

ارزیابی کارایی شرکت‌های توزیع نیروی برق ایران با استفاده از مدل ترکیبی شبکه‌های عصبی و تحلیل پوششی داده‌ها

مهدی فلاح جلودار*

۱- دانشیار، دانشگاه آزاد اسلامی واحد آیت الله آملی، گروه ریاضی، آمل، ایران

رسید مقاله: ۱۷ تیر ۱۳۹۵

پذیرش مقاله: ۲ آذر ۱۳۹۵

چکیده

امروزه تجزیه و تحلیل کارایی شرکت‌های توزیع برق به موضوع مهمی برای قانون‌گذاران تبدیل شده است. حرکت به سوی خصوصی‌سازی و تجدید ساختار صنعت برق بر اهمیت این موضوع افزوده است. برای ارزیابی عملکرد شرکت‌های توزیع برق از روش‌های پارامتریک و ناپارامتریک استفاده می‌شود که با توجه به ضعف قدرت تفکیک‌پذیری و حساسیت مرز کارایی به داده‌های پرت در روش تحلیل پوششی داده‌ها، در این پژوهش کارایی ۳۹ شرکت توزیع نیروی برق ایران در سال ۱۳۸۹ با روش ترکیبی شبکه‌های عصبی و تحلیل پوششی داده‌ها به عنوان دو روش ناپارامتریک، مورد ارزیابی قرار می‌گیرد. مقایسه نتایج مدل ترکیبی با روش تحلیل پوششی داده‌ها نشان‌دهنده قدرت بالای شبکه‌های عصبی برای اندازه‌گیری کارایی می‌باشد.

کلمات کلیدی: شبکه‌های عصبی مصنوعی، تحلیل پوششی داده‌ها، شرکت‌های توزیع نیروی برق.

۱ مقدمه

صنعت برق به خاطر نقش زیربنایی و ارتباط زیادی که با کلیه عوامل موثر بر رشد اقتصادی دارد، صنعتی پویا و تاثیر گذار است. با توجه به فراگیری گسترده انرژی برق می‌توان آن را به عنوان یکی از اصلی‌ترین عوامل بستر ساز توسعه اقتصادی کشور محسوب کرد. صنعت برق به دو بخش تولید و توزیع تقسیم می‌شود که هریک به نوبه خود اهمیت اساسی دارند. در این بین بخش توزیع برق به دلیل ارتباط نزدیک با مشترکان از جایگاه و اهمیت خاصی برخوردار است [۱].

ارزیابی عملکرد شرکت‌های توزیع برق همواره به عنوان یکی از مسایل اساسی مورد توجه مدیران این سازمان بوده است. در حقیقت اندازه‌گیری کارایی یک شرکت در مقایسه با سایر شرکت‌ها به مدیران جهت تنظیم عوامل مختلف مانند هزینه‌ها، درآمدها و تدوین نظام انگیزش‌محور، کمک می‌کند [۲]. از آن جا که در

* عهده دار مکاتبات

آدرس الکترونیکی: m.fallahjelodar@iauamol.ac.ir

بیش تر موارد کارایی شرکت‌ها با کیفیت برق عرضه شده به مشترکین ارتباط دارد، عمل کرد صحیح شرکت‌ها اثرات اقتصادی فراوانی برای مشترکین شرکت‌های توزیع و دولت به همراه دارد [۳]. امروزه جهت تخمین درجه کارایی شرکت‌های توزیع برق، از روش‌های مختلفی استفاده می‌کنند. این روش‌ها به‌طور کلی به دو دسته پارامتریک و ناپارامتریک تقسیم می‌شود. در روش پارامتریک تابع تولید یا تابع هزینه تخمین زده می‌شود در حالی که در روش‌های ناپارامتریک نیاز به تخمین تابع هزینه نمی‌باشد [۴]. در مقایسه بین همه مدل‌های به کار گرفته شده، تحلیل پوششی داده‌ها^۱ (DEA) که از روش‌های ناپارامتریک می‌باشد، روش بهتری برای سازماندهی و تحلیل داده می‌باشد؛ زیرا اجازه تغییر کارایی را در طول زمان می‌دهد و به هیچ گونه پیش فرضی در مورد مرز کارایی نیاز ندارد. با وجود این، مرز کارایی منتج شده از DEA نسبت به نویزهای آماری و داده‌های پرت بسیار حساس می‌باشد و ممکن است نویزهای آماری و داده‌های پرت، مرز DEA را جابجا کند. هم چنین DEA قدرت پیش‌بینی برای واحدهای تصمیم‌گیری^۲ را در سال‌های آتی ندارد [۵]. ضعف‌های DEA از یک سو و توانایی شبکه‌های عصبی مصنوعی^۳ از سویی دیگر به عنوان ابزاری مناسب برای تخمین مسایل غیرخطی، مفید بودن در سیستم پیش‌بینی برای مدیران [۴]، ابزار شبیه‌سازی مناسب جهت تخمین مسایل ناپارامتریک [۶] و هم چنین قدرت یادگیری و تعمیم پذیری به گونه‌ای که در برابر داده‌های پرت و نویزهای حاصل از اندازه‌گیری نادقیق داده‌ها مقاوم تر عمل می‌کند، دلیل به کارگیری شبکه‌های عصبی جهت اندازه‌گیری کارایی می‌باشد.

با توجه به ضعف‌های DEA و توانایی‌های شبکه‌های عصبی، در این نوشتار سعی بر آن است که از روش ترکیبی تحلیل پوششی داده‌ها - شبکه‌های عصبی (Neural-DEA) برای اندازه‌گیری کارایی ۳۹ شرکت توزیع نیروی برق ایران در سال ۱۳۸۹ استفاده شود. نتایج حاصل از مدل ترکیبی با روش DEA مورد مقایسه قرار می‌گیرد.

۲ پیشینه تحقیق

۲-۱ پیشینه تحقیق در زمینه ترکیب تحلیل پوششی داده‌ها و شبکه‌های عصبی

آتانوسوپولوس و کورامبرای [۷] اولین بار ایده ترکیب شبکه‌های عصبی و تحلیل پوششی داده‌ها را برای طبقه‌بندی یا پیش‌بینی ارائه دادند. آن‌ها از DEA به عنوان ابزاری برای پیش‌پردازش، جهت به کارگیری داده‌ها برای آموزش استفاده کردند. این روش روی مجموعه‌ای از داده‌های مربوط به بانک مورد استفاده قرار گرفت. نتایج این تحقیق نشان داد، نتایج شبکه عصبی، به نتایج مدل بازده به مقیاس ثابت^۴ تحلیل پوششی داده‌ها بیش تر از نتایج بازده به مقیاس متغیر^۵ نزدیک است. کاستا و مارکلوس [۸] در مقاله ای کارایی متروی لندن را طی سال‌های ۱۹۷۰-۱۹۹۴ به روش ناپارامتریک شبکه‌های عصبی مورد بررسی قرارداد. نتایج به دست آمده از این روش با

^۱ Data Envelopment Analysis

^۲ Decision Making Units (DMUs)

^۳ Artificial Neural Network (ANN)

^۴ Constant Returns to Scale (CRS)

^۵ VariableReturns to Scale (VRS)

نتایج روش‌های تحلیل پوششی داده‌ها و حداقل مربعات اصلاح شده^۱ مورد مقایسه قرار گرفت که نشان‌دهنده تشابه نتایج ANNs با DEA و حداقل مربعات معمولی اصلاح شده بود. پنهان‌کر و راجر [۹] جهت پیش‌بینی توابع غیرخطی با استفاده از شبکه‌های عصبی، از DEA برای جداسازی داده‌های آموزش استفاده کرد. آن‌ها داده‌های آموزش را که مربوط به بیمارستان‌های ایالت پنسیلوانیا آمریکا بود به دو دسته کارا و غیر کارا به روش DEA تقسیم کردند و شبکه را بر مبنای این دو دسته آموزش دادند. نتایج نشان داد قدرت پیش‌بینی شبکه‌ای که با آن دسته از داده‌های آموزشی کارا آموزش دیدند بیش‌تر از شبکه‌ای است که با آن دسته از داده‌های ناکارا آموزش دیده‌اند. سانتین و همکاران [۱۰] از شبکه‌های عصبی برای تخمین تابع تولید غیر خطی و تحلیل کارایی استفاده کردند. نتایج شبکه‌های عصبی مصنوعی را با روش‌های DEA و تحلیل مرز تصادفی^۲ مورد مقایسه قرار داد که نتایج نشان داد که شبکه‌های عصبی مصنوعی جایگزین امیدوارکننده‌ای برای روش‌های سنتی، مدل‌های اقتصادسنجی و روش‌های ناپارامتریک مانند تحلیل پوششی داده‌ها، جهت تخمین تابع تولید و تحلیل کارایی در شرایط غیر خطی، می‌باشند. وو و همکاران [۵] با ترکیب تحلیل پوششی داده‌ها و شبکه‌های عصبی مصنوعی به ارزیابی کارایی نسبی شعب یک بانک بزرگ کانادایی پرداختند. نتایج نشان داد، مدل ترکیبی NN-DEA مرز پایدارتری را ایجاد می‌کند و با توجه به یادگیری بهتر الگوی کارایی واحدهای کارای بیش‌تری را شناسایی می‌کند. وو [۱۱] از مدل ترکیبی تحلیل پوششی داده‌ها، شبکه عصبی و درخت تصمیم^۳ برای انتخاب تأمین کنندگان ارایه داد. نتایج تحقیق نشان داد درخت تصمیم و شبکه‌های عصبی هر دو در طبقه‌بندی و رگرسیون نتایج قابل قبولی ارایه می‌دهند. مصطفی [۱۲] کارایی بانک‌های عربی را با دو مدل کمی تحلیل پوششی داده‌ها و شبکه‌های عصبی مصنوعی بررسی کرد و نتایج نشان دهنده قدرت بالای شبکه‌های عصبی در پیش‌بینی کارایی می‌باشد. محرابیان و همکاران [۳۶]، از تلفیق روش تحلیل پوششی داده‌ها و شبکه‌های عصبی برای ارزیابی عملکرد شعب بانک اقتصاد نوین در ایران استفاده کردند.

۲-۲ پیشینه تحقیق در زمینه به کارگیری تحلیل پوششی داده‌ها در شرکت‌های توزیع برق

تاکنون مطالعات زیادی جهت ارزیابی عملکرد و اندازه‌گیری کارایی شرکت‌های توزیع برق انجام شده است. از مطالعات مهم در این زمینه می‌توان به موارد زیر اشاره کرد:

ژالمارسون و ویدرپرس [۱۳] در سوئد به بررسی کارایی بین شرکت‌های دولتی و خصوصی پرداختند که تفاوتی پیدا نکردند. امامی میبدی [۱۴] درجه کارایی شرکت‌های توزیع برق ایران را به روش تحلیل پوششی داده‌ها مورد بررسی قرار داد. چن [۱۵] کارایی فنی و کارایی نسبی شرکت‌های توزیع برق تایوان را به کمک تحلیل پوششی داده‌ها طی سال‌های ۱۹۹۷ تا ۱۹۹۸ مورد بررسی قرار داد. پاکودان و گازمان [۱۶] با استفاده از تحلیل پوششی داده‌ها عملکرد موثر و هم‌چنین اثر سیاست کارایی انرژی بر کارایی موثر صنعت توزیع نیروی برق را در فیلیپین مورد بررسی قرار دادند. نتایج به‌دست آمده از تحقیقات و مطالعات انجام شده نشان داد که عدم

^۱ CLOS

^۲ Stochastic Frontier Analysis

^۳ Decision Tree

کارایی شرکت‌های فیلیپینی به دلیل انحراف آن‌ها از کارایی قیاسی می‌باشد. هاتوری و همکاران [۱۷] در مقاله‌ای به مقایسه کارایی شرکت‌های توزیع برق انگلستان و ژاپن به‌روشنای تحلیل پوششی داده‌ها و تحلیل مرز تصادفی پرداختند و دریافتند کارایی شرکت‌های انگلیسی بیش‌تر از شرکت‌های ژاپنی می‌باشد. سجادی و عمرانی [۲] در پژوهشی برای ارزیابی عمل‌کرد دو دهه اخیر شرکت‌های توزیع نیروی برق از روش تحلیل پوششی داده‌ها با داده‌های غیردقیق در ستاده‌ها استفاده کردند و نتایج به‌دست آمده را با روش تحلیل مرز تصادفی مورد مقایسه قرار دادند و به این نتیجه رسید که DEA نتایج قابل اتکایی در تخمین کارایی و رتبه بندی استراتژی‌ها می‌دهد. راموس و همکاران [۱۸] در پژوهشی تغییرات کارایی تکنیکی و کارایی قیاسی جهت تخمین تغییرات در بهره‌وری شرکت‌های توزیع نیروی برق برزیل را بین سال‌های ۱۹۹۸-۲۰۰۵ مورد مقایسه قرار دادند. کالمن و همکاران [۱۹] کارایی شرکت‌های توزیع نیروی برق اروپای شرقی شامل کشورهای لهستان، جمهوری چک، اسلواکی و مجارستان به روش‌های ناپارامتریک تحلیل پوششی داده‌ها و پوسته دسترسی آزاد^۱ مورد بررسی قرار دادند و دریافتند که شرکت‌های توزیع برق لهستان ناکارا هستند، شرکت‌های توزیع نیروی برق اسلواکی و مجارستان دارای کارایی متوسط و شرکت‌های توزیع نیروی برق جمهوری چک کارایی نسبتاً بالایی دارند. خصوصی‌سازی اثر مثبتی بر کارایی فنی در چهار کشور داشته است. آزاده و همکاران [۴] جهت ارزیابی عمل‌کرد و خط‌مشی‌گذاری در ۳۸ شرکت توزیع برق ایران از ترکیب روش‌های پارامتریک و ناپارامتریک استفاده کردند. در این مقاله از تلفیق روش‌های تحلیل پوششی داده‌ها، حداقل مربعات معمولی تصحیح شده، تحلیل مرز تصادفی و تحلیل مؤلفه‌های اصلی^۲ استفاده شد.

۳ مبانی نظری

۳-۱ تحلیل پوششی داده‌ها

مدل DEA یک مدل ناپارامتریک است که برای تخمین درجه کارایی واحدهای تصمیم‌گیری به‌کار می‌رود. مدل‌های DEA می‌توانند ورودی‌محور یا خروجی‌محور باشند و هم‌چنین می‌توانند به‌صورت مدل‌های بازده به مقیاس ثابت (CRS) و یا بازده به مقیاس متغیر (VRS) مشخص شوند. مدل‌های ورودی‌محور مدل‌هایی هستند که بدون تغییر در خروجی‌ها از ورودی‌های کم‌تری برای به‌دست آوردن همان مقدار خروجی استفاده می‌کنند و مدل‌های خروجی‌محور، بدون تغییر در میزان ورودی، میزان خروجی بیش‌تری را به‌دست می‌آورند [۲۰].

مدل DEA در حالت بازده به مقیاس ثابت توسط چارنز و همکاران [۲۱] بر مبنای دیدگاه بهره‌وری کل بیان شد و به مدل معروف CCR گردید. در این مدل n واحد تصمیم‌گیرنده هرکدام دارای m ورودی و s خروجی می‌باشند. به عبارت دیگر $X_j = (x_{1j}, \dots, x_{mj})$ و $Y_j = (y_{1j}, \dots, y_{sj})$ که در آن $j = 1, \dots, n$ ، به‌ترتیب بردار ورودی و خروجی DMU_j است. مدل اولیه جهت اندازه‌گیری کارایی از طریق حل روش برنامه‌ریزی کسری^۳، به‌صورت نسبت مجموع موزون خروجی‌ها به مجموع موزون ورودی‌ها می‌باشد:

^۱ Free Disposal Hull (FDH)

^۲ Principal Component Analysis

^۳ Fractional Programming

$$\begin{aligned}
 \text{Max} \quad & \theta_o = \frac{\sum_{r=1}^s u_r y_{ro}}{\sum_{i=1}^m v_i x_{io}} \\
 \text{s.t.} \quad &
 \end{aligned}
 \tag{۱}$$

$$\begin{aligned}
 & \frac{\sum_{r=1}^s u_r y_{rj}}{\sum_{i=1}^m v_i x_{ij}} \leq 1, \quad j = 1, \dots, n, \\
 & u_r, v_i \geq 0, \quad r = 1, \dots, s, \quad i = 1, \dots, m.
 \end{aligned}$$

در مدل (۱) مقدار کارایی DMU_o ، θ_o نامیده می‌شود و u_r و v_i به ترتیب اوزان خروجی و ورودی می‌باشند. مدل شماره (۱) به دلیل مشکلاتی که در ارتباط با حل برنامه ریزی کسری وجود دارد، به مدل برنامه ریزی خطی^۱ (LP) به شکل مدل (۲) تغییر یافت. این مدل فرم مضربی مدل CCR ورودی محور نام گرفت:

$$\begin{aligned}
 \text{Max} \quad & \sum_{r=1}^s u_r y_{ro} \\
 \text{s.t.} \quad & \sum_{i=1}^m v_i x_{io} = 1, \\
 & \sum_{r=1}^s u_r y_{rj} - \sum_{i=1}^m v_i x_{ij} \leq 0, \quad j = 1, \dots, n, \\
 & u_r, v_i \geq 0, \quad r = 1, \dots, s, \quad i = 1, \dots, m.
 \end{aligned}
 \tag{۲}$$

دوآل مدل (۲) فرم پوششی مدل CCR ورودی محور می‌باشد که به شکل مدل (۳) بیان می‌شود:

$$\begin{aligned}
 \text{Min} \quad & \theta \\
 \text{s.t.} \quad & \sum_{j=1}^n \lambda_j x_{ij} \leq \theta x_{io}, \quad i = 1, \dots, m, \\
 & \sum_{j=1}^n \lambda_j y_{rj} \geq y_{ro}, \quad r = 1, \dots, s, \\
 & \lambda_j \geq 0, \quad j = 1, \dots, n.
 \end{aligned}
 \tag{۳}$$

با اضافه کردن محدودیت $\sum_{j=1}^n \lambda_j = 1$ به مدل (۳)، مدل پوششی BCC ورودی محور، به دست می‌آید که بازه به مقیاس متغیر است و به شکل مدل (۴) بیان می‌شود [۲۲]:

^۱ Linear Programming

$$\text{Min } \theta$$

$$s.t.$$

$$\begin{aligned} \sum_{j=1}^n \lambda_j x_{ij} &\leq \theta x_{io}, & i = 1, \dots, m, \\ \sum_{j=1}^n \lambda_j y_{rj} &\geq y_{ro}, & r = 1, \dots, s, \\ \sum_{j=1}^n \lambda_j &= 1, \\ \lambda_j &\geq 0, & j = 1, \dots, n. \end{aligned} \quad (4)$$

۲-۳ شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی یک الگوی پردازش اطلاعات است که به دنبال تقلید از رفتار سیستم‌های بیولوژیکی عصبی، مانند مغز انسان می‌باشد. شبکه عصبی می‌تواند از مثال‌ها یاد بگیرد و در میان داده‌ها، روابط دقیق عملکردی را متوجه شود؛ حتی اگر روابط اساسی مجهول و توصیف آن مشکل باشد [۲۳]. تحقیقات مختلف نشان دادند که شبکه‌های عصبی عملکرد بهتری از تکنیک‌های سنتی مانند رگرسیون چند متغیره دارد و برخلاف رگرسیون، برای مجموعه داده‌های بزرگ هم خوب عمل می‌کند [۲۴]. از مهم‌ترین خصوصیات شبکه عصبی می‌توان به قابلیت یادگیری یک نگاشت، مقام بودن در برابر نویز و پردازش موازی اطلاعات اشاره کرد [۲۵]. شبکه عصبی به کمک فرآیند یادگیری^۱ و با استفاده از پردازشگرهایی به نام نرون تلاش می‌کند با شناخت روابط ذاتی بین داده‌ها، نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهد. لایه‌های میانی یا لایه‌های مخفی^۲، اطلاعات دریافت شده از لایه ورودی را پردازش کرده و در اختیار لایه خروجی قرار می‌دهند. هر شبکه با دریافت مثال‌هایی آموزش می‌بیند. آموزش فرایندی است که در نهایت منجر به یادگیری می‌شود. یادگیری شبکه، زمانی انجام می‌شود که وزن‌های ارتباطی بین لایه‌ها چنان تغییر کند که اختلاف بین مقادیر پیش‌بینی شده و محاسبه شده در حد قابل قبولی باشد. با دست‌یابی به این شرایط فرایند یادگیری محقق شده است. وزن‌ها حافظه و دانش شبکه را بیان می‌کنند. شبکه عصبی آموزش دیده می‌تواند برای پیش‌بینی خروجی‌های متناسب با مجموعه جدید داده‌ها به کار رود [۲۶]. شبکه‌های عصبی از نوع ارتباطات به دو دسته شبکه‌های پیش‌رو^۳ و برگشتی^۴ تقسیم می‌شوند. گرچه محققین روش‌های متنوعی برای آموزش شبکه‌های عصبی ارائه نمودند؛ اما در یک طبقه‌بندی کلی به دو دسته یادگیری باناظر و بدون ناظر تقسیم می‌شود [۲۷].

¹ Learning

² Hidden Layers

³ Feed Forward

⁴ Recurrent

۳-۲-۱ شبکه پرسپترون چند لایه^۱

شبکه‌های موسوم به پرسپترون چند لایه (MLP) یکی از متداول‌ترین شبکه‌ها در پیش‌بینی و حل مسایل غیر خطی می‌باشند و جزو شبکه‌های پیش‌رو می‌باشد. این شبکه شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است. آموزش این شبکه‌ها با استفاده از الگوریتم پس‌انتشار خطا^۲ (BP)، که از نوع الگوریتم‌های آموزش با ناظر است، می‌باشد. الگوریتم پس‌انتشار خطا اساساً از دو مسیر اصلی تشکیل می‌شود [۲۸]. در طی آموزش شبکه MLP به کمک الگوریتم یادگیری BP، ابتدا محاسبات از ورودی‌های شبکه به‌سوی خروجی‌های شبکه انجام می‌شود (مسیر رفت) و سپس مقادیر خطای محاسبه شده به لایه‌های قبل انتشار می‌یابد (مسیر برگشت). محاسبه خروجی به‌صورت لایه به لایه انجام می‌شود و خروجی هر لایه، ورودی لایه بعدی خواهد بود. در حالت پس‌انتشار، ابتدا لایه‌های خروجی تعدیل می‌شود؛ زیرا برای هر یک از نرون‌های لایه خروجی، مقدار مطلوبی وجود دارد و می‌توان به کمک آن‌ها و قاعده‌های بهنگام‌سازی، وزن‌ها را تعدیل نمود [۲۶].

۳-۲-۲ الگوریتم لونبرگ - مارکوآرت^۳ (LM)

الگوریتم آموزش لونبرگ - مارکوآرت از الگوریتم‌های پس‌انتشار خطا می‌باشد که برای پرسپترون چند لایه کاربرد دارد [۲۹]. از آن‌جا که برای آموزش شبکه عصبی بر اساس الگوریتم LM محاسبات به‌صورت موازی انجام می‌شود، جزء سریع‌ترین روش‌ها برای آموزش شبکه عصبی پس‌انتشار خطا با کم‌تر از صد اتصال وزنی محسوب می‌شود. الگوریتم LM اساساً بر مبنای ماتریس هسین^۴ است که برای بهینه‌سازی غیرخطی بر مبنی حداقل مربعات استفاده می‌شود [۳۰].

۳-۲-۳ الگوریتم شیب توام^۵ (CG)

الگوریتم‌های پایه پس‌انتشار خطا وزن‌ها را در خلاف جهت شیب اصلاح می‌کنند، این همان جهتی است که تابع کارایی در آن سمت به‌سرعت کاهش می‌یابد. این جهت بیش‌ترین میزان کاهش را در پی دارد؛ ولی لزوماً منتهی به همگرایی بیش‌تر نخواهد شد؛ بنابراین بهتر است تواماً چند جهت را چک کنیم. چندین الگوریتم مختلف شیب توام نظیر Fletcher-Reeves، Polak-Ribiere، Powell-Beale Restarts و الگوریتم شیب توام مقیاس شده^۶ (SCG) وجود دارند [۳۱].

¹ Multi-Layer Perceptron

² Back Propagation

³ Levenberg-Marquardt

⁴ Hessian matrix

⁵ Conjugate Gradient Algorithms

⁶ Scaled Conjugate Gradient

۳-۲-۴ الگوریتم شیب توام مقیاس شده (SCG)

تمامی الگوریتم‌های شیب توام نیاز به یک جستجوی خطی در هر تکرار دارند. این جستجوی خطی از لحاظ محاسباتی بسیار گران تمام می‌شود؛ زیرا شبکه باید به تمام ورودی‌های آموزش عکس‌العمل نشان داده و برای هر جستجو چندین پارامتر را حساب کند. الگوریتم SCG طوری طراحی شده که از جستجوی خطی زمان‌بر دوری کند. اساس کار این الگوریتم ترکیب دو روش شیب توام و لونبرگ - مارکوآرت می‌باشد [۳۱].

۴ روش تحقیق

۴-۱ مدل Neural-DEA

در این پژوهش مدل Neural-DEA بر پایه ترکیب دو روش DEA (مدل CCR با ماهیت ورودی) و شبکه عصبی می‌باشد و جهت اندازه‌گیری اعداد کارایی شرکت‌های توزیع برق مورد استفاده قرار می‌گیرد. مجموع ورودی‌ها و خروجی‌های به کار گرفته شده هر DMU در DEA به عنوان ورودی شبکه عصبی استفاده می‌شود. شبکه از یادگیری با ناظر استفاده می‌کند و بردار یادگیری آن کارایی‌ای است که قبلاً توسط DEA محاسبه شده است. خروجی شبکه نیز عددی تقریباً بین صفر و یک می‌باشد که مقدار کارایی واحدها را نشان می‌دهد. شبکه پس از آموزش، الگوی کارایی را یاد گرفته و قدرت تعمیم آن برای داده‌های جدید را دارد. برای محاسبه کارایی با استفاده از مدل Neural-DEA مراحل زیر را باید انجام داد:

۱. انتخاب متغیرها و جمع‌آوری داده‌ها

انتخاب متغیرهای ورودی و خروجی یکی از مهم‌ترین گام‌ها در ارزیابی شرکت‌های توزیع برق است. عدم انتخاب صحیح متغیرهای مورد نیاز، نتایج ارزیابی بین شرکت‌های توزیع نیروی برق را بی‌اعتبار می‌سازد. شایان ذکر است که تا کنون هیچ اجماعی در بین شرکت‌های توزیع برق برای انتخاب بهترین متغیر که بتواند عملکرد این شرکت‌ها را به خوبی نشان دهد، وجود ندارد [۳۲]. با بررسی تحقیقات گذشته ارزیابی شرکت‌های توزیع برق مانند: امامی میبدی [۱۴]، پاکودان [۱۶]، هاتوری و همکاران [۱۷]، کالمن و همکاران [۱۹]، سجادی و عمرانی [۲] راموس و همکاران [۱۸]، چن [۱۵]، آزاده و همکاران [۴]، قادری و همکاران [۳]، فلاحی و احمدی [۱] پر استفاده‌ترین متغیرهای ورودی را طول شبکه، ظرفیت ترانسفورماتور، تعداد کارکنان تشکیل می‌دهند. همچنین پر استفاده‌ترین متغیرهای خروجی میزان برق فروخته‌شده، انرژی تحویلی و تعداد مشترکین می‌باشد. با توجه به تحقیقات گذشته و به دلیل این که معمولاً داده‌های هزینه‌ای در دسترس نیستند و تحقیقات نشان داده است که ۸۵٪ هزینه‌ها با تعداد مشترکین و کل فروش برق تغییر می‌کند، ورودی‌ها و خروجی‌های مورد استفاده در این پژوهش عبارتند از:

جدول ۱. متغیرهای ورودی و خروجی مورد استفاده

ورودی ها	خروجی ها
طول خطوط شبکه (بر حسب کیلومتر)	تعداد مشترکین (هزار نفر)
ظرفیت ترانسفورماتور (MVA)	کل فروش برق (MWh)
تعداد کارکنان (نفر)	

برای استانداردسازی میزان تاثیر هر متغیر بر نتیجه باید متغیرهای عددی را هم مقیاس یا نرمال سازی کرد [۳۳]. همچنین جهت افزایش دقت و سرعت یادگیری شبکه های عصبی، داده های مورد استفاده نرمال می شود. برای این منظور، روش های متعددی ارایه گردیده، که در این تحقیق از رابطه (۵) برای نرمال سازی داده ها استفاده شد.

$$N_{ij} = \frac{X_{ij}}{\max(X_{ij})}; \quad i = 1, \dots, 39, \quad j = 1, \dots, 5 \quad (5)$$

در رابطه (۵) N_{ij} مقدار نرمال شده i امین متغیر برای i امین شرکت توزیع برق می باشد و X_{ij} مقدار واقعی i امین متغیر برای i امین شرکت توزیع می باشد. در این پژوهش از داده های سال های ۱۳۸۷، ۱۳۸۸، ۱۳۸۹ مربوط به ۳۹ شرکت توزیع برق ایران که برگرفته از «سالنامه آمار تفصیلی صنعت برق ایران توزیع نیروی برق» می باشد، استفاده شده است.

۲. محاسبه کارایی

با استفاده از داده های جمع آوری شده کارایی تمام واحدهای تصمیم گیرنده در سال های ۱۳۸۷، ۱۳۸۸ و ۱۳۸۹ با مدل CCR تحلیل پوششی داده ها محاسبه می شود.

۳. انتخاب مجموعه داده های آموزش، اعتبارسنجی ۱ و آزمایش

به طور معمول در پیش بینی با شبکه های عصبی داده ها به دو بخش آموزش و آزمایش تقسیم می شود [۳۴]؛ ولی یکی از مشکلاتی که در حین آموزش شبکه های عصبی با آن مواجه هستیم، انطباق بیش از حد^۲ می باشد. این بدان معنا است که میزان خطای آموزش شبکه بسیار پایین می باشد؛ ولی میزان خطای داده های آزمایش بالا می باشد و شبکه نمونه داده های آموزش را حفظ کرده و قدرت تعمیم را برای داده های جدید ندارد. برای رفع این مشکل، داده ها را به سه دسته داده های آموزش و اعتبارسنجی و آزمایش تقسیم می کنیم [۳۵].

در این پژوهش ۸۰٪ داده های مربوط به سال های ۱۳۸۷ و ۱۳۸۸ جهت مجموعه داده های آموزش شبکه، ۲۰٪ داده های مربوط به سال های ۱۳۸۷ و ۱۳۸۸ جهت مجموعه داده های اعتبارسنجی و داده های سال ۱۳۸۹ جهت آزمایش شبکه استفاده می کنیم.

۴. آموزش شبکه و معیار توقف آن

در این مرحله شبکه با استفاده از مجموعه داده های آموزش و اعتبارسنجی که در گام قبلی انتخاب شدند آموزش می بیند. میزان خطا در داده های اعتبارسنجی معمولاً در حین آموزش باید کاهش یابد و همچنین زمانی که شبکه

¹ Validation
² Over Fitting

شروع به آموزش بیش از اندازه داده‌ها می‌کند، میزان خطا در داده‌های اعتبارسنجی افزایش می‌یابد [۳۵]؛ بنابراین در این پژوهش زمانی که میزان خطا در داده‌های اعتبارسنجی افزایش یابد، آموزش متوقف می‌شود.

۵. آزمایش شبکه و مقایسه نتایج DEA و Neural-DEA

جهت تست شبکه و همچنین اندازه‌گیری کارایی واحدهای جدید با استفاده از شبکه عصبی آموزش دیده، از داده‌های سال ۱۳۸۹ استفاده می‌کنیم. شبکه‌های آموزش دیده با تعداد لایه‌های پنهان متفاوت و نرون‌های متفاوت در هر لایه، تست می‌شود. از میان شبکه‌ها با ساختارهای مختلف، شبکه با بهترین عملکرد در پیش‌بینی اعداد کارایی انتخاب می‌شود. جهت تعیین بهترین ساختار شبکه عصبی برای پیش‌بینی اعداد کارایی از ۴ شاخص میانگین مربع خطا^۱، میانگین مربع خطای نرمالیزه شده^۲، میانگین خطای مطلق^۳ و ضریب تعیین (r^2) استفاده گردید که در روابط (۶)، (۷)، (۸) و (۹) نشان داده شده است.

$$MSE = \frac{\sum_{i=1}^n (O_i - P_i)}{n} \quad (۶)$$

$$NMSE = \frac{1}{\sigma^2} \frac{1}{n} \sum_{i=1}^n (O_i - P_i) \quad (۷)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - P_i| \quad (۸)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (۹)$$

در روابط فوق O_i و P_i به ترتیب مقادیر واقعی و پیش‌بینی شده داده i ام، n تعداد داده‌ها و σ^2 واریانس داده‌ها و $\bar{O}$ میانگین مقادیر واقعی می‌باشد.

۴-۲ ساختار شبکه عصبی


در این مقاله، برای ساخت مدل Neural-DEA از یک شبکه عصبی چند لایه پیش‌خور که عموماً شبکه‌های چند لایه پرسپترون هم نامیده می‌شود، استفاده می‌گردد. در این شبکه ورودی‌های شبکه شامل مجموع ورودی‌ها و خروجی‌های هر DMU است. خروجی مورد انتظار شبکه، عدد کارایی هر DMU که به روش تحلیل پوششی داده‌ها به دست آمده، می‌باشد. تعداد لایه‌های پنهان نیز به روش آزمون و خطا تعیین می‌گردد. تابع تبدیل لایه پنهان، تابع تانژانت هیپربولیک و تابع تبدیل لایه خروجی، تابع خطی می‌باشد. در این پژوهش از میان روش‌های مختلف آموزش به روش پس انتشار خطا، الگوریتم لونیبرگ - مارکوآرت (LM) و از بین روش‌های مختلف

^۱ Mean-squared error (MSE)

^۲ Normalized mean-squared error (NMSE)

^۳ Mean absolute error (MAE)

آموزش شیب توام، الگوریتم آموزش شیب توام مقیاس شده (SCG) استفاده شده است و نتایج به دست آمده از این دو الگوریتم آموزش با هم مورد مقایسه قرار می گیرد. در شکل (۱) ساختار شبکه عصبی مورد استفاده نشان داده شده است.



شکل ۱. ساختار شبکه عصبی مورد استفاده در این پژوهش

۵ تجزیه و تحلیل اطلاعات

در این پژوهش کارایی ۳۹ شرکت توزیع نیروی برق ایران در سال ۱۳۸۹ به دو روش DEA و Neural-DEA مورد محاسبه قرار می گیرد. در جدول (۲) خلاصه آماری داده های سال ۱۳۸۹ نشان داده شده است.

جدول ۲. خلاصه آماری داده های سال ۱۳۸۹

متغیر	مینیمم	ماکزیمم	میانگین	انحراف استاندارد
طول شبکه	۶۲۰۸	۳۶۷۷۰	۱۶۸۸۳/۱۲	۷۸۵۹/۹۸
ظرفیت ترانسفورماتور	۶۱۹	۹۴۵۰	۲۲۱۳/۳۳	۱۶۱۵/۱۲
تعداد کارکنان	۱۶۵	۲۰۴۸	۵۰۰/۴۱	۳۳۳/۰۸۳
تعداد مشترکین	۱۵۹	۳۶۸۸	۶۵۸/۲۵	۵۶۹/۴۶
میزان برق فروخته شده	۹۱۹	۱۷۴۲۰	۳۹۵۰/۶۹	۳۰۳۹/۸۳

برای اندازه گیری کارایی شرکت های توزیع در سال ۱۳۸۹ به روش Neural-DEA، شبکه های مختلف با تعداد لایه های میانی و نرون های مختلف در لایه های میانی و دو الگوریتم آموزش LM و SCG با استفاده از داده های سال ۱۳۸۷-۱۳۸۸ آموزش می بینند. برای آزمایش شبکه و هم چنین اندازه گیری کارایی شرکت های توزیع برق با استفاده از شبکه های عصبی در سال ۱۳۸۹، از داده های سال ۱۳۸۹ استفاده شده است. در این پژوهش برای اجرای مدل های شبکه عصبی از نرم افزار NeuroSolution نسخه ۵ استفاده شد. هر شبکه ۶ بار آموزش می بیند و شبکه با بهترین عمل کرد در آموزش مورد آزمایش قرار می گیرد. از بین ساختارهای متفاوت آزمایش شده بهترین شبکه برای پیش بینی اعداد کارایی CCR با توجه به معیارهای MSE، NMSE، MAE و R^2 انتخاب می گردد. در جدول های شماره (۳) و (۴) مقدار معیارها برای شبکه های عصبی با ساختارهای مختلف با دو الگوریتم آموزش LM و SCG نشان داده شده است.

جدول ۳. اثر تعداد لایه پنهان و نرون‌های آن بر دقت پیش‌بینی CCR با شبکه عصبی با الگوریتم LM

مدل	تعداد نرون‌های لایه پنهان		MSE	NMSE	MAE	R^2
	۱	۲				
۱	۴		۰/۰۰۴۲۲۹۷۸	۰/۲۴۳۵۴۵	۰/۰۴۵۲۸۴	۰/۷۸۷۳۸۱
۲	۵		۰/۰۰۱۰۰۱۸۳	۰/۰۵۷۶۸۴	۰/۰۲۲۱۷۷	۰/۹۴۵۵۳۳
۳	۶		۰/۰۰۱۴۳۰۵۸	۰/۰۸۲۳۷۱	۰/۰۲۷۲۰۵	۰/۹۵۲۶۰۵
۴	۷		۰/۰۰۱۷۱۹۸۶	۰/۰۹۹۰۲۷	۰/۰۳۳۹۳۱	۰/۹۴۳۴۹۱
۵	۸		۰/۰۰۴۱۹۳۲۸	۰/۲۴۱۴۴۳	۰/۰۴۳۴۸	۰/۸۱۳۳۳۸
۶	۹		۰/۰۰۱۲۵۸۳۳	۰/۰۷۲۴۵۳	۰/۰۲۷۳۵۱	۰/۹۶۴۹۴۲
۷	۱۰		۰/۰۰۲۲۸۷۳۱	۰/۱۳۱۷	۰/۰۳۱۵۷۸	۰/۹۱۵۹۱۳
۸	۴	۴	۰/۰۰۱۳۶۹۸۴	۰/۰۷۸۸۷۳	۰/۰۲۷۷۱۵	۰/۹۵۱۴۶۶
۹	۵	۵	۰/۰۰۰۷۱۷۹۲	۰/۰۴۱۳۳۷	۰/۰۲۱۷۳۱	۰/۹۷۷۱۹۴
۱۰	۶	۶	۰/۰۰۱۴۱۰۶۳	۰/۰۸۱۲۲۲	۰/۰۲۸۸۲۸	۰/۹۵۴۶۸۶
۱۱	۷	۷	۰/۰۰۱۱۵۸۳۸	۰/۰۶۶۶۹۸	۰/۰۲۷۱۴۶	۰/۹۶۰۴۴۴
۱۲	۸	۸	۰/۰۰۱۱۰۹۱۱	۰/۰۶۳۸۶۱	۰/۰۲۷۰۷۷	۰/۹۶۷۶۸۹
۱۳	۹	۹	۰/۰۰۱۱۵۸۶۷	۰/۰۶۶۷۱۵	۰/۰۲۶۸۵۴	۰/۹۶۳۳۸۴
۱۴	۱۰	۱۰	۰/۰۰۱۰۵۶۶۵	۰/۰۶۰۸۴	۰/۰۲۵۰۸۵	۰/۹۶۱۹۶۱

جدول ۴. اثر تعداد لایه پنهان و نرون‌های آن بر دقت پیش‌بینی CCR با شبکه عصبی با الگوریتم SCG

مدل	تعداد نرون‌های لایه پنهان		MSE	NMSE	MAE	R^2
	۱	۲				
۱	۴		۰/۰۰۲۱۲۴	۰/۱۲۲۳۰۳	۰/۰۳۵۹۹۴	۰/۹۱۷۰۵۷
۲	۵		۰/۰۰۶۱۱۵	۰/۳۵۲۰۷۹	۰/۰۶۱۸۹	۰/۷۴۷۵۹۸
۳	۶		۰/۰۰۴۱۸۱	۰/۲۴۰۷۲۱	۰/۰۵۱۷۸۴	۰/۸۳۵۹۸۶
۴	۷		۰/۰۰۳۴۵۲	۰/۱۹۸۷۴۴	۰/۰۴۸۷۹۱	۰/۸۶۳۳۰۳
۵	۸		۰/۰۰۲۳۹۲	۰/۱۳۷۷۳۲	۰/۰۴۰۱۰۱	۰/۹۰۸۴۸۹
۶	۹		۰/۰۰۳۵۲۱	۰/۲۰۲۷۶۲	۰/۰۴۶۹۶۹	۰/۸۴۹۰۳
۷	۱۰		۰/۰۰۵۲۷۵	۰/۳۰۳۷۱۸	۰/۰۵۶۸۱۸	۰/۷۸۰۸۳۳
۸	۴	۴	۰/۰۰۵۶۷۵	۰/۳۲۶۷۴۶	۰/۰۵۷۹۷۷	۰/۷۴۵۵۲۴
۹	۵	۵	۰/۰۰۳۴۶۸	۰/۱۹۹۶۶	۰/۰۴۵۶۲۵	۰/۸۴۸۴۴۲
۱۰	۶	۶	۰/۰۰۲۴	۰/۱۳۸۲۱۶	۰/۰۳۹۲۷۲	۰/۸۷۴۷۵۳
۱۱	۷	۷	۰/۰۰۴۵۴۵	۰/۲۶۱۷۲	۰/۰۵۵۷۰۵	۰/۷۹۶۵۷۱
۱۲	۸	۸	۰/۰۰۳۹۸۱	۰/۲۲۹۲۲۹	۰/۰۵۱۳۲۲	۰/۸۰۰۰۱۶
۱۳	۹	۹	۰/۰۰۴۵۷۱	۰/۲۶۳۲۱۷	۰/۰۵۳۹۶۶	۰/۷۹۹۵۲۹
۱۴	۱۰	۱۰	۰/۰۰۴۶۷۲	۰/۲۶۹۰۱۹	۰/۰۵۵۶۹۶	۰/۸۱۴۹۹۶

بهترین توپولوژی شبکه با الگوریتم آموزش LM جهت پیش‌بینی عدد کارایی CCR، مدل شماره ۹ از جدول شماره (۳)، یعنی پرسپترون دولایه با تعداد پنج نرون در لایه‌های میانی تعیین شد. جدول شماره (۵) بهترین نتیجه

برای شش بار آموزش مدل بهینه با الگوریتم LM (مدل شماره ۹) را نشان می‌دهد. جدول شماره (۶) نتایج تست، شبکه بهینه آموزش دیده با الگوریتم LM (مدل شماره ۹) را برای پیش‌بینی اعداد کارایی CCR نشان می‌دهد.

جدول ۵. نتایج آموزش مدل بهینه با الگوریتم LM

Best Networks	Training	Cross Validation
Run #	۱	۱
Epoch #	۹۹۹	۱۸۲
Minimum MSE	۰/۰۰۰۰۰۲۵۸۹۸۹	۰/۰۰۵۰۰۶۶۰۲
Final MSE	۰/۰۰۰۰۰۵۰۹۸۷	۰/۰۰۱۴۹۰۵۳۵۶

جدول ۶. نتایج تست مدل بهینه با الگوریتم LM

Performance	desired
MSE	۰/۰۰۰۷۱۷۹۱۷
NMSE	۰/۰۴۱۳۳۶۶۸۱
MAE	۰/۰۲۱۷۳۰۸۴۱
Min Abs Error	۰/۰۰۰۸۹۲۲
Max Abs Error	۰/۰۶۲۲۶۹۴۴۱
R	۰/۹۸۸۵۳۱۲۵

بهترین توپولوژی شبکه با الگوریتم آموزش SCM جهت پیش‌بینی عدد کارایی CCR، مدل شماره ۱ از جدول شماره (۴)، یعنی پرسپترون با یک لایه پنهان و ۴ نرون در لایه پنهان تعیین شد. جدول شماره (۷) بهترین نتیجه برای شش بار آموزش مدل بهینه با الگوریتم SCG (مدل شماره ۱) را نشان می‌دهد. جدول شماره (۸) نتایج تست شبکه آموزش دیده با الگوریتم SCM (مدل شماره ۱) را برای پیش‌بینی اعداد کارایی CCR نشان می‌دهد.

جدول ۷. نتایج آموزش مدل بهینه با الگوریتم SCG

Best Networks	Training	Cross Validation
Run #	۳	۳
Epoch #	۱۰۰۰	۸۸۲
Minimum MSE	۰/۰۰۶۴۸۷۶۵۸	۰/۰۲۳۹۸۴۴۵۵
Final MSE	۰/۰۰۶۴۸۷۶۵۸	۰/۰۳۱۹۶۵۱۲۱

ضریب همبستگی ۰/۹۸۸ برای شبکه با الگوریتم آموزش LM و ۰/۹۵۳ برای شبکه با الگوریتم آموزش SCG نشان‌دهنده قدرت بالای شبکه‌های عصبی جهت پیش‌بینی کارایی شرکت‌های توزیع برق می‌باشد. همچنین با مقایسه سایر معیارهای عملکردی دو شبکه با الگوریتم آموزشی LM و SCG که به ترتیب در جدول شماره (۵) و


(۷) نشان داده شده است، پی‌می‌بریم شبکه با الگوریتم LM از قدرت بیش‌تری برای اندازه‌گیری کارایی شرکت‌های توزیع برخوردار است. جدول شماره (۹) نتایج کارایی CCR مدل‌های DEA و Neural-DEA با الگوریتم‌های آموزش LM و SCG را برای داده‌های سال ۱۳۸۹ شرکت توزیع نیروی برق نشان می‌دهد. شکل‌های (۲) و (۳) مقایسه نتایج شبکه عصبی با الگوریتم LM و SCG را با نتایج تحلیل پوششی داده‌ها برای سال ۱۳۸۹ نشان می‌دهد.

جدول ۸. نتایج تست مدل بهینه با الگوریتم SCG


Performance	desired
MSE	۰/۰۰۲۳۹۲۰۶۳
NMSE	۰/۱۳۷۷۳۱۶۵۳
MAE	۰/۰۴۰۱۰۰۸۹۶
Min Abs Error	۰/۰۰۰۸۶۷۴۱
Max Abs Error	۰/۱۰۸۰۲۷۳۱۱
r	۰/۹۵۳۱۴۶۸۵۱

جدول ۹. نتایج کارایی CCR به روش‌های DEA و شبکه‌های عصبی با الگوریتم آموزش LM و SCG

شرکت توزیع	DEA	خروجی شبکه با الگوریتم SCG	شرکت توزیع	DEA	خروجی شبکه با الگوریتم LM	خروجی شبکه با الگوریتم SCG	خروجی شبکه با الگوریتم LM
شهرستان تبریز	۱	۱/۰۰۷۶۵۷	استان کهگیلویه و بویر احمد	۱/۰۲۵۵۱	۰/۵۱۷۰۳۵	۰/۴۸۸۵۶۵	۰/۵۱۵۹۴۹
استان آذربایجان شرقی	۰/۸۶۰۲۳۹	۰/۸۷۶۵۵	استان زنجان	۰/۸۷۹۵۳۸	۰/۸۱۵۳۳	۰/۸۵۱۰۳۶	۰/۸۴۱۵۱۱
استان آذربایجان غربی	۰/۸۹۳۱۵۶	۰/۹۰۰۶۵۱	استان قزوین	۰/۹۴۹۹۸۵	۱	۱/۰۳۵۷۱۵	۱/۰۲۶۶۸۶
استان اردبیل	۱	۱/۰۴۹۷۵۱	استان سمنان	۰/۹۷۵۸۵۹	۰/۷۷۱۶۶۴	۰/۷۷۴۷۸	۰/۷۸۵۹۹۵
استان اصفهان	۰/۷۹۷۴۸۶	۰/۷۹۳۰۶	سیستان و بلوچستان	۰/۸۸۷۵۸	۰/۶۷۴۵۶۶	۰/۷۶۸۸۶۷	۰/۶۴۲۲۷۹
شهرستان اصفهان	۱	۱/۰۲۸۰۲۶	استان کرمانشاه	۱/۰۱۹۹۶۵	۰/۸۰۳۶۷۸	۰/۷۷۴۴۵۵	۰/۸۱۴۹۱۸
استان چهارمحال و بختیاری	۰/۶۵۳۲۱۴	۰/۶۶۲۴۰۳	استان کردستان	۰/۷۳۰۰۲۹	۰/۸۵۳۳۱۸	۰/۹۱۹۳۸۲	۰/۸۹۱۱
استان مرکزی	۰/۸۳۵۲۵۲	۰/۸۳۸۵۵۷	استان ایلام	۰/۸۶۹۹۷۳	۰/۵۵۷۶۱۷	۰/۶۴۷۱۰۸	۰/۵۶۹۹۷۳
استان همدان	۰/۶۳۰۸۰۶	۰/۶۵۴۰۴۷	شهرستان شیراز	۰/۶۶۶۵۸۱	۰/۶۹۹۹۶۱	۰/۷۴۶۷	۰/۷۲۳۷۵۷
استان لرستان	۰/۶۶۲۶۵۱	۰/۶۹۰۰۹۵	استان فارس	۰/۷۱۲۵	۰/۸۱۶۸۳۱	۰/۸۳۴۳۹۴	۰/۷۶۹۱۷۹
غرب استان تهران	۱	۱/۰۲۵۸۱۱	استان بوشهر	۰/۹۶۸۰۸۸	۰/۹۵۶۸۹۶	۰/۸۴۸۸۶۹	۰/۹۷۵۳۲۹
تهران بزرگ	۱	۱/۰۰۰۸۹۲	شمال استان کرمان	۱/۰۱۰۷۴۱	۰/۷۶۵۵۹۲	۰/۷۷۳۱۹۱	۰/۷۷۶۰۰۲
نواحی تهران	۰/۶۹۰۲۰۶	۰/۶۹۶۷۳۴	جنوب استان کرمان	۰/۷۱۳۳۵۶	۰/۶۲۹۹۰۳	۰/۶۶۶۵۹۶	۰/۶۷۵۴۱۷
استان قم	۰/۸۵۶۱۱۵	۰/۸۶۶۶۱۹	استان گیلان	۰/۹۲۰۱۰۶	۰/۹۰۵۳۱۵	۰/۹۰۴۴۴۸	۰/۹۳۰۶۰۵
شهرستان مشهد	۱	۱/۰۰۹۳۲۹	استان مازندران	۱/۰۴۴۸۸۲	۰/۷۴۴۶۳۵	۰/۷۵۱۳۳۶	۰/۷۶۱۳۹۱
استان خراسان رضوی	۰/۹۷۸۱۵	۱/۰۰۱۷۴۵	غرب استان مازندران	۰/۹۷۰۸۳۸	۰/۸۲۸۸۰۵	۰/۸۴۰۲۸۶	۰/۸۴۳۳۰۴
استان خراسان شمالی	۰/۸۰۴۱۶۱	۰/۸۶۶۴۳	استان گلستان	۰/۸۸۶۵۵۵	۰/۷۶۰۹۸	۰/۷۷۷۰۵	۰/۸۰۲۷۴۵
استان خراسان جنوبی	۰/۸۰۵۵۰۳	۰/۸۲۱۲۲۳	استان هرمزگان	۰/۸۵۵۹۵۹	۰/۸۰۲۹۹۹	۰/۸۳۵۲۲۲	۰/۸۶۳۹۷
شهرستان اهواز	۱	۱/۰۱۹۳۸۸	استان یزد	۱/۰۸۳۰۹۲	۰/۸۰۵۳۹۴	۰/۸۴۵۷۴۵	۰/۸۲۸۱۰۲
استان خوزستان	۰/۸۷۵۰۲۱	۰/۸۷۱۱۴۶		۰/۸۹۷۹۷۳			



شکل ۲. نمودار مقایسه نتایج DEA(CCR) و شبکه عصبی با الگوریتم آموزش LM



شکل ۳. نمودار مقایسه نتایج DEA(CCR) و شبکه عصبی با الگوریتم آموزش SCG

نتایج کارایی جدول (۹) نشان می‌دهد، میانگین کارایی شرکت‌های توزیع به‌روش CCR برای داده‌های سال ۱۳۸۹ برابر ۰/۸۲۱ و میانگین کارایی با استفاده از شبکه عصبی با الگوریتم آموزش LM و SCM به‌ترتیب برابر ۰/۸۳۸ و ۰/۸۵ می‌باشد. کم‌ترین میزان خطا در پیش‌بینی با شبکه عصبی با الگوریتم LM و SCG به‌ترتیب برابر ۰/۰۰۰۸۹ و ۰/۰۰۰۸۶ و بیش‌ترین خطا به‌ترتیب برابر ۰/۰۶۲ و ۰/۱۰۸ می‌باشد.

۶ نتیجه‌گیری

در این پژوهش در یک مطالعه موردی به تخمین کارایی شرکت‌های توزیع نیروی برق در سال ۱۳۸۹ به‌روش DEA و Neural-DEA پرداختیم. برای پیش‌بینی کارایی شرکت‌های توزیع نیروی برق با استفاده از شبکه‌های عصبی از دو الگوریتم آموزش LM و SCG استفاده گردید. نتایج نشان می‌دهد، شبکه عصبی با الگوریتم آموزش

LM و SCG کارایی شرکت‌های توزیع برق را به ترتیب با ضریب همبستگی r ۰/۹۸۸ و ۰/۹۵۳ پیش‌بینی می‌کنند، که بیان‌کننده قدرت بالای شبکه‌های عصبی در اندازه‌گیری کارایی می‌باشد و این‌که دو روش تحلیل پوششی داده‌ها و روش ترکیبی شبکه عصبی و تحلیل پوششی داده‌ها سازگاری خوبی در تعیین اعداد کارایی دارند. بررسی ضریب همبستگی r و سایر شاخص‌های عملکردی شبکه‌های عصبی؛ یعنی MSE، NMSE، MAE نشان می‌دهد شبکه‌های عصبی با الگوریتم آموزش LM از دقت و قدرت بیش‌تری در اندازه‌گیری کارایی برخوردار می‌باشد. برای انجام تحقیقات آتی می‌توانیم، از شبکه عصبی خود سازمانده که مستقل از DEA عمل کند و قابلیت اندازه‌گیری کارایی برای واحدها را دارا باشد، استفاده کنیم.

منابع

- [۱] فلاحی، م.، احمدی، و.، (۱۳۸۴). ارزیابی کارایی شرکت‌های توزیع برق در ایران. مجله تحقیقات اقتصادی، ۷۱، ۲۹۷-۳۲۰.
- [۳] قادری، س. د.، آزاده، م. ع.، عمرانی، ه.، (۱۳۸۷). ارزیابی عملکرد شرکت‌های توزیع برق با روش‌های تحلیل پوششی داده‌ها و حداقل مربعات معمولی تصحیح شده. مجله علمی پژوهشی شریف، ۴۳، ۱۳۷-۱۴۲.
- [۲۵] قره آغاجی، ع. ا.، پالهنک، م.، شنبه، م.، (۱۳۸۴). استفاده از الگوریتم‌های شبکه عصبی مصنوعی در پیش‌بینی خصوصیات کششی نخ‌های مغزی دار با مغزی نایلون و رویه پنبه. مجله استقلال، ۲۴(۲)، ۲۴۱-۲۵۱.
- [۲۶] بهروزی خزاعی، ن.، توکلی، ت.، امیری چایجان، ر.، خوش تقاضا، م. ه.، (۱۳۸۷). کاربرد شبکه عصبی مصنوعی در پیش‌بینی محتوای رطوبتی در طی فرایند خشک‌کن انگور. پنجمین کنگره ملی مهندسی ماشین‌های کشاورزی و مکانیزاسیون.
- [۲۷] خشی، ح.، خراسانی، م.، فدوی، م. ر.، قدرتی امیری، غ.، برخورداری، م. ع.، (۱۳۸۸). تخمین پارامترهای شتاب، سرعت و جابجایی ماکزیمم زمین با استفاده از شبکه عصبی مصنوعی. مجله مدل سازی در مهندسی، ۷(۱۹)، ۱۱-۲۲.
- [۲۸] عیوضی، م.، مساعدی، ا.، دقانی، ا. ا.، (۱۳۸۸). مقایسه روش‌های مختلف پیش‌بینی شاخص خشک سالی SPI، مجله پژوهش‌های حفاظت آب و خاک، ۱۶(۲)، ۱۴۵-۱۶۷.
- [۲۹] سلطانی، س.، سرداری، س.، شیخ‌پور، م.، موسوی، س. ص.، (۱۳۸۹). شبکه‌های عصبی مصنوعی مبانی، کاربردها و آشنایی با نرم‌افزار EasyNN-plus و NeuroSolution. تهران، نشر «نص».
- [۳۰] شریفی، م.، رفیعی، ش.، کیهانی، ع.، امید، م.، (۱۳۸۷). شبیه سازی مدل سینتیک خشک شدن بستر نازک پرتقال رقم تامسون با استفاده از شبکه‌های عصبی مصنوعی. پایگاه اطلاعات علمی (SID)، ۳۹-۴۹.
- [۳۱] کیا، م.، (۱۳۸۹). شبکه‌های عصبی در MATLAB، تهران: خدمات نشر کیان رایانه سبز.
- [۳۴] اصفهانیان، م.، امین ناصری، م. ر.، (۱۳۸۷). ارایه یک مدل شبکه عصبی جهت پیش‌بینی کوتاه مدت قیمت نفت خام. نشریه بین المللی علوم مهندسی دانشگاه علم و صنعت، ۱۹(۱)، ۲۷-۳۵.
- [۳۶] محرابیان، س.، ساعتی مهدی، ص.، هادی، ع.، (۱۳۹۰). ارزیابی کارایی شعب بانک اقتصاد نوین با ترکیبی از روش شبکه عصبی و تحلیل پوششی داده‌ها. تحقیق در عملیات در کاربردهای آن، ۸(۴)، ۲۹-۳۹.
- [2] Sadjadi, S. J., Omrani, H., (2008). Data envelopment analysis with uncertain data: An application for Iranian electricity distribution companies. Energy Policy, 36, 4247-4254.
- [4] Azadeh, A., Ghaderi, S. F., Omrani, H., Eivazy, H., (2009). An integrated DEA-COLS-SFA algorithm for optimization and policy making of electricity distribution units. Energy Policy 37, 2605-2618.
- [5] Wu, D., Yang, Z., Liang, L., (2006). Using DEA-neural network approach to evaluate branch efficiency of a large Canadian bank. Expert systems with applications, 31, 108-115.
- [6] Aslani, G., MomeniMasuleh, S. H., Malek, A., Ghorbani, F., (2009). Bank efficiency evaluation using a neural network-DEA method. Iranian Journal of Mathematical Sciences and Informatics, 4 (2), 33-48.

- [7] Athanassopoulos, A., Curram, S., (1996). A Comparison of Data Envelopment Analysis and Artificial Neural Networks as Tools for Assessing the Efficiency of Decision Making Units. *Journal of the Operational Research Society*, 47, 1000-1016.
- [8] Costa, A., Markellos, P., (1997). Evaluating public transport efficiency with neural network models. *Transportation Research*, 5(5), 301-31.
- [9] Pendharkar, P., Rodger, J., (2003). Technical efficiency-based selection of learning cases to improve forecasting accuracy of neural networks under monotonicity assumption. *Decision Support Systems*, 36, 117-136.
- [10] Santian, D., Delgado, F., Valino, A., (2004). The measurement of technical efficiency: a neural network approach. *Applied Economics*, 36, 627-635.
- [11] Wu, D., (2009). Supplier selection, A hybrid model using DEA, decision tree and neural network. *Expert systems with applications*, 36, 9105-9112.
- [12] Mostafa, M. M., (2009). Modeling the efficiency of top Arab banks: A DEA-neural network approach. *Expert systems with applications*, 36, 309-320.
- [13] Pérez-Reyes, R., Tovar, B., (2009). Measuring Efficiency and Productivity Change (PTF) in the Peruvian Electricity Distribution Companies after Reforms. *Energy Policy*, 37, 2249-2261.
- [14] Emami Meibodi, A., (1998). Efficiency considerations in the Electricity Supply Industry: the case of Iran. Department of Economics, University of Surrey, Working Paper, 1-47
- [15] Chen, T. Y., (2002). An assessment of technical efficiency and cross-efficiency in Taiwan's electricity distribution sector. *European Journal of Operational Research*, 137, 421-433.
- [16] Pacudan, R., De Guzman, E., (2002). Impact of energy efficiency policy to productive efficiency of electricity distribution industry in the Philippines. *Energy Economics*, 24, 41-54.
- [17] Hattori, T., Tooraj, J., Pollit, M., (2003). A Comparison of UK and Japanese Electricity Distribution Performance 1985-1998: Lessons for Incentive Regulation. Cambridge and Massachusetts Institute of Technology, CMI Working Paper, 3.
- [18] Ramos Real, F. J., Tovar, B., Looty, M., De Almeida, E. F., Pinto Jr, H. Q., (2009). The evolution and main determinants of productivity in Brazilian electricity distribution 1998-2005: An empirical analysis. *Energy Economics*, 31, 298-305.
- [19] Cullmann, A., Hirschhausen, C., (2008). Efficiency analysis of East European electricity distribution in transition: legacy of the past?. *Springer J Prod Anal*, 29, 155-167.
- [20] Banker, R. D., Charnes, A., Cooper, W. W., (1984). Some Models For Estimating Technical and Scale Inefficiencies in DEA, *Management Science*, 30 (9), 1078-1092.
- [21] Charnes, A., Cooper, W. W., Rhodes, E., (1978). Measuring the efficiency of DMUs. *European Journal of Operational Research* 2, 429-444.
- [22] Charnes, A., Cooper, W. W., Lewin, A. Y., Seiford, L. M., (1994). *Data Envelopment Analysis: Theory, Methodology and Applications*, Boston, MA: Kluwer Academic Publishers.
- [23] Lee, C. C., Ou-Yang, C., (2009). A Neural Networks Approach for Forecasting the Supplier's Bid Prices in Supplier Selection Negotiation Process. *Expert Systems with Applications*, 36 (2), 2961-2970.
- [24] Razi, M. A., Athappilly, K., (2005). A comparative predictive analysis of neural networks (NNs), nonlinear regression and classification and regression tree (CART) models. *Expert Systems with Applications*, 29, 65-74.
- [32] Jamasb, T., Pollitt, M., (2003). International benchmarking and regulation: an application to European electricity distribution utilities. *Energy Policy*, 31, 121-130.
- [33] Ajalli, M., Miandari, K., SafaviMirmahalleh, S. R., MohammadiRamzani, M., (2012). Analysis of the Technical Efficiency of the Provincial Gas Companies in Iran Making use of the Synthetic Model of Performance Predictor Neural Networks, and Data Envelopment Analysis (Neuro-DEA). *American Journal of Scientific Research*, 48, 52-67.
- [35] Azadeh, A., Saberi, M., TavakkoliMoghadam, R., Javanmardi, L., (2011). An integrated Data Envelopment Analysis-Artificial Neural Network-Rough Set Algorithm for assessment of personnel efficiency. *Expert Systems with Applications*, 38, 1364-1373.