط به مصرف برق در ایران (سال ۱۳۴۶ تا ۱۳۸۹)

مقدار p-value حاصل از این آزمون برابر است با: ۰,۰۳۱۲. از آنجا که این مقدار از ۰,۰۵ کمتر است، نمی‌توان فرض صفر را پذیرفت یعنی داده‌ها دارای ریشه واحد نیستند و ایستا می‌باشند. تابع خود همبستگی برای داده‌های با تبدیل اولین تفاضل حاکی از این امر

است که داده‌ها ایستا نیستند. همچنین مقدار p-value حاصل از آزمون دیکی - فولر برابر است با: ۰,۶۳۹۲ و نشان دهنده آن است که نمی‌توان فرض صفر را رد کرد و داده‌ها ایستا نمی‌باشند.




الف



ب

شکل ۹- تابع خود همبستگی برای داده‌ها با تبدیل الف) لگاریتمی ب) اولین تفاضل

حال نوبت به شناسایی نوع و مرتبه مدل است. برای این کار از نمودارهای ACF و PACF داده‌ها استفاده می‌شود که به ترتیب در شکل ۹ الف) و شکل ۱۰ آورده شده است.



شکل ۱۰- تابع خود همبستگی جزئی برای داده‌ها با تبدیل لگاریتمی


با توجه به نمودارهای تابع خود همبستگی و خود همبستگی جزئی، برای مرتبه خودبرگشتی $p=1,2$ و برای مرتبه میانگین متحرک $q=1,2,3,4,5$ جهت تعیین و تخمین پارامترهای مدل‌های اولیه در نظر گرفته شده است. بدین ترتیب ۱۸ مدل اولیه برای بررسی انتخاب می‌شوند. در مرحله بعد پارامترهای مدل‌های اولیه تخمین زده می‌شوند و آن دسته از مدل‌های که ضرایب آنها در بازه $[-1,1]$ قرار نداشته باشند، حذف می‌شوند. پس از تعیین مدل‌های قابل قبول، از بین آنها بهترین مدل را با توجه به معیارهای AIC، SBC انتخاب می‌گردد که نتایج نشان می‌دهد که مدل $ARIMA(1,5)$ بایستی انتخاب گردد. در انتها برای بررسی تصادفی بودن پسماندهای مدل انتخابی از آزمون Ljung-Box استفاده می‌شود که در سه لگ ۱۲، ۱۸، ۲۴ نتایج آن در جدول ۲ نشان داده شده است.

جدول ۲- آزمون Ljung-Box برای بررسی تصادفی بودن پسماندها

لگ	آماره Q	درجه آزادی	مقدار بحرانی	p-value
۱۲	۴,۱۷۲	۶	۱۲,۵۹۱۶	۰,۶۵۳۴
۱۸	۴,۸۵۰۷	۱۲	۲۱,۰۲۶۱	۰,۹۶۲۸
۲۴	۵,۴۶۷۵	۱۸	۲۸,۸۶۹۳	۰,۹۹۷۹

همانطور که جدول ۲ نشان می‌دهد، در هر سه مورد مقدار آماره آزمون کمتر از مقدار بحرانی است ($p\text{-value} > 0.05$)، پس فرض صفر رد نشده و نشان دهنده تصادفی بودن

پسماندها می‌باشد. به این ترتیب مدل نهایی $ARIMA(1,5)$ می‌باشد که در شکل ۱۱ پیش بینی مصرف سالیانه برق توسط این مدل نشان داده شده است.



شکل ۱۱- پیش بینی مصرف سالیانه برق توسط مدل آریما

۵- مقایسه و ارزیابی مدل‌های پیش‌بینی

تا اینجا سه مدل برای پیش‌بینی مصرف برق سالیانه در ایران با استفاده از شبکه عصبی نارکس، شبکه عصبی پرسپترون و روش آریما ارائه شده است. در این مدل‌ها پارامترها به نحوی تعیین شده‌اند تا بهترین حالت برای پیش‌بینی مصرف برق حاصل شود که پیش‌بینی حاصل از هر یک از مدل‌ها در جدول ۳ آمده است.

جدول ۳- پیش‌بینی مصرف برق توسط مدل‌های به دست آمده

MAPE	سال				مدل
	۱۳۸۹	۱۳۸۸	۱۳۸۷	۱۳۸۶	
	۱۸۴۱۸۲	۱۶۸۴۳۸	۱۶۱۴۴۶	۱۵۲۳۳۰	داده‌های واقعی
۰,۰۰۷۷۱	۱۸۲۱۹۳	۱۷۰۴۹۷	۱۶۲۵۶۷	۱۵۲۱۹۶	شبکه عصبی نارکس
۰,۰۲۳۷۲	۱۷۳۵۶۲	۱۶۴۵۴۹	۱۵۹۵۳۳	۱۵۲۶۸۳	شبکه عصبی پرسپترون
۰,۰۱۱۵۸	۱۷۹۹۸۳	۱۶۵۵۹۸	۱۶۲۰۶۴	۱۵۱۸۹۳	روش آریما

برای مقایسه میانگین مقادیر حاصل از پیش‌بینی سه مدل طراحی شده، از آزمون تحلیل واریانس استفاده می‌شود که دو فرض زیر را بررسی می‌کند:

$$H_0: \mu_1 = \mu_2 = \mu_3 = \mu_4$$

$$H_1: \mu_i \neq \mu_j, \quad i, j = 1, 2, 3, 4 \text{ and } i \neq j \quad (10)$$

که μ_1, μ_2, μ_3 و μ_4 به ترتیب بیانگر میانگین مقادیر تخمین زده شده توسط داده‌های واقعی، شبکه‌عصبی نارکس، شبکه‌عصبی پرسپترون و روش آریماس است و سطح اطمینان 5% برای آزمون انتخاب می‌شود. اگر فرض صفر رد نشود، مدلی که دارای کمترین مقدار خطای MAPE باشد، به عنوان بهترین مدل انتخاب می‌شود. در غیر این صورت با رد شدن فرض صفر، از آزمون فاصله‌ای متعدد دانکان برای تعیین بهترین مدل انتخاب می‌شود. نتایج حاصل از آزمون تحلیل واریانس در جدول ۴ نشان داده شده است:

جدول ۴- نتایج حاصل از آزمون تحلیل واریانس

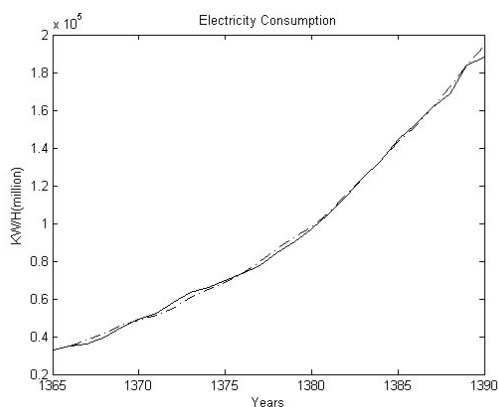
مقدار p-value	مقدار F	توان دو میانگین	درجه آزادی	توان دو مجموع	منبع تغییرات
0.9053	0.18	2.438e+7	3	7.315e+7	بین گروه
		1.326e+8	12	1.591e+9	بلوک
			15	1.664e+9	مجموع

همان‌طور که جدول ۴ نشان می‌دهد، فرض صفر رد نمی‌شود (میانگین داده‌های واقعی و سه مدل پیش‌بینی برابر است)، بنابراین مدل شبکه‌عصبی نارکس که کمترین میزان خطای MAPE را دارد، به عنوان بهترین مدل انتخاب می‌شود.

پیش‌بینی سال‌های ۹۰، ۹۱ و ۹۲ و مقایسه با آمار واقعی

همان‌طور که پیش‌تر نیز اشاره شد، دومین هدف این تحقیق بررسی تاثیر اجرای طرح هدفمند سازی یارانه‌ها در اولین سال اجرای این طرح بر روی مصرف انرژی برق در ایران است. شایان ذکر است که تاثیر مسائلی همچون تحریم‌ها به صورت غیر مستقیم در

ورودی‌های مدل (تولید ناخالص داخلی) لحاظ شده است و با توجه به وقوع رخدادهای مشابه (تحریم) در سال‌های آزمون و آموزش مدل، پیش‌بینی‌های صورت گرفته در این سال‌ها مویده صحت نتایج مدل در چنین شرایطی است. بر این اساس می‌توان اجرای طرح هدفمندسازی یارانه‌ها را عامل تمایز سال ۱۳۹۰ از سال‌های پیش از آن دانست. در این قسمت با استفاده از شبکه عصبی نارکس طراحی شده، مصرف برق را در سال‌های ۱۳۹۰، ۱۳۹۱ و ۱۳۹۲ تخمین می‌زنیم و با مقایسه آن با مقدار واقعی مصرف برق در این سال‌ها به بررسی بیشتر تاثیر هدفمندسازی یارانه‌ها بر خروجی‌های مدل می‌پردازیم. شکل ۱۲ پیش‌بینی مصرف برق در سال ۹۰ را نشان می‌دهد.



شکل ۱۲- پیش‌بینی مصرف برق سال ۱۳۹۰

همچنین مقدار عددی پیش‌بینی مصرف برق سال‌های ۱۳۹۰ تا ۱۳۹۲ در جدول ۵ آمده است.

جدول ۵- پیش‌بینی و مقدار واقعی مصرف برق در سال ۱۳۹۰

سال	مقدار واقعی مصرف برق (KW/H)	مقدار پیش‌بینی مصرف برق (KW/H)
۱۳۹۰	۱۸۳۹۰۴	۱۹۴۸۴۵
۱۳۹۱	۱۹۴۱۴۸	۱۹۶۴۵۷
۱۳۹۲	۲۰۳۰۸۸	۲۰۴۹۱۵

همان‌طور که نتایج در جدول ۵ نشان می‌دهد، پیش‌بینی‌ها نشان می‌دهد که مصرف برق

در سال ۱۳۹۰ باید در حدود ۱۹۴۸۴۵ میلیون کیلو وات بر ساعت باشد. اما با توجه به خطای ۱/۰۷٪ شبکه، با اجرای طرح هدفمند سازی یارانه‌ها، این مقدار در حدود ۵/۹٪ کاهش یافته است و میزان مصرف در این سال به مقدار ۱۸۳۹۰۴ میلیون کیلو وات بر ساعت رسیده است. با توجه به ساختار شبکه عصبی نارکس و تاثیر تدریجی عامل زمان بر آن میزان مصرف در سال ۹۱ با خطای ۱/۰۲٪ و در سال ۹۲ با خطای ۰/۹٪ پیش‌بینی شده که حاکی از صحت پیش‌بینی‌های مدل در سال‌های پس از اجرای طرح هدفمندسازی یارانه‌ها است. بنابراین می‌توان نتیجه گرفت که اجرای طرح هدفمندسازی یارانه‌ها بر مصرف اولین سال پس از اجرای این طرح یعنی سال ۱۳۹۰ تاثیر ۴/۸٪ تا ۷٪ داشته است و این مدل می‌تواند میزان مصرف برق در سال‌های پس از آن را همچون سال‌های پیش از آن با دقت بالایی پیش‌بینی نماید.

۶- نتیجه‌گیری

در این تحقیق سعی شد تا با استفاده از شبکه‌های عصبی مدلی برای پیش‌بینی مصرف برق سالیانه ایران ارائه گردد. بدین منظور از شبکه عصبی نارکس استفاده شد و داده‌های جمعیت و تولید ناخالص داخلی با دو مرحله تأخیر زمانی به عنوان بردار ورودی به شبکه اعمال شد. همچنین نتایج نشان داد که پیش‌پردازش لگاریتمی بر روی داده‌های ورودی باعث بهبود عملکرد می‌شود. برای مقایسه نتایج حاصل از این شبکه، دو روش شبکه عصبی پرسپترون و روش رگرسیون آریمای استفاده شد و نتایج حاصل از این سه شبکه به کمک آزمون تحلیل واریانس مقایسه شد. نتایج نشان داد که شبکه عصبی نارکس پیش‌بینی نزدیک‌تری به داده‌های حقیقی داشته است. نتایج تحقیق نشان داد که اجرای طرح هدفمند سازی یارانه‌ها، بر مصرف برق در اولین سال پس از اجرای این طرح یعنی سال ۱۳۹۰ تاثیر ۴/۸٪ تا ۷٪ داشته است. همچنین نتایج تحقیق حاکی از آن است که این مدل می‌تواند میزان مصرف برق در سال‌های پس از سال ۱۳۹۰ را همچون سال‌های پیش از آن با دقت بالایی پیش‌بینی نماید.

منابع:

1. Amjadi, M.H., H. Nezamabadi-pour, and M.M. Farsangi, *Estimation of electricity demand of Iran using two heuristic algorithms*. *Energ Conv Manage*, 2010. **51**: p. 493-497.
2. Kavaklioglu, K., et al., *Modeling and prediction of Turkey's electricity consumption using Artificial Neural Networks*. *Energy Conversion and Management*, 2009. **50**(11): p. 2719-2727.
3. Azadeh, A., S.F. Ghaderi, and S. Sohrabkhani, *Forecasting electrical consumption by integration of Neural Network, time series and ANOVA*. *Applied Mathematics and Computation*, 2007. **186**(2): p. 1753-1761.
4. Azadeh, A., S.F. Ghaderi, and S. Sohrabkhani, *Annual electricity consumption forecasting by neural network in high energy consuming industrial sectors*. *Energy Conversion and Management*, 2008. **49**(8): p.2272-2278.
5. Padmakumari, K., K.P. Mohandas, and S. Thiruvengadam, *Long term distribution demand forecasting using neuro fuzzy computations*. *International Journal of Electrical Power & Energy Systems*, 1999. **21**(5): p. 315-322.
6. Azadeh, A., et al., *A hybrid simulation-adaptive network based fuzzy inference system for improvement of electricity consumption estimation*. *Expert Systems with Applications*, 2009. **36**: p. 11108-11117.
7. Azadeh, A., et al., *Integration of artificial neural networks and genetic algorithm to predict electrical energy consumption*. *Applied Mathematics and Computation*, 2007. **186**(2): p. 1731-1741.
8. Azadeh, A., M. Saberi, and O. Seraj, *An integrated fuzzy regression algorithm for energy consumption estimation with non-stationary data: A case study of Iran*. *Energy*, 2010. **35**(6): p. 2351-2366.
9. Yalcinoz, T. and U. Eminoglu, *Short term and medium term power distribution load forecasting by neural networks*. *Energ Conv Manage*, 2005. **46**: p. 1393-1405.
10. Hsu, C.C.H. and Y.C.H. Chen, *Regional load forecasting in Taiwan – applications of artificial neural networks*. *Energ Conv Manage*, 2003. **44**: p. 1941-1949.
11. Beccali, M., et al., *Forecasting daily urban electric load profiles using artificial neural networks*. *Energ Conv Manage*, 2004. **45**: p. 2879-2900.
12. Azadeh, A., S.F. Ghaderi, and S. Sohrabkhani, *A simulated-based neural network algorithm for forecasting electrical energy consumption in Iran*. *Energy Policy*, 2008. **36**(7): p. 2637-2644.
13. Ekonomou, L., *Greek long-term energy consumption prediction using artificial neural networks*. *Energy*, 2010. **35**: p. 512-517.
14. Meng, M. and D. Niu, *Annual electricity consumption analysis and forecasting of China based on few observations methods*. *Energ Conv Manage*, 2011. **52**: p. 953-957.

15. Kheirkhah, A., et al., *Improved estimation of electricity demand function by using of artificial neural network, principal component analysis and data envelopment analysis*. Computers & Industrial Engineering, 2013. **64**: p. 425-441.
16. Kolen, J.F. and S.C. Kremer, *A field guide to dynamical recurrent networks*. 2001: Wiley-IEEE Press.
17. Bengio, Y., P. Simard, and P. Frasconi, *Learning long-term dependencies with gradient descent is difficult*. IEEE Transaction on neural network, 1994. **5**: p. 157-166.
18. Lin, T., B.G. Horne, and C.L. Giles, *How embedded memory in recurrent neural network architectures helps learning long-term temporal dependencies*. Neural networks, 1998. **11**: p. 861-868.
19. Leontaritis, I.J. and S.A. Billings, *Input-output parametric models for nonlinear systems - Part I: deterministic nonlinear systems*. International Journal of Control, 1985. **41**: p. 303-328.
20. Hornik, K., *Some new results on neural network approximation*. Neural networks, 1993. **6**: p. 1069-72.
21. Box, G.E. and G.M. Jenkins, *Time series analysis: Forecasting and control*. 1970, San Francisco: 7 Holiday Day.