

ارزیابی کارایی شرکت‌های برق منطقه‌ای ایران با استفاده از تحلیل پوششی داده‌ها و شبکه عصبی

محسن شفیعی نیک‌آبادی^{*}، کامبیز شاهرودی^{**}، اکرم اویسی عمران^{***}، محمدرضا خسروی^{****}

تاریخ دریافت: ۹۵/۸/۱ - تاریخ پذیرش: ۹۶/۱۲/۸

چکیده

انتخاب متغیرهای ورودی و خروجی در تعیین نمرات کارایی تحلیل پوششی داده‌ها از اهمیت فراوانی برخوردار است. در این پژوهش با استفاده از شبکه عصبی مصنوعی به تعیین ورودی‌ها و خروجی‌های شرکت‌های برق منطقه‌ای پرداخته شده است. کاربرد شبکه عصبی در انتخاب ورودی‌ها و خروجی‌های شرکت‌های برق منطقه‌ای امری است که در ادبیات موضوع سابقه نداشته و مزیت اصلی روش پیشنهادی محسوب می‌شود. به منظور آموزش شبکه عصبی دو لایه MLP، از روش آموزش پس از انتشار خطای ارتجاعی استفاده گردید؛ پس از آموزش شبکه عصبی، عملکرد شبکه عصبی با استفاده از الگوهای تست، مورد بررسی قرار گرفت. مقدار RMSE مربوط به ۱۵ الگوی تست برابر ۰/۰۲۶۹ به دست آمد که نشان‌دهنده دقت بالای شبکه آموزش داده شده است. تحلیل حساسیت پارامترهای مورد بررسی که همان ورودی‌ها و خروجی‌های تحلیل پوششی داده‌ها هستند، با افزایش ده درصدی پارامترها نسبت به حالت قبل از افزایش انجام شده و میانگین خطای نسبی خروجی برای پارامترهای شبکه عصبی محاسبه شده است. بر اساس میزان میانگین خطای نسبی خروجی، ورودی‌ها و خروجی‌های تحقیق مشخص گردید. مقایسه نمرات کارایی شرکت‌های برق منطقه‌ای قبل و بعد از کاهش تعداد متغیرها، تعداد شرکت‌های کارا در طی شش دوره زمانی فوق از ۶۲/۴ درصد به ۲۶/۴ درصد کاهش یافته است.

واژگای کلیدی: انتخاب ورودی و خروجی، تحلیل پوششی داده‌ها، ارزیابی عملکرد، شبکه عصبی، تحلیل پنجره، شرکت‌های برق منطقه‌ای.

^{*} استادیار گروه مدیریت، دانشکده اقتصاد و مدیریت، دانشگاه سمنان، (نویسنده مسئول).

shafiei@profs.semnan.ac.ir

^{**} دانشیار دانشکده مدیریت و حسابداری دانشگاه آزاد اسلامی واحد رشت.

^{***} دانشجوی دکتری مدیریت صنعتی با گرایش تحقیق در عملیات دانشکده اقتصاد و مدیریت دانشگاه سمنان.

^{****} دانشجوی دکتری مدیریت بازرگانی (بازاریابی) دانشکده مدیریت و حسابداری دانشگاه آزاد اسلامی واحد رشت

مقدمه

تحلیل پوششی داده‌ها^۱ رویکردی ناپارامتریک است که با استفاده از ورودی‌ها و خروجی‌های چندگانه، نمرات کارایی واحدهای تصمیم‌گیرنده^۲ را ارزیابی می‌کند. از آنجایی که انتخاب متغیرهای ورودی و خروجی سیستم، در ارزیابی کارایی یک واحد از اهمیت بالایی برخوردار است و در عمل تعداد زیادی از متغیرها را می‌توان به عنوان عوامل مؤثر بر کارایی در نظر گرفت؛ بنابراین، هر متغیر بایستی به عنوان ورودی یا خروجی واحد تعریف شود. صرف نظر از تشخیص ماهیت یک متغیر از حیث ورودی یا خروجی، تعداد متغیرهای مؤثر بر عملکرد یک سیستم معمولاً بسیار زیاد هستند. در مدل تحلیل پوششی داده‌ها با هر منبع به کار گرفته شده برای یک واحد تصمیم‌گیرنده باید به عنوان یک متغیر ورودی رفتار شود. متغیرهای خروجی هم در نتیجه فعالیت بنگاه به منظور تبدیل ورودی‌ها به خروجی‌ها به وجود می‌آیند. به علاوه در برخی مواقع متغیرهای محیطی هم که بر فعالیت واحد تأثیر گذارند، نیز لازم است که در فهرست متغیرها وارد شوند (کلیمبرگ و پادی کامب، ۱۹۹۵).

تعداد زیاد متغیرهای ورودی و خروجی نیازمند ابعاد بیشتری از فضای حل مسأله می‌باشد (جنکینس و اندرسون، ۲۰۰۳). از طرفی تعداد زیاد متغیرها در تحلیل، به کاهش تفاوت بین نمرات کارایی واحدها منجر شده که نتیجتاً تعداد بیشتری از واحدها کارا به نظر خواهند رسید. در واقع تعداد بیشتر متغیرها در تحلیل پوششی داده‌ها نه تنها منجر به افزایش نمرات کارایی شده بلکه تعداد واحدهای کارا را نیز افزایش داده و کاهش قدرت تشخیص مدل را در پی دارد (گولانی و رول، ۱۹۸۹).

به منظور شناسایی مرتبط‌ترین متغیرها در مدل‌های تحلیل پوششی داده‌ها، تاکنون رویکردهای متعددی توسعه یافته‌اند. یکی از این مهم‌ترین این رویکردها شامل غربالگری فهرست متغیرها بر اساس نظر متخصصان است که از بین آن‌ها می‌توان به روش دلفی یا روش تحلیل سلسله‌مراتبی اشاره کرد (بوسوفاین، ۱۹۹۱).

1- Data Envelopment Analysis (DEA)

2- Decision Making Units (DMUS)

رویکرد دیگری که به منظور کاهش متغیرها به کار گرفته می‌شود، روش تحلیل رگرسیون و همبستگی بین متغیرها می‌باشد (سالی‌ناس و اسمیت، ۱۹۹۶). در مدل‌سازی به وسیله تحلیل پوششی داده‌ها مشخص شد زمانی که یک متغیر در تحلیل همبستگی متغیری زاید محسوب شود، لزوماً در مدل تحلیل پوششی داده‌ها نیز محدودیت زاید نمی‌باشد. به این معنی که وجود همبستگی بالا بین متغیرها به این معنا نیست که لزوماً این متغیر در تحلیل‌های بعدی تحلیل پوششی داده‌ها بدون تأثیر خواهد بود. بنابراین کاربرد تحلیل همبستگی به منظور کاهش متغیرها در مدل تحلیل پوششی داده‌ها غیر منطقی خواهد بود (نوما‌ماکر، ۱۹۸۵).

در تقابل با این روش‌ها، در روش دیگری به متغیرهای مدل قبل از استفاده در مدل تحلیل پوششی داده‌ها نگریده و تلاش می‌شود که اثر این متغیرها بر روی تغییر نمرات کارایی حاصل از حذف یا کاربرد آن‌ها ارزیابی شود. در این راستا، بنکر آزمون آماری را به منظور ارزیابی اثر مدیریتی بر نمرات کارایی متغیرهایی که به مدل اضافه و یا از مدل حذف می‌شوند، توسعه داد (بنکر، ۱۹۹۳، بنکر ۱۹۹۶).

با توجه به مطالعات صورت گرفته و عدم تمرکز مطالعات جدید بر روی استفاده از یک روش علمی در انتخاب متغیرهای ورودی و خروجی در تحلیل پوششی داده‌ها، در این پژوهش با استفاده از قدرت پیش‌بینی بالای شبکه عصبی، ابتدا متغیرهای اصلی تأثیرگذار بر تغییرات کارایی شرکت‌های برق منطقه‌ای ایران شناسایی شده و سپس نمرات کارایی شرکت‌ها با استفاده از تحلیل پنجره محاسبه شده و تغییرات کارایی، قبل و بعد از کاهش متغیرها مشخص شده است.

پیشینه پژوهش

شبکه عصبی همانند یک جعبه سیاه عمل کرده و به دنبال شناسایی روابط ناشناخته در بین مجموعه داده‌ها است. این روش داده کاوی برای زمانی مناسب است که فرمول ریاضی خاصی جهت شناسایی روابط متغیرهای ورودی و خروجی وجود نداشته و پیش‌بینی نیز یکی از

اهداف اصلی مطالعه باشد. در زمینه استفاده از شبکه عصبی مصنوعی ۱ همراه با تحلیل پوششی داده‌ها مطالعات متعددی صورت گرفته است.

اولین مطالعه‌ای که به مقایسه تحلیل پوششی داده‌ها و شبکه عصبی به عنوان دو روش ناپارامتریک ارزیابی عملکرد پرداخته، توسط آثناسوپولوس و کورام انجام شده است. در این مطالعه از تکنیک شبیه‌سازی شده تولید با دو ورودی و یک خروجی با هدف ارزیابی دو روش تحلیل پوششی داده‌ها و شبکه عصبی مصنوعی به کار گرفته شد. نتایج این مطالعه حاکی از آن است که با وجود تفاوت‌های بین دو روش، هر دو روش دامنه مفیدی از اطلاعات را با توجه به ارزیابی عملکرد شعب بانک ارائه می‌کنند (آثناسوپولوس و کورام، ۱۹۹۶). کوستا به ارزیابی عملکرد خدمات حمل و نقل عمومی بر پایه مفهوم کارایی با استفاده از شبکه عصبی پرسپترون چند لایه ۲ همراه با تحلیل پوششی داده‌ها و حداقل مربعات تصحیح شده ۳ پرداخت. در این مطالعه مشخص شد که رویکرد شبکه‌های عصبی پرسپترون چند لایه نسبت به روش‌های سنتی رویکردی ناپارامتریک و احتمالی و انعطاف‌پذیر است (کوستا، ۱۹۹۷).

پندهارکر و روجر شبکه عصبی مصنوعی برای توابع پیش‌بینی یکنواخت یادگیری به کار رود، به منظور دستیابی به داده‌های غربال شده مفید بوده و نمونه‌های غربال شده نسبتاً راضی کننده‌ای را فراهم می‌کند. در این مطالعه با استفاده از تحلیل پوششی داده‌ها مجموعه داده‌های یادگیری به دو بخش کارا و ناکارا تقسیم گردید. سپس با استفاده از شبکه عصبی مصنوعی مشخص شد که پیش‌بینی عملکرد در گروه داده‌های کارا از ناکارا بیشتر بوده است (پندهارکر و روجر، ۲۰۰۳).

مینگ و همکاران مدلی برای پیش‌بینی مدل پیش‌فرض‌های وام‌گیرندگان را از طریق ساخت تحلیل تجربی و مطالعه مشتریان نامطمئن در مؤسسات مالی معین تایوان طراحی کرده و متغیرهای جمعیت شناختی و نگرش پول وام‌گیرندگان را به عنوان اطلاعات تشخیصی

1- Artificial Neural Network (ANN)

2- Multi-Layer Perceptron Neural Networks (MLP)

3- Corrected Least Squares (COLS)

واقعی در نظر گرفته‌اند. آن‌ها نشان دادند که قدرت پیش‌بینی تحلیل پوششی داده‌های تحلیل تشخیصی و شبکه عصبی از رگرسیون لجستیک و آنالیز تشخیصی بیشتر است (مینگ و همکاران، ۲۰۰۹).

وو مدل ترکیبی شامل تحلیل پوششی داده‌ها، درخت تصمیم و شبکه عصبی مصنوعی را جهت ارزیابی تأمین‌کنندگان به کار گرفته است. ابتدا تأمین‌کنندگان را به دو دسته کارا و ناکارا تقسیم و سپس با استفاده از داده‌ها درخت تصمیم و شبکه عصبی مصنوعی را آموزش داده و نهایتاً درخت تصمیم آموزش دیده را برای تأمین‌کنندگان جدید به کار برده است (وو، ۲۰۰۹).

امروزنژاد و شالی نیز در مطالعه ترکیبی تحلیل پوششی داده‌ها و شبکه عصبی انتشار به عقب را جهت حل مشکل مجموعه داده‌های بزرگ و ورودی‌ها و خروجی‌های زیاد به کار بستند. شبکه عصبی مصنوعی مجموعه داده‌ها را در پنج گروه بزرگ ارزیابی و نتایج با تحلیل پوششی داده‌های سنتی مقایسه شده است (امروزنژاد و شالی، ۲۰۰۹).

آزاده و همکاران تحلیل پوششی داده‌ها و شبکه عصبی مصنوعی و تئوری مجموعه راف را با هدف ارزیابی اثرات کارایی نگرش کارکنان در کارایی کل به کار گرفتند. تحلیل پوششی داده‌ها دارای دو نقش اصلی است که ابتدا واحدهای کارا و ناکارا را تعیین و ورودی شبکه عصبی را مهیا کرده و نهایتاً بهترین کاهش (حداقل زیرمجموعه نگرش‌ها) را از طریق شبکه عصبی را انتخاب می‌کند. شبکه عصبی نیز برای تعیین حداقل مجموعه نگرش‌های انجام شده توسط مجموعه تئوری راف و پیش‌بینی کارایی کل استفاده شده است (آزاده و همکاران، ۲۰۱۱).

الرتاجو و همکاران ذخیره انرژی صنعتی آفریقای جنوبی را در فاصله سال‌های ۱۹۷۱ تا ۲۰۰۸ را با ترکیب سه رویکرد تحلیل شاخص تجزیه ۱، تحلیل پوششی داده‌ها (تحلیل پوششی داده‌ها) و شبکه عصبی مصنوعی (شبکه عصبی مصنوعی) بررسی کردند. در این مطالعه بر روی سه عامل مؤثر بر تغییرات الگوی مصرف انرژی، فعالیت، ساختار و شدت اثرات انجام

شده است. با استفاده از تحلیل شاخص تجزیه سهم نسبی سه عامل را در ۱۱ بخش صنعتی ارزیابی نموده است. سه عامل به عنوان ورودی شبکه عصبی و مصرف انرژی در طی زمان به عنوان خروجی شبکه عصبی در نظر گرفته شد. با تأیید اعتبار نتایج پیش‌بینی شبکه عصبی توسط رگرسیون، با استفاده مدل‌های ابرکارایی، نمرات کارایی و تحلیل حساسیت واحدها انجام شده و پیشنهاداتی برای ۱۱ بخش صنعتی در آفریقای جنوبی ارائه گردید (الرتاجو و همکاران، ۲۰۱۳).

وون و لی در مطالعه‌ای با استفاده از شبکه عصبی انتشار به عقب ۱ و تحلیل پوششی داده‌ها مدلی یکپارچه را جهت ارزیابی کارایی فرایند دو مرحله‌ای عملیات جذب سپرده و کسب سود در بانک‌های تجاری آمریکا طراحی نمودند. در این مدل از معیارهای پیش‌بینی و اندازه به صورت همزمان و با هدف پیش‌بینی سود افزایشی مطابق با سطح عملکرد هر واحد تصمیم‌گیرنده در یک فرایند دو مرحله‌ای است (لی و وون، ۲۰۱۵).

یانگ و همکاران مدل تحلیل پوششی داده‌های مبتنی بر متغیرهای کمکی را برای تحلیل حساسیت نمرات کارایی واحدهای تصمیم‌گیرنده و تعیین ابعاد بهینه واحدهای ناکارا به کار بردند. سپس واحدهای بهبودیافته همراه با واحدهای کارا وارد فرایند شبکه عصبی مصنوعی شده است. نتایج بهینه و ارزش‌های حاصل از مدل پیش‌بینی برای کاهش مصرف انرژی و راهنمای سیستم تولید اتیلن و بهبود کارایی انرژی استفاده شده است (یانگ و همکاران، ۲۰۱۶).

شعبانپور و همکاران با استفاده از شبکه عصبی مصنوعی و تحلیل پوششی داده‌ها رویکرد برنامه‌ریزی آینده‌نگری را به جای ارزیابی و رتبه‌بندی واحدهای تصمیم‌گیرنده در تحلیل پوششی داده‌ها ارائه نموده‌اند. در این مطالعه برای اولین بار شبکه عصبی مصنوعی و تحلیل پوششی داده‌های پویا برای پیش‌بینی نمرات کارایی واحدهای تصمیم‌گیرنده در آینده به کار برده است. به این ترتیب که میزان ورودی‌ها و خروجی‌های سیستم در آینده پیش‌بینی و سپس در تحلیل پوششی داده‌ها پویا به کار رفته است (شعبانپور و همکاران، ۲۰۱۶).

میسوناس و همکاران مطالعه ترکیبی از تحلیل پوششی داده‌ها و شبکه عصبی مصنوعی را انجام دادند. آن‌ها ابتدا نمرات کارایی واحدهای تصمیم‌گیرنده را با استفاده از تحلیل پوششی داده‌ها مشخص نمودند. سپس با استفاده از شبکه عصبی مراحل آموزش و پیش‌بینی شبکه عصبی مصنوعی را تا دستیابی به دقت لازم در پیش‌بینی انجام دادند (میسوناس و همکاران، ۲۰۱۶).

ولتانز و پرادلوس (۲۰۱۷) با روش ترکیبی تحلیل پنجره تحلیل پوششی داده‌ها و شبکه عصبی مصنوعی به بررسی اثرات زیست محیطی سیاست‌های بخش کشاورزی اتحادیه اروپا پرداختند. در این مطالعه با کاربرد تحلیل پنجره، ارزیابی کارایی گازهای گلخانه‌ای و شناسایی تغییرات کارایی کشورهای عضو اتحادیه اروپا تحت تأثیر سیاست کشاورزی رایج انجام شد. هدف این مطالعه شناسایی اثرات مثبت و منفی سیاست‌ها بر کارایی کشورهای عضو است. نهایتاً از شبکه عصبی مصنوعی جهت تعیین نمرات کارایی کشورهای عضو اتحادیه اروپا استفاده شده است.

کاربرد شبکه عصبی در پیش‌بینی عملکرد واحدهای تصمیم‌گیرنده همراه با تحلیل پوششی داده‌ها در ادبیات موضوع فراوان به چشم می‌خورد (وون، ۲، ۲۰۱۷)، (وون و همکاران، ۲۰۱۷)، (شفیعی و عربلو، ۳، ۲۰۱۷)، (بنیادی نائینی و همکاران، ۱۳۹۵). اما در زمینه استفاده از قدرت پیش‌بینی شبکه عصبی در تعیین رفتار و میزان تغییرات متغیرهای ورودی و خروجی واحدهای تصمیم‌گیرنده مطالعه خاصی صورت نگرفته است. بنابراین نوآوری اصلی مطالعه فعلی انتخاب متغیرهای ورودی و خروجی با استفاده از قدرت پیش‌بینی شبکه عصبی مصنوعی است.

روش‌شناسی پژوهش

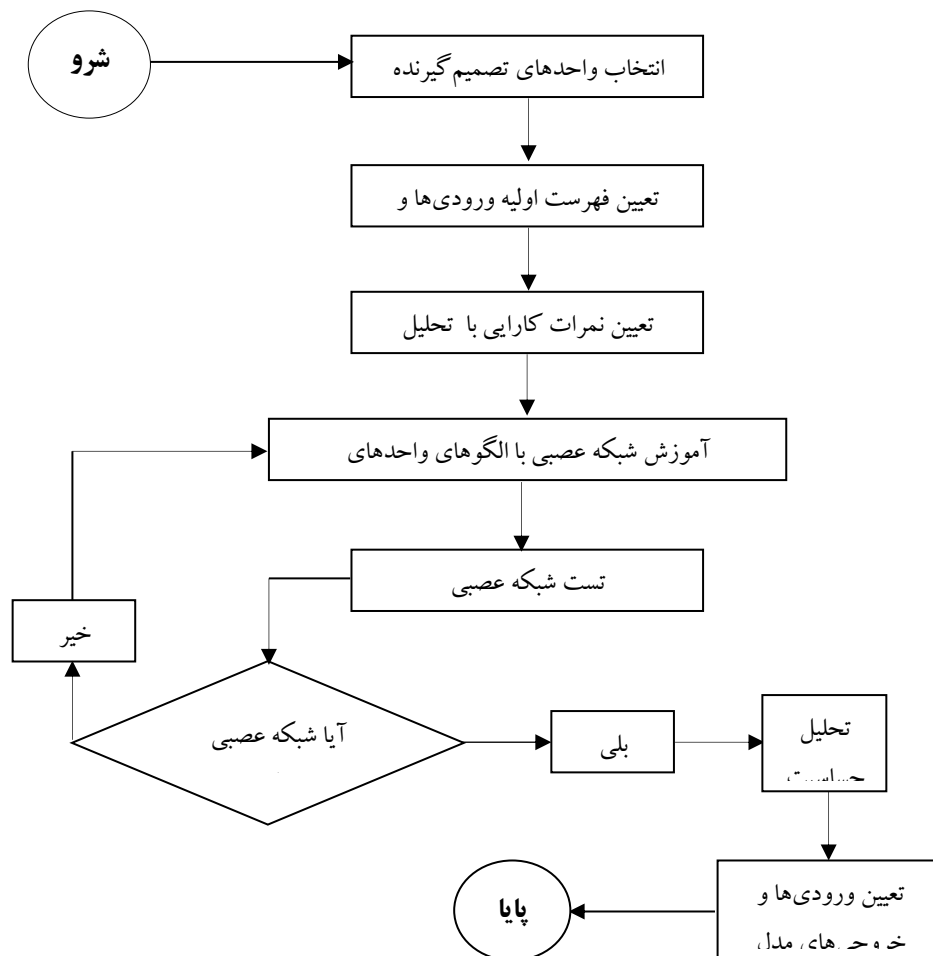
این پژوهش از حیث هدف از نوع پژوهش‌های کاربردی- توسعه‌ای بوده و در واقع به ارائه یک روش برای حل مسئله در دنیای واقعی می‌پردازد و از لحاظ متغیر، تحقیقی کمی است.

1- Vlontzos and Pardalos

2- Kwon

3- Saghafi and Arabloo

مراحل انجام پژوهش را می‌توان به صورت گام‌های ذیل خلاصه نمود. شکل ۱ گام‌های انجام این تحقیق را به صورت یک فلوجارت نشان می‌دهد.



شکل ۱- مراحل انجام پژوهش

گام اول: تعیین واحدهای تصمیم‌گیرنده

در این تحقیق به بررسی کارایی ۱۶ شرکت برق منطقه‌ای ایران پرداخته می‌شود. داده‌های مورد استفاده در این پژوهش مربوط به عملکرد سال‌های ۱۳۸۹ تا ۱۳۹۴ شرکت‌های برق منطقه‌ای ایران است. اطلاعات مزبور از سالنامه آماری صنعت برق ایران استخراج شده‌اند. در واقع، شرکت‌های برق منطقه‌ای (شرکت‌های برق منطقه‌ای آذربایجان، اصفهان، باختر، تهران، خراسان، خوزستان، زنجان، سمنان، سیستان و بلوچستان، غرب، فارس، کرمان، گیلان، مازندران، هرمزگان، یزد) به‌عنوان واحدهای تصمیم‌گیرنده انتخاب گردید.

گام دوم: تعیین نمرات کارایی اولیه

ابتدا فهرستی از متغیرهای موجود و در دسترس تأثیرگذار بر نمرات کارایی شرکت‌های برق منطقه‌ای ایران تعیین می‌شود. پس از آن نمرات کارایی شرکت‌های مزبور در بازه زمانی (۱۳۸۹-۱۳۹۴) با استفاده از تحلیل پنجره تحلیل پوششی داده‌ها محاسبه خواهد شد (رمضانیان و همکاران، ۱۳۹۱).

n تا واحد تصمیم‌گیرنده $DMU_j : (j=1,2,\dots,n)$ در دوره‌های زمانی $t : (t=1,2,\dots,T)$ مفروض است که با مصرف $i : (i=1,2,\dots,m)$ ورودی $r : (r=1,2,\dots,s)$ خروجی را تولید می‌کنند. با در نظر گرفتن تعداد واحدهای تصمیم‌گیرنده و تعداد دوره‌های زمانی موجود در تحلیل، مجموعه امکان تولیدی شامل $(n \times T)$ واحد تصمیم‌گیرنده خواهیم داشت. مشاهده n ام در دوره زمانی t ام، یعنی DMU_t^j دارای یک بردار m بعدی از ورودی‌ها $X_t^j = (x_{1t}^j, x_{2t}^j, \dots, x_{mt}^j)$ و یک بردار s بعدی از خروجی‌ها $Y_t^j = (y_{1t}^j, y_{2t}^j, \dots, y_{st}^j)$ است. این ویژگی تحلیل پنجره، هنگام مطالعه واحدهای تصمیم‌گیرنده با تعداد ناکافی منجر به افزایش تعداد واحدهای تصمیم‌گیرنده می‌شود (Asmild et al., 2004). با استفاده از مجموعه ورودی‌ها و خروجی‌ها در T دوره زمانی

می توان مدل تحلیل پنجره‌ای ورودی گرا را تحت فرض بازده به مقیاس متغیر را به صورت مدل (۱) نوشت (Banker et al., 1984).

(۱)

$$\begin{aligned} & \text{Min} \theta \\ & \text{s.t.} : \theta'X_t - \lambda'X_{k_w} \geq 0 \\ & \quad \lambda'Y_{k_w} - Y_t \geq 0 \\ & \quad \sum_{j=1}^n \lambda_j = 1 \\ & \quad \lambda_j \geq 0, (j=1, 2, \dots, n \times w) \end{aligned}$$

گام سوم: تحلیل حساسیت نمرات کارایی با کاربرد شبکه عصبی مصنوعی

مدل‌های مرسوم رگرسیون خطی می‌توانند با روش حداقل مربعات، اطلاعات را جمع‌آوری کرده و آن‌ها را به صورت ضریب رگرسیون ذخیره کنند. از این منظر این روش یک شبکه عصبی است. در واقع، می‌توان این طور استدلال کرد که رگرسیون خطی یک حالت خاص از شبکه‌های عصبی مشخص است. با این تفاوت که، رگرسیون خطی دارای یک ساختار مدل نامعطف و مجموعه فرضیاتی است که قبل از یادگیری اطلاعات اعمال می‌شوند. تعریف بالا نیاز به ساختار مدل و فرضیات را حداقل می‌کند. بنابراین یک شبکه عصبی می‌تواند بازه وسیعی از مدل‌های آماری را بدون نیاز به فرض رابطه مشخص بین متغیرهای وابسته و مستقل، تخمین بزند. در عوض، نوع ارتباط متغیرها با متغیر عملکرد واحدها حین فرآیند یادگیری مشخص می‌شود. در صورتی که رابطه خطی بین متغیرهای مستقل و وابسته مناسب باشد، نتایج شبکه‌های عصبی باید به تخمین مدل رگرسیون خطی نزدیک باشند. اگر رابطه غیرخطی مناسب‌تر باشند، شبکه عصبی به صورت خودکار ساختار صحیح مدل را تخمین خواهد زد (وون و لی، ۲۰۱۵).

ابتدا با کاربرد تعداد مناسبی از الگوهای آموزشی شبکه عصبی پرسپترون چندلایه را به روش آموزش پس از انتشار خطای ارتجاعی، آموزش داده می‌شود. پس از آن شبکه عصبی

آموزش داده شده جهت تحلیل حساسیت پارامترهای شبکه عصبی که همان ورودی‌ها و خروجی‌های تحلیل پوششی داده‌ها هستند، استفاده می‌شود.

پس از آموزش شبکه عصبی، عملکرد شبکه عصبی با استفاده از الگوهای تست، مورد بررسی قرار می‌گیرد. هدف این بررسی تعیین مقداری از RMSE است که بیانگر دقت بالای شبکه عصبی آموزش داده شده باشد.

نهایتاً با استفاده از شبکه حاصل به تحلیل حساسیت پارامترهای شبکه عصبی پرداخته می‌شود. تحلیل حساسیت بدین صورت انجام می‌گیرد که پارامترهای شبکه به میزان ده درصد افزایش یافته و تغییرات حاصل در نمرات کارایی نسبت به قبل از افزایش سنجیده می‌شوند. این اندازه‌ها مقدار میانگین خطای نسبی خروجی شبکه عصبی را نشان می‌دهد. پارامترهایی که دارای میانگین خطای نسبی خروجی بزرگتری هستند، به‌عنوان پارامترهای تأثیرگذار بر روی نمرات کارایی انتخاب می‌شوند. بزرگ بودن مقدار میانگین خطای نسبی برای یک پارامتر ورودی در واقع نشان دهنده آن است که تغییر در پارامتر منجر به تغییر بزرگی در خروجی سیستم می‌شود (شریفیان و شریفیان^۱، ۲۰۱۵).

گام چهارم: محاسبه نمرات کارایی با ورودی‌ها و خروجی‌های انتخاب شده با انتخاب ورودی‌ها و خروجی‌های تأثیرگذار بر نمرات کارایی، کارایی واحدهای تصمیم‌گیرنده با استفاده از تحلیل پنجره‌ای در بازه زمانی (۱۳۸۹-۱۳۹۲) محاسبه شده و با نمرات کارایی قبل مقایسه می‌شود.

یافته‌های پژوهش

با استفاده از متغیرهای ورودی و خروجی مطالعات مشابه و مصاحبه با کارشناسان و خبرگان صنعت برق، مجموعه‌ای از ۱۳ متغیر ورودی و خروجی، به‌عنوان مجموعه متغیرهای اولیه

¹ Sharifian and Sharifian

پژوهش انتخاب گردید که فهرست آن‌ها به همراه تعریف هر یک از متغیرهای مذکور در جدول شماره ۱ ارائه می‌شود:

جدول ۱- فهرست متغیرهای ورودی و خروجی اولیه

متغیرها	تعریف	
متغیرهای ورودی	مصارف داخلی نیروگاهها	مقدار انرژی الکتریکی که توسط تجهیزات کمکی و جنبی یک واحد، جهت راهبری آن چه در حالت کار و چه در حالت توقف لازم است و برحسب کیلووات ساعت و در طول یک دوره مشخص محاسبه می‌شود.
	سوخت مصرفی	میزان سوخت مصرفی نیروگاه
	طول خطوط انتقال (۲۳۰ و ۴۰۰ کیلوولت)	مجموع فاصله دکل‌های خط بین دو نقطه مبدأ خط و مقصد آن یا اولین پست بعد از پست مبدأ به کیلومتر است. به عبارت دیگر طول مسیر یک مدار یا خط الکتریکی (متر یا کیلومتر)، اعم از هوایی یا زیرزمینی عبارت است از طول تصویر واقعی آن.
	ظرفیت پست‌های انتقال (۴۰۰ و ۲۳۰ کیلوولت)	ظرفیت نامی یک ایستگاه برق براساس مجموع قدرت ظاهری ترانسفورماتورهای نصب شده در آن بر حسب مگاوات آمپر و یا براساس ظرفیت حرارتی شینه بر حسب کیلوآمپر می‌باشد.
	ظرفیت پست‌های فوق توزیع (۱۳۲ و ۶۳ کیلوولت)	تعداد نیروی انسانی شاغل در شرکت
	نیروی انسانی شرکت برق منطقه‌ای	قدرت نامی یک دستگاه تولیدی نیروی محرکه از طرف سازنده بر روی پلاک مشخصات آن برای شرایط معینی بر حسب اسب بخار یا مگاوات نوشته شده است.
	متغیرهای خروجی	قدرت نامی نیروگاهها
قدرت عملی نیروگاهها		حداکثر بار همزمان از مجموع بار حداکثر شبکه به هم پیوسته و بار مناطق مجزا به مگاوات، بطور همزمان به دست می‌آید.
حداکثر بار تولیدی در پیک همزمان		

تولید ناویژه نیروگاه‌ها	جمع انرژی تولیدی مولدهای برق یک نیروگاه که در طی یک دوره زمانی معین روی پایانه خروجی مولدها بر حسب کیلووات ساعت یا مگاوات ساعت اندازه گیری می‌شود.
تولید ویژه	عبارت است از تولید انرژی برق ناویژه منهای مصرف داخلی نیروگاه‌ها در یک دوره معین و برحسب کیلووات ساعت یا مگاوات ساعت محاسبه می‌شود.
راندمان	از طریق فرمول به دست می‌آید که همان نسبت خروجی به ورودی‌ها است.
انرژی تحویلی	مقدار انرژی که به شرکت‌های توزیع برق انتقال داده می‌شود.

در گام بعدی به منظور بررسی نمرات کارایی واحدهای تصمیم‌گیرنده و با توجه به تعداد کم واحدهای تصمیم‌گیرنده، نمرات کارایی واحدها با استفاده از روش تحلیل پنجره محاسبه گردید. روش تحلیل پنجره با امکان‌پذیر ساختن ترکیب مشاهدات در سری‌های زمانی و مقطعی، مشکل ناکافی بودن مشاهدات را در ارزیابی‌های زمانی برطرف می‌کند. این وضعیت باعث افزایش تعداد دوره‌های مورد بررسی در تحلیل می‌شود که در هنگام مطالعه نمونه‌هایی در اندازه کوچک مفید است (رمضانیان و همکاران، ۱۳۹۱).

تحلیل پنجره به‌طور ضمنی فرض می‌کند که تغییر جلدی در مرزهای کارایی دوره‌های موجود در عرض پنجره وجود ندارد. به عبارتی هنگام انتخاب عرض پنجره این فرض اساسی باید رعایت گردد. با رعایت این فرض اساسی نمرات کارایی در تحلیل پنجره، دربردارنده تغییرات بهره‌وری واحدها و تغییرات جزئی مرزهای کارا در بین دوره‌های موجود در تحلیل خواهد بود.

به منظور محاسبه کارایی واحدها از فرم ورودی گرای مدل BCC استفاده گردید. ابتدا نمرات کارایی واحدها در هر یک از دوره‌ها به‌طور مستقل با استفاده از نرم‌افزار تحلیل پوششی داده‌ها Solver- محاسبه شد. سپس واحدهای بهبودیافته در هر دوره به دست آمده و نهایتاً نمرات کارایی مجموعه واحدهای کارا و بهبودیافته در یک مجموعه مجدداً محاسبه

گردید. سپس با استفاده از نرم افزار SPSS، آزمون‌های فریدمن و ویل کاکسون در سطح معنی داری یک درصد انجام گردید و وضعیت مرزهای کارا در بین ۶ دوره زمانی موجود در تحلیل (۱۳۸۹-۱۳۹۴) بررسی شد که نتایج آن در جدول شماره ۲ آمده است (رمضانیان و همکاران، ۱۳۹۱).

جدول ۲- نتایج آزمون‌های آماری برای تعیین وضعیت مرزهای کارا

سال‌های موجود در تحلیل	نوع آزمون	P-Value	تصمیم نهایی
۱۳۸۹-۱۳۹۰	ویل کاکسون	۰/۰۰۲	پذیرش فرض صفر
۱۳۸۹-۱۳۹۰-۱۳۹۱	فریدمن	۰/۰۱۲	پذیرش فرض صفر
۱۳۸۹-۱۳۹۰-۱۳۹۱-۱۳۹۲	فریدمن	۰/۰۳۵	پذیرش فرض صفر
۱۳۸۹-۱۳۹۰-۱۳۹۱-۱۳۹۲-۱۳۹۳	فریدمن	۰/۰۲۳	پذیرش فرض صفر
۱۳۸۹-۱۳۹۰-۱۳۹۱-۱۳۹۲-۱۳۹۳-۱۳۹۴	فریدمن	۰/۰۰۰۱	پذیرش فرض صفر

بنابراین در سطح خطای ۵ درصد، انتقال مرز در بین دوره‌های مورد بررسی وجود ندارد. بنابراین تحلیل پنجره‌ای به عرض ۶ دوره زمانی در نظر گرفته شده و نمرات کارایی واحدها محاسبه گردید که نتایج آن در جدول شماره ۳ آمده است:

جدول ۳- نمرات کارایی واحدها با استفاده از تحلیل پنجره

نمره کارایی						DMUs
۱۳۹۴	۱۳۹۳	۱۳۹۲	۱۳۹۱	۱۳۹۰	۱۳۸۹	
۰/۹۹۱۶	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰	شرکت برق منطقه‌ای آذربایجان
۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۰/۹۸۱	شرکت برق منطقه‌ای اصفهان
۱/۰۰۰۰	۱/۰۰۰۰	۰/۹۰۱۴	۱/۰۰۰۰	۱/۰۰۰۰	۰/۹۸۴	شرکت برق منطقه‌ای باختر
۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۰/۹۲۱	۱/۰۰۰	شرکت برق منطقه‌ای تهران
۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰	شرکت برق منطقه‌ای خراسان
۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰	شرکت برق منطقه‌ای خوزستان
۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰	شرکت برق منطقه‌ای زنجان
۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰	شرکت برق منطقه‌ای سمنان
۱/۰۰۰۰	۱/۰۰۰۰	۰/۹۹۰۳	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰	شرکت برق منطقه‌ای سیستان
۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰	۱/۰۰۰۰	۰/۹۶۷۷	۰/۹۵۲۸	شرکت برق منطقه‌ای غرب
۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰	۰/۹۶۱۳	۰/۹۳۵۳	۱/۰۰۰۰	شرکت برق منطقه‌ای فارس
۱/۰۰۰۰	۱/۰۰۰۰	۰/۹۸۹۲	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	شرکت برق منطقه‌ای کرمان
۱/۰۰۰۰	۱/۰۰۰۰	۰/۹۶۸۸	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	شرکت برق منطقه‌ای گیلان
۰/۹۹۱۴	۰/۹۶۷۳	۰/۹۵۸۷	۰/۸۹۳۴	۰/۸۵۱۰	۱/۰۰۰۰	شرکت برق منطقه‌ای مازندران
۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۰/۹۸۴۴	۱/۰۰۰۰	شرکت برق منطقه‌ای هرمزگان
۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	شرکت برق منطقه‌ای یزد

در نهایت با استفاده از الگوهای آموزشی به دست آمده و با استفاده از تحلیل حساسیت به کمک شبکه عصبی، مهم‌ترین متغیرهای تأثیرگذار بر روی نمرات کارایی واحدها محاسبه

می‌شود. روش به کار رفته در این مقاله برای اولین بار در مرجع (شریفیان، ۲۰۱۵) بیان شده است و نتایج حاصله نشان دهنده کارایی و دقت روش بیان شده می‌باشد.

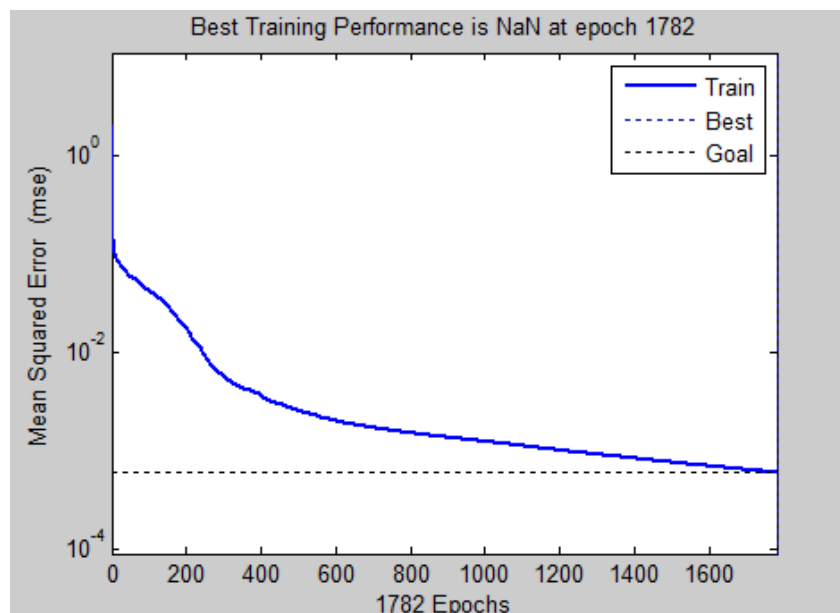
با توجه به مطالب ذکر شده در جدول ۱، ۱۴ پارامتر در محاسبه نمرات کارایی واحدها تاثیر گذر می‌باشند که به عنوان ورودی شبکه عصبی در نظر گرفته شده است. خروجی شبکه عصبی نیز نمرات کارایی واحدها می‌باشد. برای آموزش شبکه عصبی نیز از نمرات کارایی موجود در جدول ۳ استفاده شده است. از میان ۹۶ داده موجود، ۸۱ داده برای آموزش شبکه عصبی و ۱۵ داده برای تست شبکه استفاده شده است. به منظور تشریح دقیق پارامترهای تنظیم شده برای شبکه عصبی در جدول ۴ خلاصه شده است.

جدول ۴- پارامترهای تنظیم شده شبکه عصبی

مشخصات	توضیحات
نوع شبکه	شبکه عصبی MLP با دو لایه پنهان
تعداد لایه‌های پنهان	۲ لایه
تعداد نرون لایه ورودی	۱۳ نرون
تعداد نرون لایه خروجی	۱ نرون
تعداد نرون لایه پنهان	۱۵ نرون
تابع عملکرد نرون‌های لایه پنهان	تابع غیر خطی tansig
تابع عملکرد نرون‌های لایه خروجی	تابع خطی purelin
روش آموزش پس از انتشار خطای ارتجاعی	آموزش پس از انتشار خطای ارتجاعی trainrp
شرایط توقف آموزش شبکه	حداکثر تکرار در فاز آموزش برابر با ۳۰۰۰ تکرار یا رسیدن به مقدار میانگین مربع خطا (MSE) برابر با ۰/۰۰۰۶
مدت زمان آموزش شبکه	۹ ثانیه
تعداد تکرار در فاز آموزش	۱۷۸۲ تکرار

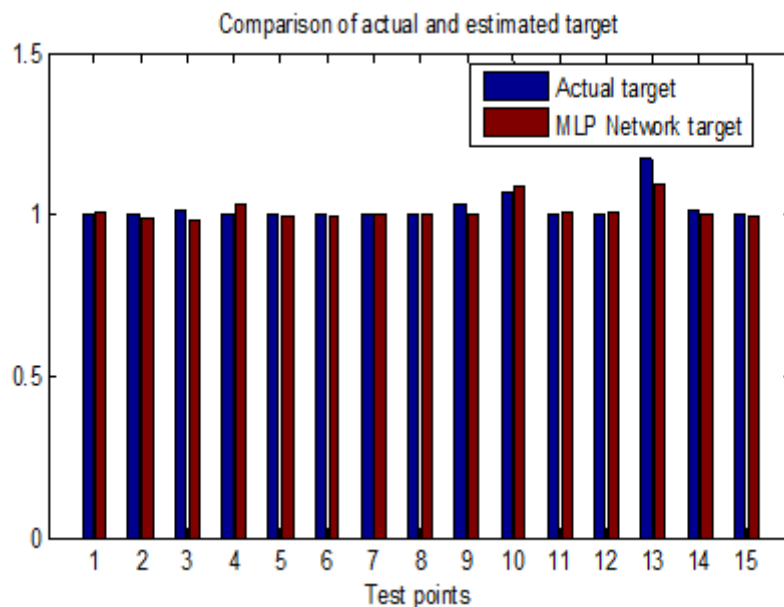
برای انجام تحلیل حساسیت ابتدا با استفاده از ۸۱ الگوی آموزشی یک شبکه MLP آموزش داده شد و سپس از این شبکه عصبی آموزش داده شده برای تحلیل حساسیت متغیرهای ورودی استفاده شد. شبکه عصبی به کار رفته یک شبکه MLP دو لایه است که دارای ۱۳

نرون در لایه ورودی و ۱۵ نرون در لایه پنهان و یک نرون در لایه خروجی است. تابع عملکرد نرون‌های لایه پنهان $tansig$ و برای نرون خروجی تابع عملکرد از نوع خطی در نظر گرفته شد و از روش آموزش پس از انتشار خطای ارتجاعی برای آموزش آن استفاده شده است. برای شبیه‌سازی شبکه عصبی از جعبه ابزار شبکه‌های عصبی نرم افزار Matlab استفاده شده است. این شبکه عصبی با در نظر گرفتن مقدار میانگین مربع خطا (MSE) برابر با $0/0006$ و پس از ۱۷۸۲ تکرار داده شد. منحنی یادگیری شبکه عصبی طرح شده در شکل ۲ نشان داده شده است.



شکل ۲- منحنی آموزش شبکه عصبی

پس از آموزش شبکه عصبی، عملکرد شبکه عصبی با استفاده از الگوهای تست، مورد بررسی قرار گرفت. مقدار RMSE مربوط به ۱۵ الگوی تست برابر با $0/0269$ به دست آمد که نشان‌دهنده دقت بالای شبکه آموزش داده شده است. علاوه بر این مقدار واقعی و مقدار تخمین زده شده نمرات کارایی واحدها توسط شبکه عصبی برای ۱۵ داده تست در شکل ۲ با یکدیگر مقایسه شده است.



شکل ۳- مقایسه مقدار واقعی و مقدار تخمین زده شده نمرات کارایی واحدها توسط شبکه عصبی

ابتدا برای هر یک از ۱۵ الگوی داده تست مقدار خروجی (نمرات کارایی واحدها) را با استفاده از شبکه عصبی تخمین زده شد و سپس برای هر یک از ۱۴ متغیر ورودی مربوط به ۱۵ الگوی تست، به صورت جداگانه مقدار هر یک از متغیر ورودی ده درصد افزایش داده شد و در مقدار سایر متغیرهای ورودی تغییری ایجاد نشد و دوباره با استفاده از شبکه عصبی آموزش دیده مقدار خروجی برای شرایط جدید محاسبه شد. این عمل برای هر یک از ۱۴ متغیر ورودی و برای ۱۵ الگوی تست تکرار شد. پس از انجام مراحل فوق، مقدار میانگین خطای نسبی خروجی شبکه عصبی قبل و بعد از تغییر هر کدام از ورودی‌ها به میزان ده درصد به دست آمد (شریفیان، ۲۰۱۵). میانگین خطای نسبی بر طبق رابطه (۱) تعریف می‌شود.

$$\Delta PF_i = \frac{1}{n} \sum_{p=1}^n \frac{|PF_i^{p'} - PF_i^p|}{|PF_i^p|} \quad (۴)$$

در رابطه فوق ΔPF_i میانگین خطای نسبی خروجی برای تغییر در متغیر ورودی ΔP است. همچنین PF_i^p مقدار خروجی برای حالتی که متغیر ورودی ΔP در الگوی آموزشی ΔP تغییری نکرده باشد و $PF_i^{p'}$ مقدار خروجی برای حالتی که متغیر ورودی ΔP در الگوی آموزشی ΔP به اندازه ده درصد مقدار اولیه افزایش پیدا کرده باشد، هستند (شریفیان، ۲۰۱۵). پس از انجام محاسبات مقدار میانگین خطای نسبی خروجی (ΔPF) به دست آمده که نتیجه حاصل در جدول ذکر شده است.

جدول ۵- مقدار میانگین خطای نسبی مربوط به نمرات کارایی واحدها

نتیجه نهایی	نوع متغیر	متغیر ورودی	میانگین خطای نسبی خروجی
✓	ورودی	مصرف داخلی پست	۰/۰۰۱۵۳
✓	خروجی	تولید ناویژه	۰/۰۰۰۹۴
✓	ورودی	ظرفیت پست‌های فوق توزیع	۰/۰۰۰۸۶
✓	ورودی	ظرفیت پست‌های انتقال	۰/۰۰۰۷۶
✓	خروجی	انرژی تحویلی	۰/۰۰۰۴۳
-	خروجی	قدرت نامی نیروگاه‌ها	۰/۰۰۰۴۲
-	خروجی	قدرت عملی نیروگاه	۰/۰۰۰۴۱
-	خروجی	راندمان	۰/۰۰۰۳۸
-	ورودی	طول خط فوق توزیع	۰/۰۰۰۳۴
-	ورودی	طول خط انتقال	۰/۰۰۰۲۷
-	ورودی	سوخت مصرفی	۰/۰۰۰۲۴
-	ورودی	نیروی انسانی	۰/۰۰۰۲۲
-	خروجی	تولید ویژه	۰/۰۰۰۲۰
-	خروجی	حداکثر بار همزمان	۰/۰۰۰۰۱۸

با توجه به نتایج حاصل می‌توان متغیرهای ورودی مصرف داخلی پست‌ها، ظرفیت پست‌های فوق توزیع ۴۰۰ و ۲۳۰ کیلو ولت، ظرفیت پست‌های انتقال ۶۳ و ۱۳۲ کیلو ولت و

تولید ناویژه و متغیر خروجی انرژی تحویلی انتخاب شده و نمرات کارایی واحدهای تصمیم گیرنده مجدداً محاسبه و در جدول ۵ آمده است.

جدول ۵- نمرات کارایی تحلیل پنجره‌ای با متغیرهای انتخاب شده


نمرات کارایی						واحدهای تصمیم گیرنده
۱۳۹۴	۱۳۹۳	۱۳۹۲	۱۳۹۱	۱۳۹۰	۱۳۸۹	
۰/۹۶۸۴	۰/۹۸۷۱	۰/۹۸۱۶	۰/۹۵۱۱	۰/۹۹۸۷	۰/۹۹۸۰	شرکت برق منطقه‌ای آذربایجان
۰/۸۸۵۷	۰/۹۱۱۹	۰/۸۵۹۰	۰/۹۰۷۷	۰/۸۶۴۵	۰/۷۵۲۳	شرکت برق منطقه‌ای اصفهان
۰/۷۰۵۱	۰/۷۲۶۷	۰/۷۲۲۴	۰/۷۲۰۶	۰/۷۰۶۷	۰/۷۴۵۲	شرکت برق منطقه‌ای باختر
۱/۰۰۰۰	۱/۰۰۰۰	۰/۹۸۵۰	۰/۹۵۰۲	۰/۹۲۳۷	۰/۹۹۱۰	شرکت برق منطقه‌ای تهران
۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۰/۹۸۲۵	شرکت برق منطقه‌ای خراسان
۱/۰۰۰۰	۰/۹۵۷۶	۰/۹۰۷۱	۰/۹۵۸۸	۰/۹۳۷۲	۱/۰۰۰۰	شرکت برق منطقه‌ای خوزستان
۰/۸۹۲۳	۰/۹۱۷۲	۰/۹۸۷۱	۱/۰۰۰۰	۱/۰۰۰۰	۰/۹۶۹۵	شرکت برق منطقه‌ای زنجان
۰/۹۷۳۳	۰/۹۸۳۲	۰/۹۹۸۲	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	شرکت برق منطقه‌ای سمنان
۱/۰۰۰۰	۰/۹۶۳۲	۰/۹۷۶۲	۱/۰۰۰۰	۱/۰۰۰۰	۰/۹۵۵۸	شرکت برق منطقه‌ای سیستان
۰/۷۰۴۹	۰/۷۲۵۸	۰/۷۰۲۸	۰/۶۹۳۱	۰/۶۸۳۰	۱/۰۰۰۰	شرکت برق منطقه‌ای غرب
۱/۰۰۰۰	۰/۸۷۴۶	۰/۸۵۸۷	۰/۸۲۶۳	۰/۸۲۱۱	۰/۸۲۳۶	شرکت برق منطقه‌ای فارس
۱/۰۰۰۰	۰/۹۹۱۹	۰/۹۸۸۱	۰/۹۷۴۵	۱/۰۰۰۰	۰/۹۶۵۲	شرکت برق منطقه‌ای کرمان
۰/۹۴۵۹	۰/۹۳۵۹	۰/۹۵۰۸	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	شرکت برق منطقه‌ای گیلان
۰/۸۹۰۵	۰/۸۵۲۱	۰/۸۶۶۷	۰/۸۱۵۹	۰/۷۶۷۵	۱/۰۰۰۰	شرکت برق منطقه‌ای مازندران
۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	۰/۸۲۱۵	۱/۰۰۰۰	شرکت برق منطقه‌ای هرمزگان
۰/۹۴۱۱	۰/۹۳۸۹	۰/۹۶۸۷	۱/۰۰۰۰	۱/۰۰۰۰	۱/۰۰۰۰	شرکت برق منطقه‌ای یزد

نتیجه‌گیری و پیشنهادها

انتخاب متغیرهای ورودی و خروجی در ارزیابی کارایی یک واحد از اهمیت بالایی برخوردار است. در عمل تعداد زیادی از متغیرها را می‌توان به عنوان ورودی و خروجی در نظر گرفت.


از طرفی تعداد زیاد متغیرها صرف نظر از ورودی یا خروجی بودن آن‌ها می‌تواند به کاهش قدرت تشخیص مدل و دشواری‌های محاسباتی منجر شود.

نقطه قوت این پژوهش استفاده از شبکه عصبی مصنوعی با هدف تعیین مهم‌ترین متغیرهای تأثیرگذار بر روی نمرات کارایی شرکت‌های برق منطقه‌ای است. نتایج حاصل از بکارگیری شبکه عصبی نشان می‌دهد که با توجه به جدول ۵ مهم‌ترین متغیرهای ورودی و خروجی تأثیرگذار بر روی نمرات کارایی واحدها شامل متغیرهای ورودی مصرف داخلی پست‌ها، ظرفیت پست‌های فوق توزیع ۴۰۰ و ۲۳۰ کیلو ولت، ظرفیت پست‌های انتقال ۶۳ و ۱۳۲ کیلو ولت و تولید ناویژه و متغیر خروجی انرژی تحویلی تعیین گردید. مصاحبه با کارشناسان صنعت برق حاکی از قابل اتکا بودن نتایج محاسبه شده است. در راستای مقایسه نمرات کارایی و تعداد واحدهای کارا قبل و بعد از انتخاب متغیرها دوره‌ها را میتوان به تفصیل مورد بررسی قرار داد. در سال ۱۳۹۴ با ۱۴ متغیر ورودی و خروجی در بین ۸۰ واحد تصمیم‌گیرنده دارای ۱۴ واحد کارا و دو واحد ناکارا بوده است. بعد از انتخاب متغیرهای تأثیرگذار بر روی نمرات کارایی تعداد واحدهای کارا به ۷ واحد کاهش یافته است. مقایسه نمرات کارایی در قالب نمودار شکل ۴ به خوبی قابل رؤیت است.




شکل ۴- مقایسه نمرات کارایی قبل و بعد از انتخاب متغیرها در سال ۱۳۹۴

همچنین در یک نگاه کلی نمرات کارایی واحدهای تصمیم گیرنده در مجموعه امکان ادغام شده تحلیل پنجره قبل و بعد از انتخاب متغیرها در شکل های ۵ و ۶ نشان داده شده است. بنابراین با مقایسه نمرات کارایی قبل و بعد از کاهش متغیرها می توان به وضوح تفاوت نمرات کارایی را در واحدهای تصمیم گیرنده مشاهده نمود. همچنین تعداد واحدهای کارا نیز از ۷۸ واحد به ۳۳ واحد کاهش یافته است.



شکل ۵- مقایسه نمرات کارایی بعد از انتخاب متغیرها



شکل ۶- مقایسه نمرات کارایی قبل از انتخاب متغیرها

با توجه به نتایج و بررسی‌های انجام شده در این مطالعه می‌توان موضوعاتی را برای انجام مطالعات آتی مطرح نمود. تهیه فهرست متغیرهای تأثیرگذار از طریق روش‌های دیگر مانند تحلیل مؤلفه‌های اصلی، تحلیل همبستگی، رگرسیون، استفاده از نظر خبرگان با روش دلفی می‌تواند دقت و قدرت شبکه عصبی در انتخاب متغیرهای ورودی و خروجی را مورد ارزیابی قرار داد. همچنین لحاظ کردن ترکیب‌ها و تعداد مختلف ورودی‌ها و خروجی‌های تحلیل پوششی داده‌ها در شبکه عصبی نیز موضوعی است که می‌تواند در مطالعات آتی مد نظر قرار گیرد.

منابع

- بنیادی نائینی، علی، یوسفی، سعید و فاضلی‌راد، محمدعلی، (۱۳۹۵)، پویاسازی خوشه‌بندی مشتریان با استفاده از روش *DEA-DA* در بستر شبکه عصبی مصنوعی *SOM*، فصلنامه علمی-پژوهشی مطالعات مدیریت صنعتی، سال چهاردهم، شماره ۴۰، صفحات ۱۶۵-۱۸۷.
- رمضانیان، محمد رحیم، اویسی عمران، اکرم و یاکیده، کیخسرو، (۱۳۹۱)، تبیین الگوی ارزیابی عملکرد در طی زمان با تحلیل پنجره‌ای، مدیریت صنعتی تهران، دوره ۴: ۲، ۶۹-۸۶.
- Angelidis, D., Lyroudi, K., (2006), *Efficiency in the Italian banking industry: Data envelopment analysis and neural networks*, *International Research Journal of Finance and Economics* 1 (5), 155–165.
- Athanassopoulos, A. D., 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 Operational Research Society* 47 (8), 1000–1017.
- Azadeh, A., Saberi, M., Tavakkoli Moghaddam, R., (2011), Javanmardi, L., *An integrated Data Envelopment Analysis–Artificial Neural Network–Rough Set Algorithm for assessment of personnel efficiency*, *Expert Systems with Applications*, (38), pp. 1364–1373.
- Banker, R.D., (1993). *Maximum likelihood, consistency and data envelopment analysis: A statistical foundation*. *Management Science*, 39 (10), 1265–1273.
- Banker, R.D., (1996). *Hypothesis tests using data envelopment analysis*. *Journal of Productivity Analysis*, 7 (23), 139–159.
- 8- Boussofiane, A., Dyson, R.G., Thanassoulis, E., (1991). *Applied data envelopment analysis*. *European Journal of Operational Research*, 52 (1), 1–15.
- Costa, A., Markellos, R.N., 1997. *Evaluating public transport efficiency with neural network models*. *Transportation Research* 5 (5), 301–312.
- Emrouznejad, A., Shale, E. A., (2009), *a combined neural network and DEA for measuring efficiency of large scale data sets*. *Computers and Industrial Engineering* 56, 249–254.

Golany, B., Roll, Y., (1989). *An application procedure for DEA*. *Omega*, 17(3), 237–250.

Jenkins, L., Anderson, M., (2003). *A multivariate statistical approach to reducing the number of variables in data envelopment analysis*. *European Journal of Operational Research*, 147 (1), 51–61.

Klimberg, R., Puddicombe, M., (1995). *A multiple objective approach to data envelopment analysis, working paper 95-105, School of Management, Boston University, MA*.

Kwon, H., B., and Lee, J., (2015), *Two-stage production modeling of large U.S. banks: a DEA-neural network approach*, *Expert Systems with Applications*, Vol, (42), Issue (19), pp. 6758- 6766.

Kwon, H., B., (2017), *Exploring the predictive potential of artificial neural networks in conjunction with DEA in railroad performance modeling*, *Int. J. Production Economics*, 183, pp. 159–170.

Kwon, H., B., Marvel, J., H., and Roh, J., J., (2017), *Three-stage performance modeling using DEA-BPNN for better practice benchmarking*, *Expert Systems with Applications*, 71, pp. 429-441.

Ming-Chun, T., Shu-Ping, L., Ching-Chan, C., Yen-Ping, L., (2009), *The consumer loan default predicting model – An application of DEA–DA and neural network*, *Expert Systems with Applications* 36, pp. 11682–11690.

[Misiunas](#), N., Oztekin, A., Chen, Y. and Chandra, k., (2016), *DEANN: A healthcare analytic methodology of data envelopment analysis and artificial neural networks for the prediction of organ recipient functional status*, Vol, 58, pp. 46-58.

Nunamaker, T.R., (1985). *Using data envelopment analysis to measure the leniency of non-profit organizations: A critical evaluation*. *Managerial and Decision Economics*, 6 (1), 50–58.

Olanrewaju, O. A., Jimoh, A. A. & Kholopane, P. A., (2016), *assessing the energy potential in the South African industry: A combined IDA-ANN-DEA (Index Decomposition Analysis-Artificial Neural Network-Data Envelopment Analysis) model*, *Energy*, (63), pp. 225- 232.

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 (1), 117–136.

Ramezani, M. R., Oveysi Omran, A., and Yakideh, K. (2012). *Explanation of Performance Evaluation Model over Time by Window Analysis*. *Industrial Management*, 4 (2), 69-86. (In persian)

Salinas-Jimenez, J., Smith, P., (1996). *Data envelopment analysis applied to quality in primary health care*. *Annals of Operations Research*, 67, 141-161.

Shabanpour, H., Yousefi, S. & Farzipoor Saen, R., (2016), *Forecasting efficiency of green suppliers by dynamic data envelopment analysis and artificial neural networks*, *In Press*, pp. 1-10.

Saghafi, H., and Arabloo, M., (2017), *Modeling of CO 2 solubility in MEA, DEA, TEA, and MDEA aqueous solutions using AdaBoost-Decision Tree and Artificial Neural Network*, *International Journal of Greenhouse Gas Control*, 58, pp. 256-265.

Sharifian, A., & Sharifian, S., (2015), *A new power system transient stability assessment method based on Type-2 fuzzy neural network estimation*, *Electrical Power and Energy Systems* 64, pp. 71-87.

Vlontzos, G., and Pardalos, P. M., (2017), *Assess and prognosticate green house gas emissions from agricultural production of EU countries, by implementing, DEA Window analysis and artificial neural networks*, *Renewable and Sustainable Energy Reviews*, 76, pp. 155-162.

Wang, S., (2003), *Adaptive non-parametric efficiency frontier analysis: A neural- network-based model*. *Computers and Operations Research* 30 (2), 279 - 295.

Wu, D., (2009), *Supplier selection: A hybrid model using DEA, decision tree and neural network*. *Expert Systems with Applications* 36 (5), 9105-9112.

Yong-Ming, H., Zhi-Qiang, G. & Qun-Xiong, Z., (2016), *Energy optimization and prediction of complex petrochemical industries using an improved artificial neural network approach integrating data envelopment analysis*, *Energy Conversion and Management*, 124, pp. 73-83.