

چشم‌انداز مدیریت صنعتی

سال نهم، شماره ۳۴، تابستان ۱۳۹۸

شاپا چاپی: ۹۸۷۴-۲۲۵۱، شاپا الکترونیکی: ۴۱۶۵-۲۶۴۵

ص ص ۱۲۹ - ۱۰۷

طراحی یک مدل ترکیبی جدید مبتنی بر تحلیل پوششی داده‌ها، شبکه عصبی مصنوعی، الگوریتم ژنتیک و بهینه‌سازی انبوه ذرات برای ارزیابی کارایی و الگوسازی واحدهای کارا و ناکارا

محمد رضا میرزائی*، محمد علی افشار کاظمی*، عباس طلوعی اشلقی***

چکیده

هدف اصلی پژوهش حاضر، طراحی یک مدل ترکیبی جدید مبتنی بر تحلیل پوششی داده‌ها، شبکه عصبی مصنوعی، الگوریتم ژنتیک و بهینه‌سازی انبوه ذرات برای ارزیابی کارایی و الگوسازی واحدهای کارا و ناکارا است که واحدهای تصمیم‌گیری در آن اندک باشد. فرایندی دومرحله‌ای، برای ارزیابی کارایی نسبی ۱۶ شرکت‌های برق منطقه‌ای شرکت توانیر، از مدل ترکیبی تحلیل پوششی داده‌ها با شبکه عصبی که به وسیله الگوریتم ژنتیک بهینه شده است، بهره برده است و با یک الگوریتم ترکیبی انبوه ذرات با الگوریتم ژنتیک به الگوسازی برای واحدهای کارا و ناکارا پرداخته شده است. میانگین کارایی شرکت‌های برق منطقه‌ای طی سال‌های ۱۳۹۱ تا ۱۳۹۶ از ۰/۸۹۳۴ به ۰/۹۱۴۷ افزایش یافته است و شرکت‌های برق منطقه‌ای آذربایجان، اصفهان، تهران، خراسان، سمنان، کرمان، گیلان و یزد، همواره دارای بیشترین میانگین کارایی، ۱ و شرکت‌های برق منطقه‌ای غرب و فارس با مقادیر میانگین کارایی ۰/۷۰۴۷ و ۰/۶۰۲۵ دارای کمترین مقدار کارایی طی سال‌های ۱۳۹۱ تا ۱۳۹۶ بوده‌اند.

کلیدواژه‌ها: الگوریتم بهینه‌سازی انبوه ذرات- ژنتیک؛ الگوسازی؛ کارایی؛ مدل تحلیل پوششی داده‌ها- شبکه عصبی ژنتیکی.

تاریخ دریافت مقاله: ۱۳۹۷/۰۳/۱۱، تاریخ پذیرش مقاله: ۱۳۹۸/۰۶/۰۶.

* دانشجوی دکتری، گروه مدیریت صنعتی، واحد تهران مرکز، دانشگاه آزاد اسلامی، تهران، ایران.

** دانشیار، گروه مدیریت صنعتی، واحد تهران مرکز، دانشگاه آزاد اسلامی، تهران، ایران (نویسنده مسئول).

E-mail: dr.mafshar@gmail.com

*** استاد، گروه مدیریت صنعتی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

۱. مقدمه

در عصر حاضر، پیشرفت‌ها و تحولات دانش مدیریت، وجود نظام ارزشیابی را در سازمان‌ها به امری اجتناب‌ناپذیر و ضروری تبدیل کرده است؛ تا حدی که فقدان یک نظام ارزیابی برای سنجش استفاده از منابع و امکانات که نشان‌دهنده میزان تحقق اهداف باشد را به‌عنوان یکی از علائم بیماری‌های سازمانی قلمداد می‌کنند. رتبه‌بندی و ارزیابی کارایی شرکت‌ها و مؤسسه‌ها یکی از مهم‌ترین ابزارهای سنجش نقاط قوت و ضعف سازمان‌ها به‌شمار می‌آید. از جمله مشکلات روش‌های موجود رتبه‌بندی سازمان‌ها، تأکید عمده آن‌ها تنها بر یک شاخص اصلی، نظیر فروش یا درآمد و عدم جامعیت آن‌ها است؛ به‌عبارتی دیگر این روش‌ها به‌جای تعیین برترین شرکت‌ها، حجیم‌ترین و بزرگ‌ترین آن‌ها را تعیین می‌کنند؛ بنابراین در ارزیابی باید جامعیت آن در فراگیری تمام زوایای کاری لحاظ شود و یکی از روش‌های رتبه‌بندی و ارزیابی شرکت‌ها که ویژگی‌های بالا را دارا باشد، تحلیل پوششی داده‌ها است.

تحلیل پوششی داده‌ها (DEA)^۱ با قابلیت‌ها و ویژگی‌های منحصر به فرد خود به‌عنوان یک تکنیک ارزیابی چندمعیاره توانسته است به مفهوم ارزیابی در حوزه مدیریت، شفافیت و دقت بالایی ببخشد؛ همچنین تحلیل پوششی داده‌ها دارای ویژگی‌های منحصر به فردی است، از قبیل اینکه در تحلیل پوششی داده‌ها پس از ارزیابی واحدهای تصمیم‌گیری (DMU)^۲ ها، برای هر واحد ناکارا یک نقطه مرجع روی مرز کارایی شناسایی می‌شود؛ به‌گونه‌ای که واحد تحت ارزیابی با کم‌کردن ورودی‌ها، افزودن خروجی‌ها یا با کم‌کردن ورودی‌ها و افزودن خروجی‌هایش هم‌زمان، به نقطه مرجع روی مرز کارا می‌رسد. این خاصیت ارزشمند در سایر تکنیک‌های ارزیابی موجود نیست و مختص این تکنیک است؛ هرچند واحد مرجع برای هر واحد ناکارا، ترکیبی از واحدهای کارا موجود است که در واقعیت وجود عینی ندارد و تصنعی و خیالی است [۳۳].

مدل‌های جدید حاصل از ترکیب تحلیل پوششی داده‌ها با شبکه عصبی توانایی افزایش تعمیم‌پذیری و تخمین روابط غیرخطی برای مدل‌های تحلیل پوششی داده‌ها با تعداد واحدهای تصمیم‌گیری اندک را فراهم کرده است [۴۲، ۴۵]؛ البته تا امروز امکان الگوسازی برای این مدل‌ها وجود نداشت. از نوآوری‌های پژوهش حاضر، ۱. ترکیب تحلیل پوششی داده‌ها و GANN است که سرعت بیشتری در هم‌گرا شدن نسبت به مدل ترکیب تحلیل پوششی داده‌ها با شبکه عصبی دارد و ۲. الگوسازی الگوریتم فراابتکاری ترکیبی انبوه ذرات و الگوریتم ژنتیک برای واحدهای کارا و ناکارای مدل ترکیبی تحلیل پوششی داده‌ها با شبکه عصبی ژنتیکی است. هدف اصلی این پژوهش، طراحی مدلی با ویژگی‌های بالا است که به طراحی یک مدل ترکیبی جدید مبتنی بر تحلیل پوششی داده‌ها، شبکه عصبی مصنوعی ژنتیکی، الگوریتم ژنتیک و بهینه‌سازی

1. Data Envelopment Analysis

2. Decision Making Unit

انبوه ذرات برای ارزیابی کارایی و الگوسازی واحدهای کارا و ناکارا است که تعداد واحدهای تصمیم‌گیری در آن اندک باشد.

۲. مبانی نظری و پیشینه پژوهش

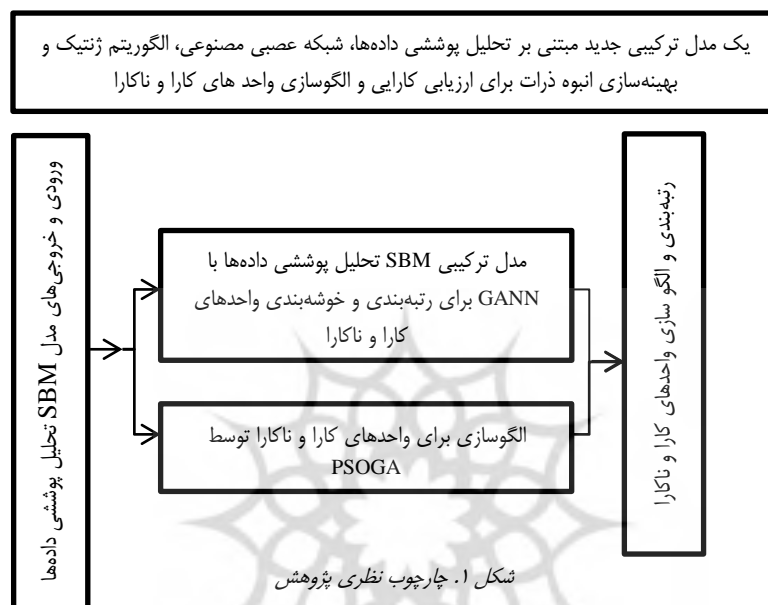
در پژوهشی که به ارزیابی کارایی مناطق برق در کشور سوئد پرداخته است، تفاوتی در کارایی بین شرکت‌های عمومی و خصوصی مشاهده نشد [۲۷]. در اروپای شرقی، شرکت‌های توزیع برق کوچک لهستان ناکارا هستند [۸]، شرکت‌های توزیع برق جمهوری چک کارایی بالاتری نسبت به بقیه دارند و شرکت‌های توزیع برق اسلواکی و مجارستان دارای کارایی متوسط هستند. در این پژوهش‌های تجربی که به تحلیل کارایی در بخش برق پرداخته‌اند، تحلیل پوششی داده‌ها را بسیار مؤثرتر از تحلیل مرزی تصادفی (SFA) می‌دانند [۲۱]. مقایسه بین شرکت‌های توزیع برق انگلیس و ژاپن طی سال‌های ۱۹۸۵ تا ۱۹۹۸ که با اصلاحاتی در مدل تحلیل پوششی داده‌ها همراه بود، نشان داد که اختلاف مقادیر کارایی در بین شرکت‌های انگلیس افزایش یافته است [۲۵]. در مطالعه آلمان شرقی و غربی، یافته‌ها نشان داد که به‌طور متوسط شرکت‌های توزیع برق آلمان شرقی دارای کارایی فنی بالاتری نسبت به هم‌تایان آلمان غربی طبق مدل‌های مختلف تجربی هستند [۲۶]. البته در مطالعه شرکت‌های ژاپنی و آمریکایی، شرکت‌های ژاپنی به‌طور متوسط نسبت به شرکت‌های آمریکایی کارا تر هستند [۲۴]. کارایی ۲۴ شرکت توزیع برق چین با تحلیل پوششی داده‌های چندمرحله‌ای حاکی از آن بود که شرکت‌های هبی، چینگهای، نینگزها، پکن و شانگهای طی سال‌های ۲۰۰۳ تا ۲۰۱۰ بیشترین مقدار کارایی را داشتند [۳۲]. مدلی برای ارزیابی و الگوسازی واحدهای ناکارا به‌وسیله میانگین الگوهای کارا در ۱۸ شرکت‌های برق منطقه‌ای نیز ابداع شده است [۹]. از مطالعات کارایی شرکت‌های برق در ایران می‌توان به مطالعه امامی میبیدی (۱۹۹۸)، در ۳۰ شرکت توزیع برق ایران اشاره کرد که عدم کارایی فنی و مقیاس، سهم یکسانی در عدم کارایی شرکت‌های توزیع برق در ایران داشته‌اند و بیشتر شرکت‌ها در ناحیه بازدهی صعودی نسبت به مقیاس فعالیت می‌کنند [۳۴]. سجادی و عمرانی (۲۰۰۸)، با مطالعه ۳۸ شرکت توزیع برق ایران دریافتند که رویکرد DEA روشی نسبتاً قابل‌اتکا برای تخمین کارایی و استراتژی‌های رتبه‌بندی است [۳۹]. فلاحی و احمدی (۲۰۰۵)، با مطالعه ۴۲ شرکت توزیع ایران در سال ۱۳۸۱ به این نتیجه رسیدند که عدم کارایی مقیاس، مهم‌ترین عامل عدم کارایی شرکت‌های توزیع برق در ایران است و بیشتر شرکت‌ها در ناحیه بازدهی نسبت به مقیاس فزاینده فعالیت می‌کنند [۲۰]. سلیمی و کرامتی (۱۳۹۴)، در مدلی سه‌مرحله‌ای تحلیل پوششی داده‌ها به تحلیل کارایی ۱۶ شرکت برق منطقه‌ای در سال‌های ۱۳۸۵ تا ۱۳۹۲ پرداختند [۴۰].

حسینی (۱۳۹۱)، تغییرات بهره‌وری با استفاده از تحلیل پوششی داده‌ها و شاخص مالم کوئیست در شرکت‌های مدیریت تولید برق در سال ۱۳۹۱ اندازه‌گیری کرد و متوسط نرخ رشد بهره‌وری را طی سال‌های ۱۳۸۱ تا ۱۳۸۷ معادل با ۱/۰۴ به دست آورد [۲۹]. مدل ترکیبی جدیدی نیز با ترکیب تحلیل پوششی داده‌های شبکه‌ای و پویا برای ۱۴ بانک‌ها ارائه شد [۴۳]. پیش‌بینی کارایی به کمک تأثیرپذیری غیرخطی از تأخیرهای زمانی در تحلیل پوششی داده‌ها با شبکه‌های عصبی مصنوعی توسط کاظمی و فاضلی راد ارائه شد [۳۰]. اجلی و صفری (۱۳۹۰)، در پژوهشی با عنوان «ارزیابی عملکرد واحدهای تصمیم‌گیری با استفاده از مدل ترکیبی شبکه‌های عصبی پیش‌بینی‌کننده عملکرد و تحلیل پوششی داده‌ها (مورد مطالعه: شرکت ملی گاز ایران)»، ترکیب تحلیل پوششی داده‌ها با شبکه عصبی مصنوعی را مدلی کارا برای اندازه‌گیری کارایی واحدهای تصمیم‌گیری با تعداد اندک معرفی کردند [۲]. تعداد واحدهای تصمیم‌گیری شرکت‌های برق منطقه‌ای در ایران طبق آخرین تقسیم‌بندی‌ها ۱۶ واحد است که با توجه به تعداد ورودی‌ها و خروجی‌ها، اندک است؛ بنابراین پژوهشگران را بر آن ساخت تا با طراحی مدل ترکیبی جدیدی به رتبه‌بندی، ارزیابی کارایی و الگوسازی واحدهای کارا و ناکارایی بپردازند که در آن با تعداد واحدهای تصمیم‌گیری، اندک باشد.

در این پژوهش از داده‌های پانل ۱۶ شرکت توزیع برق ایران در دوره زمانی ۱۳۹۱ تا ۱۳۹۶ استفاده شده است. با استفاده از پیشینه ذکر شده، متغیرهای تحت کنترل مدیریت که در جعبه معروف تحلیل پوششی داده‌ها به عنوان ورودی‌ها و خروجی‌های مدل SBM مستقل از واحد قرار می‌گیرند، عبارت‌اند از: ۱. طول خطوط شبکه (کیلومتر)؛ ۲. ظرفیت ترانسفورماتورها (مگاوات آمپر)؛ ۳. تعداد کارکنان (نفر) و ۴. تلفات انتقال و توزیع (درصد) به عنوان متغیرهای ورودی و ۱. تعداد مشترکین (هزار نفر) و ۲. انرژی تحویلی به مشترکین (میلیون کیلووات ساعت) به عنوان متغیرهای خروجی به کار گرفته شده‌اند.

در مرحله نخست، با استفاده از کارایی‌های به دست آمده با مدل SBM مستقل از واحد، طی سال‌های ۱۳۹۱ تا ۱۳۹۶ و مقادیر داده‌های ورودی و خروجی مدل SBM مستقل از واحد طی این سال‌ها، اقدام به ساخت مدل GANN-DEA می‌شود. ۷۰ درصد داده‌ها در این مرحله به عنوان داده‌های آموزش، ۱۵ درصد به عنوان داده‌های آزمون و ۱۵ درصد باقی‌مانده به عنوان داده‌های تعمیم استفاده می‌شوند؛ سپس رتبه‌بندی واحدهای شرکت‌های برق منطقه‌ای توانیر در سال ۱۳۹۶ مشخص شده و تفکیک واحدهای کارا و ناکارا در این مرحله صورت می‌گیرد. در مرحله دوم، با استفاده از الگوریتم ترکیبی PSOGA، مقادیر متغیرهای کمکی ورودی‌ها و خروجی‌ها (۴ ورودی و ۲ خروجی) ارائه می‌شود تا برای بهبود مقادیر کارایی در سال آینده مورد استفاده قرار گیرند. این مرحله با قراردادن مقادیر داده‌های سال ۱۳۹۶ در مدل SBM مستقل از واحد، صورت می‌گیرد و سعی می‌شود مقدار کارایی حاصل از الگوریتم ترکیبی

PSOGA به کارایی حاصل از GANN-DEA به عنوان هدف نزدیک شود تا مقادیر متغیرهای کمکی برای GANN-DEA به دست آید و برای هر واحد ناکارا نیاز به یک الگوریتم ترکیبی PSOGA است. مدل SBM مستقل از واحد تحلیل پوششی داده‌ها در تابع برآزش این الگوریتم قرار می‌گیرد و با سعی و خطا و تنظیمات متفاوت پارامترهای این الگوریتم ترکیبی برای رسیدن به کارایی مدل GANN-DEA تلاش می‌شود. از بهترین جواب‌های محلی به دست آمده، مقادیر متغیرهای کمکی به دست می‌آید که همان الگوسازی معروف مدل تحلیل پوششی داده‌ها است. چارچوب نظری پژوهش حاضر مطابق شکل ۱، است



در مرحله سوم، به منظور رتبه‌بندی و ارائه الگو برای واحدهای کارا از روش خوشه‌بندی واحدهای تصمیم‌گیرنده که آذر و همکاران (۱۳۹۱) و طلوعی اشلقی و همکاران (۱۳۹۲)، معرفی کرده‌اند، استفاده می‌شود [۷، ۴۴]؛ البته این مدل از تحلیل پوششی داده‌ها توسط کوک و گرین (۲۰۰۵) با عنوان «ارزیابی نیروگاه‌های برق: یک مدل سلسله‌مراتبی» برای صنعت برق انجام شده است [۱۲]. طلوعی اشلقی و همکاران (۱۳۹۲) و آذر و همکاران (۱۳۹۱)، در این روش واحدهایی را که در سطح هر کدام از ورودی و خروجی‌های مدل کارا می‌شوند را از مدل خارج کردند و دوباره برای واحدهای باقیمانده کارایی را اندازه گرفتند تا چند سطح از مرز کارایی ایجاد شود (واحدهایی که در سطح اول کارا می‌شوند، در اجرای بعد از مدل حذف خواهند شد)؛ اما برای الگوسازی واحدهای مرجع (در نخستین سطح کارا شده‌اند)، اقدام به ساخت واحد مجازی می‌شود؛ به این صورت که برای هر شاخص از تمام ورودی‌ها کمترین و از تمام خروجی‌ها بیشترین مقدار

برای هر واحد مجازی انتخاب می‌شود. واحد مجازی، واحدی است که هرچند عینیت نیافته است، ولی با مجموعه واحدهای تجربه‌شده امکان تحقق چنین واحدی وجود دارد. پس از اضافه‌کردن واحد مجازی به سایر واحدهای تصمیم‌گیرنده، مدل مجدداً اجرا می‌شود. واحدهایی که تاکنون کارا بوده‌اند، کارایی کمتر از ۱ اختیار می‌کنند و بدین ترتیب می‌توان برای واحدهای مرجع نیز واحد مرجعی تعریف کرد و این مرحله نیز توسط مدل SBM مستقل از واحد کلاسیک حل می‌شود. در مرحله چهارم، مراحل مدل GANN-DEA برای واحدهای کارا و واحد مجازی که در گام پنجم شرح داده شد، اجرا و تکرار می‌شود؛ با این تفاوت که به‌منظور طراحی مدل GANN-DEA برای واحدهای کارا، داده‌های سال‌های ۱۳۹۵ و ۱۳۹۶ استفاده شده است و ۵۰ درصد داده‌ها به‌عنوان داده‌های آموزش، ۲۵ درصد داده‌ها به‌عنوان داده‌های آزمون و ۲۵ درصد داده‌های باقیمانده به‌عنوان داده‌های تعمیم، به‌دلیل کم‌بودن ردیف داده‌ها استفاده شده است. در مرحله آخر، مدل SBM مستقل از واحد، که در گام پنجم شرح داده شد، با داده‌های سال ۱۳۹۶ در الگوریتم ترکیبی PSOGA قرار می‌گیرد تا الگوسازی برای واحدهای کارا صورت گیرد و باز هم برای هر واحد تصمیم‌گیرنده یک الگوریتم ترکیبی PSOGA مجزا نیاز است.

۳. روش‌شناسی پژوهش

پژوهش حاضر به دو روش کتابخانه‌ای و اسنادی است. برای انجام آن از داده‌های پانل ۱۶ شرکت توزیع برق ایران در دوره زمانی ۱۳۹۱ تا ۱۳۹۶ استفاده شده است و از آمار تفصیلی صنعت برق ایران موجود در وب‌سایت توانیر^۱ و معاونت هماهنگی و نظارت مالی وزارت نیرو گرفته شده است. پژوهش حاضر از منظر هدف کاربردی-توسعه‌ای است. ابزارهای استفاده شده در روش‌شناسی پژوهش معرفی شده است.

تحلیل پوششی داده‌ها. دبرو و کوپمنز (۱۹۵۱)، نخستین بار کارایی اندازه‌گیری را اندازه‌گیری کردند [۱۶، ۳۱]. فارل (۱۹۵۷) با استفاده از روشی مانند اندازه‌گیری کارایی در مباحث مهندسی، اقدام به اندازه‌گیری کارایی برای یک واحد تولیدی کرد. موردی که فارل (۱۹۵۷) برای اندازه‌گیری کارایی مدنظر قرار داد شامل یک ورودی و یک خروجی بود. مطالعه فارل (۱۹۵۷) شامل اندازه‌گیری کارایی‌های فنی و تخصیصی و مشتق تابع تولید کارا بود [۲۱]. به‌طور خلاصه مدل‌های ابتدایی تحلیل پوششی داده‌ها یک مدل برنامه‌ریزی خطی بوده است که به روش ناپارامتریک، کارایی واحد تصمیم‌گیرنده که دارای چندین نهاده و ستانده هستند، را اندازه‌گیری می‌کند. نخستین مدل تحلیل پوششی داده‌ها بر اساس حروف اول نام واضعان آن‌ها CCR^۲ نام

۱. به سایت توانیر به آدرس "http://www.tavanir.org.ir" مراجعه کنید.

2. Charnes, Cooper & Rhodes

گرفت. در این مدل، هدف اندازه‌گیری و مقایسه کارایی نسبی واحدهای سازمانی مانند مدارس، بیمارستان‌ها، شعب بانک و شهرداری‌ها با چندین خروجی شبیه به هم است [۱۰]. این وسیله سنجش کارایی نیازمند مجموعه‌ای از ورودی‌ها و خروجی‌هایی است که در تمامی واحدهای تصمیم‌گیرنده تحت بررسی استفاده می‌شود. فیر و لاول (۱۹۷۸)، ایراداتی بر اندازه‌گیری کارایی مطرح کردند که انگیزه توسعه اندازه‌گیری کارایی جدید تکنیکی شد. نتایج مطالعات فیر و لاول (۱۹۷۸)، «اندازه راسل» نامیده شد [۳۸]. تفاوت اصلی بین مدل فارل و راسل در این است که اندازه فارل شعاعی است، ولی اندازه راسل غیر شعاعی؛ بنابراین طبقه‌بندی نتایج حاصل مدل این دو الزاماً یکسان نیست. چارز، کوپر، رودز و رودریگواز (۱۹۸۵)، مدلی به نام مدل جمعی که هم‌زمان با کاهش ورودی‌ها، افزایش خروجی‌ها را موردتوجه قرار می‌داد، ابداع کردند. در این مدل مقادیر کمبود ورودی‌ها و مازاد خروجی‌ها استفاده می‌شود که قادر به سنجش میزان ناکارایی واحدها است و به واحد کارا مقدار صفر را اختصاص می‌دهد [۱۱]. در پژوهش حاضر از مدلی که توسط تن (۲۰۰۱)، بر مبنای مقادیر مازاد ورودی‌ها و کمبود خروجی‌ها مطرح شد، استفاده می‌شود و شامل مدل‌های ورودی‌محور، خروجی‌محور، بدون محور و ابرکارایی است که حتی متغیرهای منفی را نیز می‌تواند اختیار کند [۴۶] مدل تن (۲۰۰۱) به شرح رابطه ۱، است:

رابطه (۱) مدل SBM مستقل از واحد [۴۶]

$$\text{Minimize } \rho = \frac{1 - \frac{1}{m} \sum_{i=1}^m (s_i^- / R_i^-)}{1 + \frac{1}{s} \sum_{r=1}^s (s_r^+ / R_r^+)}$$

Subject to,

$$\sum_{j=1}^n x_{ij} \lambda_j + s_i^- = x_{iq} \quad i = 1, 2, \dots, m$$

$$\sum_{j=1}^n y_{ij} \lambda_j - s_r^+ = y_{rq} \quad r = 1, 2, \dots, s$$

$$\sum_{j=1}^n \lambda_j = 1 \quad j = 1, 2, \dots, n$$

$$\lambda_j, s_i^-, s_r^+ \geq 0 \quad i = 1, 2, \dots, m \quad r = 1, 2, \dots, s \quad j = 1, 2, \dots, n$$

چارنز و همکاران (۱۹۸۵)، در ساخت مدل تحلیل پوششی داده‌ها به یک رابطه تجربی در ارتباط با «تعداد واحدهای موردارزیابی» و «تعداد ورودی‌ها و خروجی‌ها» به صورت زیر رسیدند:

رابطه (۲) رابطه تجربی چارنز و همکاران [۱۱]

$$(\text{تعداد خروجی‌ها} + \text{تعداد ورودی‌ها}) \geq 3 \text{ تعداد واحدهای موردارزیابی}$$

به کارنگرفتن رابطه ۲، در عمل موجب می‌شود که تعداد زیادی از واحدها روی مرز کارا قرار گیرند و به عبارت دیگر دارای امتیاز کارایی یک شوند؛ در نتیجه قدرت تفکیک مدل کاهش می‌یابد.

مدل خوب، مدلی است که قدرت تفکیک‌پذیری بالایی داشته باشد؛ به این معنا که تفاوت میان میزان کارایی واحدهای مختلف را تشخیص دهد. مدلی که امتیاز کارایی تمامی و یا اکثر واحدها را یک محاسبه می‌کند، توان تشخیص تفاوت کارایی واحدها را ندارد و دارای قدرت تفکیک‌پذیری پایین است [۳۳]. در مسائلی که تعداد واحدهای موردارزیابی اندک باشد، این رابطه تجربی به کار گرفته نخواهد شد و برای افزایش قدرت تفکیک‌پذیری در مدل‌هایی که تعداد واحدهای موردارزیابی اندک دارند، یکی از راه‌حل‌ها استفاده از مدل ترکیبی تحلیل پوششی داده‌ها با شبکه عصبی است [۲]. در پژوهش حاضر از مدل ترکیبی تحلیل پوششی داده‌ها با شبکه عصبی و الگوریتم ژنتیک بهره بردیم که با داده‌های چند سال متوالی آموزش داده شده است که علاوه بر آنکه قدرت تفکیک‌پذیری مسائل داری واحدهای تصمیم‌گیرنده اندک را افزایش می‌دهد، شبکه عصبی آن هم به دلیل آنکه با الگوریتم ژنتیک بهینه شده است، دارای نرخ یادگیری بالاتر است و سریع‌تر به همگرا می‌شود.

مدل SBM مستقل از واحد، قابلیت الگوسازی برای واحدهای تصمیم‌گیری را دارد؛ اما بعد از ترکیب با شبکه عصبی ژنتیکی به دلیل آنکه جواب‌های قطعی جای خود را به جواب‌های محلی می‌دهند (مقدار خطای شبکه عصبی ژنتیکی) دیگر امکان استفاده از فضای محدب خطی برای الگوسازی را نخواهد داشت. در پژوهش حاضر از الگوریتم ترکیبی بهینه‌سازی انبوه ذرات و الگوریتم ژنتیک برای رفع این نقص بهره برده شده است.

تحلیل پوششی داده‌ها و شبکه عصبی بهینه‌شده با الگوریتم ژنتیک. شبکه‌های عصبی مصنوعی یک سیستم پردازش داده‌ای است که از تعداد زیادی عناصر پردازشگر ساده و بسیار مرتبط با هم (یعنی همان اعصاب مصنوعی) تشکیل شده است. این عناصر پردازشگر معمولاً در لایه‌ها با صفحات ارتباط منطقی دارند؛ به طوری که بین لایه‌ها ارتباطات کامل و یا تصادفی وجود دارد [۱۷]. مغز به عنوان یک سیستم پردازش اطلاعاتی با ساختار موازی از ۷۵۵ تریلیون نورون به هم مرتبط تشکیل شده است [۳۷]. از آنجاکه عوامل زیادی همچون لایه‌های پنهان، تعداد نورون‌های لایه‌های پنهان، وزن‌های مربوط به هر لایه، توابع تبدیل، نرمال کردن داده‌ها و الگوریتم یادگیری می‌توانند عملکرد شبکه‌های عصبی را تحت تأثیر قرار دهند، بنابراین بهترین معماری شبکه عصبی با استفاده از تجربه و آزمایش و خطا به دست می‌آید. از معروف‌ترین مدل‌های شبکه عصبی «مدل پرسپترون چندلایه» است که شامل یک لایه ورودی، یک لایه خارجی و یک لایه بین آن‌ها است که به طور مستقیم به داده‌های ورودی و نتایج خروجی متصل

نیست. در واقع این لایه را «لایه پنهان» می‌نامند. هر واحد در لایه پنهان و لایه خروجی مانند یک پرسپترون عمل می‌کند، با این تفاوت که تابع استفاده شده به جای تابع پلکانی، تابع سیگموئید است. واحدهای لایه ورودی صرفاً وظیفه توزیع مقادیر ورودی را به لایه بعدی بر عهده دارند و بنابراین هیچ محاسبه‌ای را انجام نمی‌دهند [۱۷].

ابتدا باید تابع خطایی را تعریف کرد که تفاوت خروجی واقعی و خروجی مطلوب را نشان دهد؛ چون خروجی مطلوب مشخص است، این نوع فراگیری «فراگیری با سرپرست» نامیده می‌شود. برای موفق شدن در آموزش شبکه باید خروجی آن را به تدریج به خروجی مطلوب نزدیک کرد؛ به عبارت دیگر باید میزان تابع خطا را به طور دائم کاهش داد. برای این منظور ضرایب وزنی خطوط ارتباطی واحدها با استفاده از قاعده کلی دلتا میزان می‌شود. قاعده دلتا مقدار تابع خطا را محاسبه می‌کند و آن را به عقب از یک لایه به لایه پیشین آن انتشار می‌دهد. ضرایب وزنی هر واحد جداگانه میزان می‌شود و بدین صورت میزان خطا کاهش می‌یابد. این عمل در مورد واحدهای لایه خارجی ساده است؛ زیرا خروجی واقعی و مطلوب آن‌ها مشخص است؛ ولی در مورد لایه میانی چندان روشن نیست. این گمان می‌رود که ضرایب وزنی واحدهای پنهان که به واحدهای خروجی با میزان خطایی بزرگ مرتبط هستند باید بیشتر از واحدهای پنهان که به واحدهای مرتبط آن‌ها خروجی تقریباً صحیحی دارند، تغییر یابد. در واقع ریاضیات نشان می‌دهد که ضرایب واحدها باید به تناسب میزان خطای واحدی که به آن متصل هستند، تغییر کند؛ بنابراین می‌توان با انتشار خطا به عقب ضرایب وزنی خطوط ارتباطی تمام لایه‌ها را به درستی میزان کرد. به این طریق تابع خطا کاهش و شبکه آموزش می‌یابد [۴].

برای ارزیابی عملکرد شبکه‌های عصبی در پژوهش کنونی از میانگین خطای مربعات (MSE)^۱، نرمال شده میانگین خطای مربعات (NMSE)^۲، میانگین خطای مطلق (MAE)^۳، کوچک‌ترین خطای مطلق (Min Abs Error)، بزرگ‌ترین خطای مطلق (Max Abs Error) و ضریب همبستگی (r) استفاده شده است. ابزارهای ارزیابی عملکرد شبکه مصنوعی در جدول ۱، نشان داده است.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی

1. Mean Squared Error
2. Normalised Mean Square Error
3. Mean Absolute Error

جدول ۱. ابزارهای ارزیابی عملکرد شبکه مصنوعی [۲۰]

ابزار ارزیابی عملکرد شبکه عصبی	فرمول ریاضی
میانگین خطای مربعات	$MSE = \frac{\sum_{i=1}^n (X_{obs,i} - X_{model,i})^2}{n}$
نرمال شده میانگین خطای مربعات	$NMSE = \frac{MSE}{X_{obs,max} - X_{obs,min}}$
نرمال شده میانگین خطای مربعات	$NMSE = \frac{MSE}{X_{obs}}$
ضریب همبستگی	$r = \frac{\sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \cdot \sum_{i=1}^n (y_i - \bar{y})^2}}$
میانگین خطای مطلق	$MAE = \frac{\sum_{i=1}^n X_{obs,i} - X_{model,i} }{n}$

شبکه عصبی مدل NN-DEA یک پرسپترون چندلایه با الگوریتم پس‌انتشار خطا است که یک لایه ورودی، یک لایه پنهان و یک لایه خروجی دارد. تابع تبدیل لایه پنهان تابع تانژانت هیپربولیک است و تابع تبدیل لایه خروجی یک تابع خطی است. در این شبکه، ورودی‌های شبکه شامل مجموع ورودی‌ها و خروجی‌های هر واحد تصمیم‌گیرنده است و خروجی مورد انتظار (O) مقدار کارایی هر واحد تصمیم‌گیرنده خواهد بود [۶، ۱۳، ۴۷، ۱۹، ۳۸، ۴۲، ۴۵]؛ البته شبکه‌های احتمالی برای ارزیابی کارایی بانک‌های عالی عربی نیز به کار گرفته شده است [۳۶]. الگوریتم ژنتیک (GA) روش جست‌وجوی احتمالاتی فراگیر است که از فرآیند تکامل زیست‌شناختی طبیعی پیروی می‌کند. الگوریتم ژنتیک بر جمعیت جواب‌های بالقوه عمل می‌کند و اصول تنازع بقا را در تولید تقریب‌های بهتر و بهتر جواب مسئله به کار می‌گیرد. در هر نسل، مجموعه جدیدی از تقریب‌ها با فرآیند انتخاب بهترین عضو بر اساس میزان برآزش آن‌ها در دامنه مسئله و تکثیر با عملگرهای گرفته‌شده از ژنتیک طبیعی ساخته می‌شود. این فرآیند در نهایت به تکامل جمعیتی از اعضا ختم می‌شود که نسبت به اعضای اولیه که در واقع والدین اصلی آن‌ها هستند با محیط سازگاری بهتری دارند [۳].

جان هلند (۱۹۷۵) این روش را معرفی کرد [۲۸]؛ ولی سرانجام یکی از شاگردان وی به نام گلدبرگ (۱۹۸۸) آن را جمع‌بندی و ارائه کرد [۳۳]؛ البته نتایج مطالعات دیونگ (۱۹۷۵)، کارآمدی الگوریتم ژنتیک را تأیید کرد [۱۵]. هدف از به‌کارگیری الگوریتم ژنتیک، بهینه‌سازی پارامتر وزن شبکه عصبی مصنوعی است؛ بنابراین تابع هدف الگوریتم ژنتیک، تابعی از نتایج آماری شبکه عصبی مصنوعی است. بخشی از جمعیت هر نسل برای آموزش توسط شبکه عصبی به‌طور

تصادفی مقداردهی اولیه می‌شود و میزان خطا با استفاده از داده‌های آموزش محاسبه می‌شود؛ سپس به‌روزرسانی پارامترهای شبکه با توجه به مقادیر تابع هدف و نرخ‌های جهش و تلاقی صورت می‌گیرد. هر کروموزوم، مجموعه ژن‌هایی است که سعی در بهینه‌سازی پارامترهای شبکه عصبی و برآورد مقادیر سطح ایستایی دارد. تمرکز این روش بر جمعیتی از نقاط به‌عنوان مجموعه جواب موجب جلوگیری از افتادن الگوریتم ژنتیک در حداقل‌های محلی می‌شود.

در مرحله بعد، توابع هدف کروموزوم‌های نسل اولیه محاسبه می‌شود. در این مرحله پارامترهای الگوریتم ژنتیک از طریق آموزش کروموزوم‌ها به کمک شبکه عصبی و ارزیابی توده‌های تولیدی در مرحله تولیدمثل، تکامل می‌یابند. با پیدایش نسل‌های جدید شبکه عصبی آموزش داده‌شده با داده‌های نسل اولیه می‌تواند دچار خطا شود؛ بنابراین آموزش کروموزوم‌ها به‌طور دوره‌ای تکرار می‌شود. تمرکز روش جست‌وجوگر عصبی ژنتیک بر جمعیتی از نقاط به‌عنوان مجموعه جواب موجب جلوگیری از افتادن الگوریتم ژنتیک در حداقل‌های محلی می‌شود؛ همچنین به‌کارگیری شبکه عصبی به کاهش پیچیدگی‌های زمان‌بر محاسباتی و بهره‌گیری از قواعد آماری به‌جای قواعد صریح منجر می‌شود. شبکه عصبی مورد استفاده در این روش همان شبکه عصبی پروسپترون در مدل NN-DEA متشکل از یک لایه ورودی، یک لایه میانی و یک لایه خروجی است که با الگوریتم ژنتیک ترکیب شده و GANN-DEA نام‌گذاری شده است.

الگوریتم ترکیبی بهینه‌سازی انبوه ذرات و الگوریتم ژنتیک. روش بهینه‌سازی انبوه ذرات یا به‌اختصار «بهینه‌سازی انبوه ذرات» از شبیه‌سازی رفتار اجتماعی گروه پرندگان مدل‌سازی شده است. جیمز کندی^۱، روان‌شناس اجتماعی و راسیل سی‌ایرهارت^۲، مهندس برق، صاحبان اصلی نظریه الگوریتم بهینه‌سازی انبوه ذرات هستند [۱۸]. پژوهش آن‌ها به شبیه‌سازی رفتار پرندگان برای یافتن دانه انجامید. این کار تحت تأثیر کار هیپر و گراندره (۱۹۹۰) بود که در سال ۱۹۹۰ برای شبیه‌سازی رفتار پرندگان به‌صورت یک سیستم غیرخطی صورت گرفت [۱]. آنجلین (۱۹۹۸) نخستین رویکرد برای ترکیب مفاهیم GA با بهینه‌سازی انبوه ذرات را پیشنهاد کرد که نشان می‌دهد عملکرد PSO^۳ می‌تواند برای کلاس‌های خاصی از مسائل توسط اضافه کردن یک فرآیند انتخاب شبیه به چیزی که در الگوریتم‌های تکاملی رخ می‌دهد، بهبود یابد. رویه انتخاب قبل از به‌روزرسانی سرعت اجرا می‌شود و به‌طور تجربی نشان داد که این الگوریتم، توانایی جست‌وجوی محلی PSO را بهبود می‌دهد؛ همچنین از آنجاکه نیمی از ذرات توسط نیمی دیگر جایگزین

1. James Kennedy
2. Russell C. Earhart
3. Particle Swarm Optimization

می‌شوند، تنوع حل، تا ۵۰ درصد در هر تکرار کاهش می‌یابد. تنوع می‌تواند توسط جایگزینی بدترین ذرات با کپی جهش‌یافته از بهترین ذرات جایگزین شود و هر دو الگوریتم به صورت پیوسته استفاده می‌شوند [۵]. عبدالواحد و همکاران (۲۰۱۱)، با الگوریتم PSOGA به حل توابع آزمون مختلف غیرخطی پرداختند و الگوریتم یادشده را سریع‌تر و دارای جواب‌های بهتر معرفی کردند [۱]. گاج هاریش (۲۰۱۶)، با الگوریتم PSOGA به حل دو مسئله مکانیکی (طراحی مخزن تحت فشار و طراحی محل جوش) محدودیت‌دار پرداخت و روش یادشده را کارا توصیف کرد [۲۲]. در پژوهش حاضر نیز از نحوه ترکیب مفاهیم GA با بهینه‌سازی انبوه ذرات ارائه‌شده توسط گاج (۲۰۱۶)، بهره گرفته شده است. مدل گاج شامل دو روبه GA و PSO است که در ادامه شرح آن‌ها شرح داده خواهد شد.

رویه کلی یا شبه‌کد الگوریتم ژنتیک

۱. شروع: ایجاد جمعیتی از n کروموزوم (جواب‌های بالقوه مسئله) به صورت تصادفی؛
۲. برازش: ارزیابی میزان سازگاری هر کروموزوم (X) با استفاده از تابع $f(x)$ ؛
۳. جمعیت جدید: ایجاد جمعیت جدید با تکرار مراحل زیر تا تکمیل جمعیت جدید؛
- ۳-۱. انتخاب: انتخاب دو کروموزوم والد از میان جمعیت بر اساس میزان سازگاری آن‌ها (سازگاری بیشتر = احتمال انتخاب بیشتر)؛
- ۳-۲. تقاطع: کروموزوم‌های والد مرحله قبل؛
- ۳-۲-۱. کروموزوم‌های والد به طور تصادفی با میزان احتمال تعیین شده جفت‌گیری می‌کنند و دو فرزند جدید به وجود می‌آورند. اگر تقاطع صورت نگیرد فرزندان عیناً مشابه دو کروموزوم والد می‌شوند؛
- ۳-۳. جهش: کروموزوم‌های فرزند ایجادشده به طور تصادفی با میزان احتمال تعیین شده جهش می‌یابد؛
- ۳-۴. قبول: فرزندان ایجادشده در جمعیت جدید قرار می‌گیرند؛
۴. جایگزینی: از جمعیت جدید برای تکرار الگوریتم استفاده می‌شود؛
۵. آزمون: اگر شرایط مطلوب حاصل شود، الگوریتم متوقف می‌شود و جمعیت موجود، جواب مطلوب را نشان می‌دهد؛
۶. [حلقه تکرار]: به مرحله ۲ برگشت داده می‌شود.

شبه‌کد الگوریتم بهینه‌سازی انبوه ذرات

۱. n ذره در ابعاد فضای جواب مسئله به صورت تصادفی ایجاد می‌شود؛

۲. برای تمام ذرات همانند ذره λ_m ، x (موقعیت فعلی ذره) و V_i (سرعت حرکت ذره) به صورت تصادفی ایجاد می‌شود؛

۳. تا زمانی که شرایط توقف الگوریتم به وجود نیامده باشد، مراحل زیر انجام می‌شود:

۳-۱. به ازای هر یک از ذرات ($i=1, \dots, n$) حلقه زیر انجام می‌شود:

۳-۲. تابع برازش محاسبه می‌شود؛

۳-۳. اگر تابع برازش ذره λ_m بهتر از y_i بود، آنگاه ذره λ_m جایگزین y_i می‌شود و به مرحله بعدی می‌رویم؛

۳-۴. در غیر این صورت به مرحله بعد می‌رویم؛

۳-۵. پایان حلقه (به ازای)

۴. بهترین ذره از میان اعضای جمعیت فعلی که دارای بهترین تابع برازش باشد، انتخاب شده و

\hat{y}_i نامیده می‌شود. به ازای هر یک از ذرات ($i=1, \dots, n$) مراحل زیر انجام می‌شود:

۴-۱. سرعت هر ذره بر اساس رابطه ۱، محاسبه می‌شود.

$$v_{ik+1} = w v_{ik} + c_1 r_1 (p_{ik} - x_{ik}) + c_2 r_2 (p_{gk} - x_{ik}) \quad \text{رابطه (۱)}$$

در رابطه ۱، w ضریب اینرسی، r_1 و r_2 اعداد تصادفی بین صفر تا یک، c_1 و c_2 ضرایب

یادگیری (به ترتیب شخصی و اجتماعی) و p_{gk} وضعیت هر ذره است.

۴-۲. موقعیت هر ذره بر اساس رابطه ۲، به روز می‌شود.

$$x_{ik+1} = x_{ik} + v_{ik+1} \quad \text{رابطه (۲)}$$

۴-۳. پایان حلقه (به ازای)

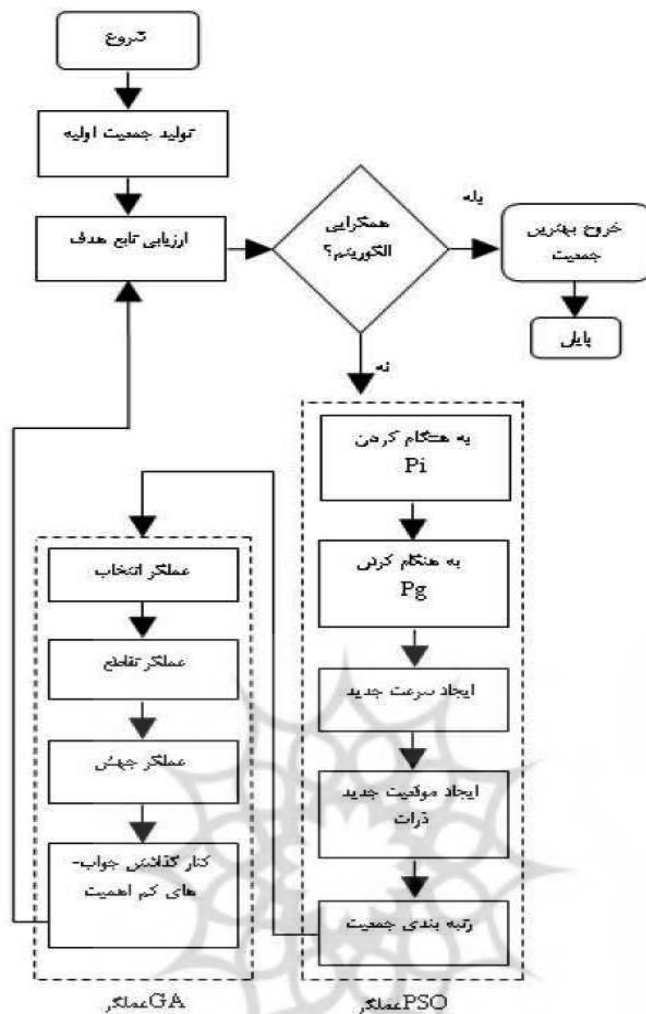
۵. پایان حلقه (تا زمانی که).

جواب‌های به دست آمده از یک تکرار الگوریتم PSO در اختیار الگوریتم GA قرار می‌گیرد و

پس از پایان یک تکرار GA، یک تکرار از الگوریتم PSOGA به اتمام می‌رسد. خروجی حاصل

یک جواب محلی است و این حلقه تا رسیدن به شرط توقف ادامه می‌یابد [۲۲] و در شکل ۲،

الگوریتم ترکیبی PSOGA به تصویر کشیده شده است.



شکل ۲. الگوریتم ترکیبی PSOGA [۲۲]

۴. تحلیل داده‌ها و یافته‌های پژوهش

شرکت‌های توزیع و انتقال برق منطقه‌ای آذربایجان، اصفهان، تهران، خراسان، سمنان، کرمان، گیلان و یزد در فاصله زمانی سال‌های ۱۳۹۱ تا ۱۳۹۶ همواره کارا بوده‌اند. از میان شرکت‌های کارا در سال ۱۳۹۶ (وضعیت کنونی)، بهترین عملکرد متعلق به شرکت برق منطقه‌ای سمنان بوده و کمترین نمره ابرکارایی را شرکت برق منطقه‌ای تهران به خود اختصاص داده است. رتبه‌بندی کارایی شرکت‌های کارا در سال ۱۳۹۶، به ترتیب نمرات کارایی آن‌ها به صورت شرکت‌های توزیع و انتقال برق منطقه‌ای سمنان، کرمان، اصفهان، خراسان، گیلان، یزد،

آذربایجان، سیستان و بلوچستان، خوزستان و تهران است. میانگین نمرات کارایی شرکت‌های برق منطقه‌ای از سال ۱۳۹۲ تا ۱۳۹۴ اندکی کاهش یافته، اما از سال ۱۳۹۲ به بعد دوباره سیر صعودی خود را ادامه داده است. شرکت توزیع و انتقال برق منطقه‌ای خوزستان برای نخستین بار در سال ۱۳۹۶ کارا شناخته شد و این در حالی است که در سال‌های گذشته رشد صعودی بیشتری نسبت به سایر شرکت‌های برق منطقه‌ای داشته است. شرکت‌های توزیع و انتقال برق منطقه‌ای باختر، زنجان، غرب، فارس، مازندران و هرمزگان در بازه زمانی ۱۳۹۱ تا ۱۳۹۶ همواره ناکارا شناخته شده‌اند. رتبه‌بندی کارایی شرکت‌های ناکارا در سال ۱۳۹۶ به ترتیب نمرات کارایی آن‌ها به صورت شرکت‌های توزیع و انتقال برق منطقه‌ای هرمزگان با $0/848337$ کارایی، زنجان با $0/804779$ کارایی، مازندران با $0/801438$ کارایی، باختر با $0/774004$ کارایی، غرب با $0/71636$ کارایی و فارس با $0/669565$ کارایی ارزیابی شده است. مقادیر کارایی شرکت‌های توزیع و انتقال برق منطقه‌ای توانیر در بازه زمانی ۱۳۹۱ تا ۱۳۹۶ که با استفاده از مدل SBM مستقل از واحد و بازدهی متغیر نسبت به مقیاس به دست آمد، در جدول ۲، ارائه شده است.

جدول ۲. کارایی مدل SBM مستقل از واحد و بازدهی متغیر نسبت به مقیاس شرکت‌های توزیع و انتقال برق منطقه‌ای توانیر طی سال‌های ۱۳۹۱ تا ۱۳۹۶

شرکت برق منطقه‌ای	مدل DEA	سال					میانگین SBM
		۱۳۹۱	۱۳۹۲	۱۳۹۳	۱۳۹۴	۱۳۹۵	
آذربایجان	SBM	۱	۱	۱	۱	۱	۱
	Super Efficiency	۱/۰۶۲۲۵۶	۱/۰۶۴۱۸۳	۱/۰۲۸۳۶۷	۱/۰۳۶۵۳۸	۱/۰۳۱۵۹۱	۱/۰۳۰۲۶۹
اصفهان	SBM	۱	۱	۱	۱	۱	۱
	Super Efficiency	۱/۰۶۶۹۸۵	۱/۱۴۹۱۹۷	۱/۱۹۴۹۹۲	۱/۱۷۶۲۵	۱/۱۵۰۸۰۷	۱/۱۴۱۰۱۳
باختر	SBM	$0/73867$	$0/71412$	$0/753131$	$0/718155$	$0/701485$	$0/771126$
	Super Efficiency	$0/420592$	$0/753131$	$0/718155$	$0/701485$	$0/771126$	$0/774004$
تهران	SBM	۱	۱	۱	۱	۱	۱
	Super Efficiency	۱/۵۵۳۰۳۸	۱	۱	۱	۱	۱
خراسان	SBM	۱	۱	۱	۱	۱	۱
	Super Efficiency	۱/۳۵۶۸۳۱	۱/۱۳۶۳۵۳	۱/۱۰۴۹۴۹	۱/۰۸۱۹۲۵	۱/۰۹۱۳۱	۱/۱۰۵۱۷
خوزستان	SBM	$0/848639$	$0/865687$	$0/804222$	$0/821384$	$0/783101$	$0/817439$
	Super Efficiency	$0/517863$	$0/804222$	$0/821384$	$0/783101$	$0/817439$	۱/۰۱۵۴۲۱
زنجان	SBM	$0/836778$	$0/836451$	$0/863951$	$0/849852$	$0/858508$	$0/807127$
	Super Efficiency	$0/485461$	$0/863951$	$0/849852$	$0/858508$	$0/807127$	$0/804779$
سمنان	SBM	۱	۱	۱	۱	۱	۱
	Super Efficiency	۱/۴۹۷۴۲	۱/۲۸۳۸۳۵	۱/۳۴۰۳۸۸	۱/۳۷۷۶۲۴	۱/۳۴۰۳۵۵	۱/۳۶۶۳۰۷
سیستان و	SBM	$0/999765$	$0/999721$	$0/999702$	$0/999745$	$0/999422$	۱

شرکت برق منطقه‌ای	مدل DEA	سال					میانگین SBM
		۱۳۹۱	۱۳۹۲	۱۳۹۳	۱۳۹۴	۱۳۹۵	
بلوچستان	Super Efficiency	۱/۰۱۹۴۵	-/۹۹۹۴۲۲	-/۹۹۹۷۴۵	۱/۰۱۳۳۹۹	-/۹۹۹۷۰۲	۱/۱۶۴۰۴۳
	SBM	-/۷۱۶۳۶	-/۶۹۹۵۴۹	-/۷۰۹۰۸۵	-/۷۲۷۲۷۱	-/۷۱۱۲۲۳	-/۷۰۴۷۹۴
غرب	Super Efficiency	-/۷۱۶۳۶	-/۶۹۹۵۴۹	-/۷۰۹۰۸۵	-/۷۲۷۲۷۱	-/۷۱۱۲۲۳	-/۴۵۴۶۱۳
	SBM	-/۶۶۹۵۶۵	-/۶۲۶۸۶۵	-/۶۰۱۶۳۲	-/۵۸۳۶۸۲	-/۵۸۳۲۷۲	-/۵۵۰۴۶۲
فارس	Super Efficiency	-/۶۵۹۵۶۵	-/۶۲۶۸۶۵	-/۶۰۱۶۳۲	-/۵۸۳۶۸۲	-/۵۸۳۲۷۲	-/۴۴۷۰۴
	SBM	۱	۱	۱	۱	۱	۱
کرمان	Super Efficiency	۱/۲۰۳۱۵۳	۱/۱۷۷۰۸۳	۱/۱۱۹۶۴۹	۱/۱۷۱۳۳۳	۱/۱۶۷۳۷۱	۱/۲۵۸۸۷۷
	SBM	۱	۱	۱	۱	۱	۱
گیلان	Super Efficiency	۱/۰۹۵۸۶۳	۱/۰۱۸۶۶	۱/۰۹۹۰۶۳	۱/۱۱۶۱۷۷	۱/۱۶۰۸۵۱	۱/۱۷۱۷۷۷
	SBM	-/۸۰۱۴۳۸	-/۷۸۸۳۷۱	-/۸۴۲۳۰۲	-/۸۲۶۰۲۶	-/۸۳۸۸۳۹	-/۸۰۸۴۶۷
مازندران	Super Efficiency	-/۸۰۱۴۳۸	-/۷۸۸۳۷۱	-/۸۴۲۳۰۲	-/۸۲۶۰۲۶	-/۸۳۸۸۳۹	-/۴۹۳۲۱۶
	SBM	-/۸۴۸۳۳۷	-/۷۹۷۰۶	-/۸۰۰۲۱۸	-/۸۱۱۲۷۲	-/۸۰۶۴۰۸	-/۸۵۵۴۱۳
هرمزگان	Super Efficiency	-/۸۴۸۳۳۷	-/۷۹۷۰۶	-/۸۰۰۲۱۸	-/۸۱۱۲۷۲	-/۸۰۶۴۰۸	-/۴۵۴۲۸۵
	SBM	۱	۱	۱	۱	۱	۱
یزد	Super Efficiency	۱/۰۷۷۳۹۸	۱/۰۷۲۳۷۶	۱/۰۶۰۵۲۸	۱/۰۶۲۹۹۶	۱/۰۵۸۷۵۱	۱/۰۷۸۳۳۵
	SBM	-/۹۱۴۷۰۴	-/۸۹۴۱۸۵	-/۸۹۳۵۰۵	-/۸۹۶۱۰۳	-/۸۹۷۵۵۹	۱/۸۹۳۴۶۹
میانگین	SBM						

برای اجرای مدل GANN-DEA ابتدا مدل NN-DEA، یعنی یک پرسپکترون سه لایه با الگوریتم پس انتشار خطا، که یک لایه ورودی، یک لایه پنهان و یک لایه خروجی دارد، طراحی می‌شود. تابع تبدیل به لایه پنهان، تابع تانژانت هیپرپولیک است و تابع تبدیل لایه خروجی یک تابع خطی است. در این شبکه، ورودی‌های شبکه شامل مجموع ورودی‌ها و خروجی‌های هر واحد تصمیم‌گیرنده است و خروجی موردانتظار (O) مقدار کارایی هر واحد تصمیم‌گیرنده خواهد بود و شبکه فوق با الگوریتم ژنتیک بهینه شده و GANN-DEA نام‌گذاری شده است؛ سپس با سعی و خطا بهترین تنظیمات برای NN-DEA و الگوریتم ژنتیکی که آن را بهینه می‌کند، به دست آمده است. بهترین تنظیمات GA شامل چرخ رولت برای نحوه انتخاب و با جمعیت اولیه ۲۰، تزویج دونقطه‌ای با نرخ ۰/۹، جهش با تابع یکنواخت و نرخ جهش ۰/۰۱ و شرط توقف ۶۰ دقیقه یا ۱۰۰ نسل، حاصل شد.

خلاصه بهینه‌سازی دو شبکه عصبی یادشده با الگوریتم ژنتیک در جدول ۳، ارائه شده است.

جدول ۳. خلاصه بهینه‌سازی با الگوریتم ژنتیک برای دو شبکه عصبی NN-DEA

خلاصه بهینه‌سازی	بهترین برازندگی (شبکه عصبی شامل تمامی واحدها)	متوسط برازندگی (شبکه عصبی شامل تمامی واحدها)	بهترین برازندگی (شبکه عصبی شامل واحدهای کارا)	متوسط برازندگی (شبکه عصبی شامل واحدهای کارا)
نسל	۴	۵	۵	۷
کمترین مقدار میانگین مربعات خطا	۰/۰۰۰۴۱۳۷۳۷	۰/۰۰۱۴۹۹۵۹	۰/۰۰۰۳۹۶۴۸۳	۰/۰۰۰۱۴۲۸۲۸
مقدار میانگین مربعات خطا نهائی	۰/۰۰۰۴۱۳۷۳۷	۰/۰۰۱۴۹۹۵۹	۰/۰۰۰۳۹۶۴۸۳	۰/۰۰۰۱۴۲۸۲۸

عملکرد شبکه‌های عصبی NN-DEA بعد از بهینه‌سازی با الگوریتم ژنتیک در جدول ۴، ارائه شده است.

جدول ۴. نتایج ابزارهای ارزیابی عملکرد شبکه‌های عصبی

عملکرد شبکه عصبی	خروجی شبکه عصبی شامل تمامی واحدها	خروجی شبکه عصبی شامل واحدهای کارا
میانگین مربعات خطا	۰/۰۰۰۴۱۳۷۳۷	۰/۰۰۰۱۴۲۸۲۸
نرمال شده مقدار میانگین مربعات خطا	۰/۰۰۲۵۶۱۰۹۱	۰/۰۰۱۶۴۰۲۷۳
میانگین قدر مطلق خطا	۰/۰۰۱۴۹۹۵۹	۰/۰۰۱۱۷۴۸۹۸
کوچک‌ترین قدر مطلق خطا	۰/۰۰۱۴۹۹۵۹	۰/۰۰۱۱۷۴۸۹۸
بزرگ‌ترین قدر مطلق خطا	۰/۰۰۷۶۶۲۵۹۷	۰/۰۰۴۹۱۵۶۴۹
ضریب همبستگی	۰/۹۹۹۷۰۹۰۵	۰/۹۹۹۸۱۷۷۲۶

بهترین تنظیمات الگوریتم ترکیبی PSOGA شامل مؤلفه ادراکی و مؤلفه اجتماعی ۱/۵، بیشترین مقدار ضریب اینرسی ۰/۹ و کمترین مقدار ضریب اینرسی ۰/۴ قرار داده شده است. تزویج تک‌نقطه‌ای با نرخ ۰/۸۵، نرخ جهش ۰/۰۲، جهش با تابع یکنواخت، جمعیت اولیه برای هر ذره در الگوریتم ژنتیک ۱۰، کمترین تعداد تکرار در الگوریتم ژنتیک ۱۰، بیشترین تعداد تکرار در الگوریتم ژنتیک ۲۰، کمترین تعداد افراد در الگوریتم ژنتیک ۱، نرخ کاهش تعداد افراد تحت تأثیر الگوریتم ژنتیک (۷) ۱۰ و نرخ افزایش حداکثر تکرار الگوریتم ژنتیک (β) ۱۵، به‌دست آمده است. مقادیر کارایی که با الگوریتم GANN-DEA و PSOGA برای واحدهای ناکارا و کارا تخمین زده شده است و نیز مقادیر متغیرهای کمکی که برای الگو سازی واحدهای ناکارا توسط الگوریتم ترکیبی PSOGA به‌دست آمده است، در جدول‌های ۵ و ۶ مشاهده می‌شود.

جدول ۵. مقادیر کارایی GANN-DEA و PSOGA برای واحدهای نا کارا و مقادیر متغیر کمکی برای الگوسازی واحدهای نا کارا توسط PSOGA

شرکت برق منطقه‌ای	کارایی GANN- DEA	کارایی PSOGA	S6(PSOG A)	S5(PSOG A)	S4(PSO GA)	S3(PSO GA)	S2(PSO GA)	S1(PSOGA)
باختر	-/۷۷۸۶۵۲	-/۷۷۴۰۰۷	-/۰۰۰۰۵۰۱	-/۰۰۰۰۰۰۵	-/۰۹۹۸۶۲	۲۵۵/۴۷۲۹	۲۶۵۵/۴۲۳	۴۰۷۵/۸۶۲
فارس	-/۶۷۶۰۴۸	-/۶۷۱۷۰۸	-/۰۰۰۰۴۹۷	-/۰۰۰۰۰۵۰۱	-/۰۲۷۱۴۶	۹۹۸/۰۶۸۸	۸۴۷۵/۳۶۳	۶۱۵۳/۸۲۴
غرب	-/۷۱۰۲۳۷	-/۷۱۶۳۶۵	-/۰۰۰۰۵۲۶	-/۰۰۰۰۰۵۰۲	-/۵۴۲۰۷۷	۸۹/۳۷۹۱۹	۱۹۳۳/۹۳۵	۴۷۸۶/۶۹۷
هرمزگان	-/۸۴۷۳۴۱	-/۸۴۴۹۷۲	۹۲۰/۳۷۳۹	.	-/۸۷۳۳۵۷	۱۰۴/۷۰۴۷	۱۸۸۴/۷۲۹	-/۰۰۰۰۱۰۹
مازندران	-/۸۰۵۳۱۵	-/۸۰۲۶۴۸	-/۰۰۰۰۵۱۱	-/۰۰۰۰۰۴۹۸	-/۴۵۸۳۱۹	۱۳۰/۴۴۶۹	۱۷۲۳/۰۲۲	۱۱۳۶/۶۰۸
زنجان	-/۸۰۷۶۵۶	-/۸۰۴۷۸۹	-/۰۰۰۰۵۰۴	-/۰۰۰۰۰۵۰۱	-/۵۹۱۰۰۳	۱۵۵/۰۹۲۵	۵۷۷/۴۴۶	۱۰۴۴/۲۶۵

جدول ۶. مقادیر کارایی GANN-DEA و PSOGA برای واحدهای کارا و مقادیر متغیر کمکی برای الگوسازی واحدهای کارا توسط PSOGA

شرکت برق منطقه‌ای	کارایی GANN-DEA	کارایی PSOGA	S6(PSOG A)	S5(PSOG A)	S4(PSOG A)	S3(PSOG A)	S2(PSOG A)	S1(PSOG A)
آذربایجان	-/۳۴۴۸۷۲	-/۳۴۰۴۱۸	۷۸۷/۸۲۸	-/۰۰۹۱۵۴	-/۹۴۵۶۹۲	۸۷۲/۸۶۳۸	۶۵۴۹/۹۸	۵۹۳۲/۳۰۲
اصفهان	-/۴۰۴۴۱۳	-/۴۰۴۱۵۸	۵۳۵/-/۰۲۹	۱۹۱۲۲/۶۹	-/۵۱۰۷۹۴	۵۲۱/۳۳۴۷	۱۳۵۴۲/۹۹	۷۵۶۹/۹۹۲
خراسان	-/۳۸۱۳۴۱	-/۳۸۲۹۰۲	۴۸۸۸/۰۰۳	۳۴۰۹۴/۵۶	-/۵۰۸۰۶۹	۲۱۶۷/۹۷	۳۵۱۲۸/۹۹	۶۸۸۲/۹۹۲
خوزستان	-/۲۹۱۲۴۱	-/۲۹۷۵۲	-/۰۴۰۶۳۶	۲۰۰۱۰/۹۳	۱/۱۶۶۷۹۶	۱۸۸۴/۰۶۸	۲۱۱۵۶/۹۸	۶۴۵۸/۹۸۹
سمنان	-/۹۳۶۰۳۷	-/۹۲۸۹۹۵	۷۵۸۰/۱۶	۳۶۳۵۲/۱۴	-/۱۹۱	۸۱/۵۳۰۹۸	-/۰۰۱۰۵۵	-/۰۰۱۳۲۱
سیستان و بلوچستان	-/۴۹۹۵۲۱	-/۴۹۵۱۹۶	۳۴۸۹۲/۸۵	۱/۵۱۹۹۵۳	۶۱۲/۲۰۳۱	۱۰۳۱/۰۷۶	۵۳۳۲/۹۹۲	-/۴۳۹۹۴۸
گیلان	-/۶۸۹۹۴۴	-/۶۸۲۰۴۲	۹۴۸۷۰۷۷	۲۲۷۵/۱۳۲	۱/۱۲	۴۳۷/۹۹۶	۲۲۱۷/۹۹۵	۶۰۴/۹۹۶۷
یزد	-/۷۴۲۵۹۶	-/۷۴۸۴۸۲	۷۵۳۹/۸۰۷	۳۴۲۰۵	-/۰۰۱	۱۹۲/۰۰۸	۲۴۷۶/۱۵۴	۱۵۴۵/۲۷۵
تهران	-/۲۹۱۴۴۴	-/۲۹۵۲۱۶۳	-/۰۰۱	-/۰۰۱	-/۶۳۷۷	۲۲۲۲	۳۵۱۳/۰۰۷	۶۸۸۲/۹۹۹
کرمان	-/۵۶۰۷۳۷	-/۵۶۷۳۶۳۶	۷۰۶۷/۶۸۷۲	۳۰۴۳۹/۰۰۶	۱/۱۸۸۹	-/۰۰۲۸۷	۵۶۳۳/۰۰۷۸	۶۰۲۸/۹۳۲

برای مقایسه کارایی حاصل از دو الگوریتم GANN-DEA و PSOGA در جدول‌های ۵ و ۶، فرض برابری میانگین کارایی‌ها در نظر گرفته شده و با استفاده از آزمون آماری تی استیوننت بررسی شد. با توجه به نتایج این آزمون، فرض برابری میانگین کارایی‌ها مورد پذیرش قرار گرفت. در این آزمون مقدار ارزش t ، $۰/۰۰۰۴۱۳$ ، ارزش p $۰/۹۹۶۷۴$ ، درجه آزادی ۳۰ ، نسبت واریانس f $۰/۰۸۴۳۶$ و واریانس p $۰/۹۸۷۲۳۶$ به دست آمد و به عبارت دیگر اختلاف معناداری در سطح ۹۵ درصد اطمینان میان الگوریتم‌ها از منظر برابری میانگین کارایی‌ها وجود ندارد.

یافته‌های مدیریتی. با الگوریتم PSOGA سعی می‌شود تا مقدار کارایی به نحوی محاسبه شود که نزدیک به مقدار کارایی GANN-DEA باشد. مقادیر به دست آمده با متغیرهای کمکی، الگوهای واحدهای تصمیم‌گیری خواهند بود. بدین صورت که مقادیر متغیرهای ورودی کاهش و مقادیر متغیرهای خروجی افزایش یابد. برای مثال، شرکت برق منطقه‌ای ۳ در جدول ۵، باید طول خطوط شبکه را به مقدار $4075/862$ کیلومتر، ظرفیت ترانسفورماتورها را به مقدار $2655/433$ مگاوات‌آمپر، تعداد کارکنان را 255 نفر و تلفات انتقال و توزیع را $199862/0$ درصد کاهش دهد و تعداد مشترکین $0/00005$ هزار نفر و انرژی تحویلی به مشترکین را $0/0000501$ میلیون کیلووات ساعت افزایش دهد تا به مرز کارا برسد؛ البته همین تفسیر برای جدول ۶ نیز وجود دارد؛ اما شرکت‌های برق منطقه‌ای این جدول، کارا هستند و سعی در رسیدن به مرز کارایی مجازی را دارند. برای مثال، شرکت برق منطقه‌ای ۸ در جدول ۶، باید طول خطوط شبکه را به مقدار $0/01321$ کیلومتر، ظرفیت ترانسفورماتورها را به مقدار $0/001055$ مگاوات‌آمپر، تعداد کارکنان را 81 نفر و تلفات انتقال و توزیع را $0/191$ درصد کاهش داده و تعداد مشترکین $36352/14$ هزار نفر و انرژی تحویلی به مشترکین را $7580/16$ میلیون کیلووات ساعت افزایش دهد تا به مرز کارایی مجازی که دارای کمترین مقادیر از متغیرهای ورودی و بیشترین مقادیر از متغیرهای خروجی است، برسد.

مدل‌های NN-DEA در پژوهش‌هایی که تاکنون صورت گرفته است [۱۴، ۱۱، ۲۰، ۴۷، ۲۶، ۴۱، ۴۴، ۴۵]، قادر به الگوسازی برای واحدهای تصمیم‌ساز نبوده‌اند؛ اما در پژوهش حاضر این امر توسط الگوریتم ترکیبی PSOGA امکان‌پذیر شد. افزودن الگوسازی برای واحدهای کارا نیز از دیگر ویژگی‌های پژوهش حاضر است که تا به امروز برای مدل NN-DEA ممکن نبود؛ همچنین بهینه‌کردن شبکه NN-DEA برای نخستین بار در پژوهش حاضر صورت گرفته است که دارای سرعت بیشتر در همگرآشدن شبکه NN-DEA است.

با توجه به اینکه جمع‌آوری داده‌های شرکت‌های انتقال و توزیع برق منطقه‌ای توانیر به صورت دوماهه و حتی کمتر به روز می‌شوند، مدل ترکیبی بالا قادر خواهد بود با یک‌بار آموزش توسط داده‌های ۶ ساله موجود، شرایط جدید را ارزیابی کرده و مقادیر پیشنهادی را برای افزایش یا کاهش داده‌های طول خطوط شبکه (کیلومتر)، ظرفیت ترانسفورماتورها (مگاوات‌آمپر)، تعداد کارکنان (نفر)، تلفات انتقال و توزیع (درصد)، تعداد مشترکین (هزار نفر) و انرژی تحویلی به مشترکین (میلیون کیلووات ساعت) ارائه کند که این ویژگی تاکنون در هیچ یک از مدل‌های NN-DEA وجود نداشته است.

مدل ترکیبی جدید مبتنی بر تحلیل پوششی داده‌ها، شبکه عصبی مصنوعی و الگوریتم ژنتیک برای ارزیابی کارایی و الگوسازی شرکت‌هایی است که تعداد واحدهای تصمیم‌گیری در آن اندک باشد یا به عبارتی هر چه نسبت ۳ برابری مجموع تعداد خروجی‌ها و ورودی‌ها در جعبه

تحلیل پوششی داده‌ها از تعداد شرکت‌ها یا واحدهای تصمیم‌گیرنده بیشتر باشد، استفاده از مدل ارائه‌شده ارجحیت پیدا می‌کند؛ زیرا بعید به نظر می‌رسد مسئله‌ای بتوان یافت که ۹۰ واحد تصمیم‌گیری و مجموع ورودی و خروجی آن بیشتر از واحد ۳۰ باشد؛ اما در مسائلی از تحلیل پوششی داده‌ها با ۸ یا ۹ واحد تصمیم‌گیرنده راحت‌تر می‌توان نسبت تجربی یادشده را بر هم زد و مجموع ورودی و خروجی‌هایی بیشتر از ۸ یا ۹ واحد یافت.

۵. نتیجه‌گیری و پیشنهادها

رویکرد ترکیبی جدید مبتنی تحلیل پوششی داده‌ها، شبکه عصبی مصنوعی، الگوریتم ژنتیک و بهینه‌سازی انبوه ذرات برای ارزیابی کارایی و الگوسازی واحدهای کارا و ناکارا علاوه بر دارا بودن خصوصیات و قابلیت‌های مدل‌های کلاسیک تحلیل پوششی داده‌ها، ابزاری است که قابلیت‌های جدیدی از جمله در نظر گرفتن کارایی چند سال متوالی برای تخمین کارایی سال آخر، تأثیرپذیری بسیار کم نسبت به داده‌های دارای اغتشاش، ارائه الگو برای واحدهای ناکارا با در نظر گرفتن کارایی GANN-DEA و همچنین الگوسازی برای واحدهای کارا با در نظر گرفتن کارایی GANN-DEA را دارا است. مدل حاضر برای اندازه‌گیری کارایی و الگوسازی شرکت‌هایی طراحی شده است که دارای تعداد اندک واحدهای تصمیم‌گیرنده باشند. برای پژوهش‌های آتی پیشنهاد می‌شود شاخص بودجه توسعه شرکت‌ها و شاخص‌های آب‌وهوایی (رطوبت، میزان نمک و ریزگردها) برای طراحی مدلی مشابه پژوهش کنونی، پیشنهاد می‌شود.

منابع

1. Abd-El-Wahed, W., Mousa, A., & El-Shorbagy, M. (2011). Integrating particle swarm optimization with genetic algorithms for solving nonlinear optimization problems. *Journal of Computational and Applied Mathematics*, 235(5), 1446-1453.
2. Ajaly, Mehdi and Safari, Hossein. (2011). Performance Evaluation of Decision Making Units Using Hybrid Model of Predictive Neural Networks and Data Envelopment Analysis (Case Study: National Iranian Gas Company). *Journal of Industrial Engineering*, 45 (1), 13-29 (in Persian).
3. Alborzi, Mahmoud. (2014). Genetic Algorithm. Sharif University of Technology Scientific Publishing Institute: Tehran (in Persian).
4. Alborzi, Mahmoud. (2014). Neural Networks - Translated by R. Bill and T. Jackson. Sharif University of Technology Publications Institute: Tehran (in Persian).
5. Angeline, P. J. (1998). Using selection to improve particle swarm optimization. Paper presented at the Evolutionary Computation Proceedings, 1998. *IEEE World Congress on Computational Intelligence.*, The 1998 IEEE International Conference on.
6. Athanassopoulos, A. D., & Curram, S. P. (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(8), 1000-1016.
7. Azar, A., Daneshvar, M., Khodad Hosseini, S. H., & Azizi, Sh. (2012). Designing a Multilevel Performance Assessment Model: A Data Envelopment Analysis Approach. *Organizational Resource Management Research*, Volume 2 (3), 1-22 (in Persian).
8. Bagdadioglu, N., Price, C. M. W., & Weyman-Jones, T. G. (1996). Efficiency and ownership in electricity distribution: a non-parametric model of the Turkish experience. *Energy Economics*, 18(1-2), 1-23.
9. Bongo, M. F., Ocampo, L. A., Magallano, Y. A. D., Manaban, G. A., & Ramos, E. K. F. (2018). Input-output performance efficiency measurement of an electricity distribution utility using super-efficiency data envelopment analysis. *Soft Computing*. doi:10.1007/s00500-018-3007-2
10. Charnes, A., Cooper, W. W., & Rhodes, E. (1978). Measuring the efficiency of decision making units. *European Journal of Operational Research*, 2(6), 429-444.
11. Charnes, A., Cooper, W., Lewin, A., & Seiford, L. (1995). *Data Envelopment Analysis: Theory, Methodology and Applications*, Kluwer Publications.
12. Cook WD and Green RH. (2005). Evaluating power plant efficiency: a hierarchical model. *Computers & Operations Research*; 32, 813-823.
13. Costa, Á., & Markellos, R. N. (1997). Evaluating public transport efficiency with neural network models. *Transportation Research Part C: Emerging Technologies*, 5(5), 301-312.
14. Cullmann, A., & von Hirschhausen, C. (2008). Efficiency analysis of East European electricity distribution in transition: legacy of the past? *Journal of Productivity Analysis*, 29(2), 155.
15. De Jong, K. A. (1975). Analysis of the behavior of a class of genetic adaptive systems.
16. Debreu, G. (1951). The Coefficient of Resource Utilization, *Econometric*, 19, *Economics: Principles and Applications*: Zaria: AGTAB Publishers Ltd.

17. Dreyfus, G. (2005). *Neural networks: methodology and applications*: Springer Science & Business Media.
18. Eberhart, R., & Kennedy, J. (1995). *A new optimizer using particle swarm theory*. Paper presented at the Micro Machine and Human Science, 1995. MHS'95., Proceedings of the Sixth International Symposium on.
19. Emrouznejad, A., & Shale, E. (2009). A combined neural network and DEA for measuring efficiency of large scale datasets. *Computers & Industrial Engineering*, 56(1), 249-254.
20. Fallahi, M., & Ahmadi, V. (2005). Cost efficiency analysis of electricity distribution companies in Iran. *Journal of Economic Researches*, 71, 297-320.
21. Farrell, M. J. (1957). The measurement of productive efficiency. *Journal of the Royal Statistical Society. Series A (General)*, 120(3), 253-290.
22. Garg, H. (2016). A hybrid PSO-GA algorithm for constrained optimization problems. *Applied Mathematics and Computation*, 274, 292-305.
23. Goldberg, D. E., & Holland, J. H. (1988). Genetic algorithms and machine learning. *Machine learning*, 3(2), 95-99.
24. Goto, M., & Tsutsui, M. (2008). Technical efficiency and impacts of deregulation: An analysis of three functions in US electric power utilities during the period from 1992 through 2000. *Energy Economics*, 30(1), 15-38.
25. Hattori, T., Jamasb, T., & Pollitt, M. G. (2003). A comparison of UK and Japanese electricity distribution performance 1985-1998: lessons for incentive regulation.
26. Hess, B., & Cullmann, A. (2007). Efficiency analysis of East and West German electricity distribution companies—Do the “Ossis” really beat the “Wessis”? *Utilities Policy*, 15(3), 206-214.
27. Hjalmarsson, L., & Veiderpass, A. (1992). Efficiency and ownership in Swedish electricity retail distribution *International Applications of Productivity and Efficiency Analysis* (pp. 3-19): Springer.
28. Holland, J. (1975). Adaptation in natural and artificial systems: an introductory analysis with application to biology. *Control and artificial intelligence*.
29. Hosseini, Mirza Hassan (2012). Measuring Productivity Changes Using Data Envelopment Analysis and Malmquist Index in Power Generation Management Companies. *Industrial Management Perspective*, 2 (6), 150-129 (in Persian).
30. Kazemi, Mostafa., Fayezy Rad, Mohammad Ali (1979). Predicting Performance by Nonlinear Influence of Time Delay in Data Envelopment Analysis with Artificial Neural Networks. *Journal of Industrial Management*, 10 (1) 34-17 (in Persian).
31. Koopmans, T. C. (1951). Efficient allocation of resources. *Econometrica: Journal of the Econometric Society*, 455-465.
32. Li, J., Li, J., & Zheng, F. (2014). Unified efficiency measurement of electric power supply companies in China. *Sustainability*, 6(2), 779-793.
33. Mehregan, Mohammad Reza. (2012). *Quantitative Models in Organizational Performance Evaluation (Data Envelopment Analysis)*. Tehran: Tehran University School of Management Publications (in Persian).
34. Meibodi, A. E. (1998). *Efficiency considerations in the electricity supply industry: The case of Iran*: university of Surrey.
35. Menhaj, Mohammad Bagher. (2014). *Fundamentals of Neural Networks (Computational Intelligence)* Amirkabir University of Technology (Tehran Polytechnic) (in Persian).

36. Mostafa, M. M. (2009). Modeling the efficiency of top Arab banks: A DEA-neural network approach. *Expert systems with applications*, 36(1), 309-320.
37. Munakata, T. (1998). *Fundamentals of the new artificial intelligence (Vol. 2)*: Springer.
38. Russell, R. R. (1985). Measures of technical efficiency. *Journal of Economic Theory*, 35(1), 109-126.
39. Sadjadi, S., & Omrani, H. (2008). Data envelopment analysis with uncertain data: An application for Iranian electricity distribution companies. *Energy Policy*, 36(11), 4247-4254.
40. Salimi, Mehrdad. Karamati, Mohammad Ali. (2015). Evaluating and Analyzing the Technical Efficiency of Regional Electricity Companies of Iran with Three-Stage Data Envelopment Analysis Approach. *Quality and Productivity of Iranian Power Industry, Fourth Year (8)*, 37-48 (in Persian).
41. Samoilenko, S., & Osei-Bryson, K.-M. (2010). Determining sources of relative inefficiency in heterogeneous samples: Methodology using Cluster Analysis, DEA and Neural Networks. *European Journal of Operational Research*, 206(2), 479-487.
42. Shokrollahpour, E., Lotfi, F. H., & Zandieh, M. (2016). An integrated data envelopment analysis-artificial neural network approach for benchmarking of bank branches. *Journal of Industrial Engineering International*, 12(2), 137-143.
43. Soleimaniadena, R., Momeni, M., Mostafaei, A., and Rostami-M Khalifa, M. (2017). Development of a dynamic network data envelopment analysis model to evaluate the performance of banks. *Industrial Management Perspectives*, 25 (7), 67-89 (in Persian).
44. Toloei Eshlaghi, Abbas., Afshar Kazemi, Mohammad Ali. And Abbasi, Fatima. (2013) Evaluation of Insurance Companies' Performance Based on Integrated Balanced Scorecard Approach and Data Envelopment Analysis Technique and Providing Development Pathway for Inefficient Companies. *Journal of Business Management (17)*, 65-82 (in Persian).
45. Toloie-Eshlaghy, A., Alborzi, M., & Ghafari, B. (2012). Assessment of the personnel's efficiency with Neuro/DEA combined model.
46. Tone, K. (2001). A slacks-based measure of efficiency in data envelopment analysis. *European Journal of Operational Research*, 130(3), 498-509.
47. Wu, D. 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(1), 108-115.



پرویشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی

Designing a New Combined Model Based on Data Envelopment Analysis, Artificial Neural Network, Genetic Algorithm and Particle Swarm Optimization to Evaluate Efficiency and Benchmarking of Efficient and Inefficient Units

Mohammad Reza Mirzaei^{*}, Mohammad Ali Afshar Kazemi^{}, Abbas Toloie Eshlaghy^{***}.**

Astract

The main purpose of the present study is to design a new hybrid model based on data envelopment analysis, artificial neural network, genetic algorithm and particle swarm optimization to evaluate the efficiency and benchmarking of efficient and inefficient units. A two stage process has been used to evaluate the relative efficiency of 16 Tavanir regional power companies, using the combined model of data envelopment analysis with the neural network optimized by genetic algorithm and using a hybrid model of particle swarm optimization with genetic algorithm Benchmarking for efficient and inefficient units has been addressed. The average efficiency of regional power companies during the years 1391 to 1396 has increased from 0.8934 to 0.91477, while the regional power companies of Azerbaijan, Isfahan, Tehran, Khorasan, Semnan, Kerman, Gilan and Yazd have always had the highest average efficiency, And West and Fars regional electric companies with average values of 0.70747 and 0.60525 have the lowest efficiency during the years 1391 to 1396.

Keywords: Hybrid Particle Swarm Optimization - Genetic Algorithm; Benchmarking; Efficiency; Combined Model of Data Envelopment Analysis with Neural Network and Genetic.

Received: June 01, 2018, Accepted: August 28, 2019.

^{*}Ph.D. Candidate in Industrial Management & Operational Research, Department of industrial management, Central Tehran Branch, Islamic Azad University, Tehran, Iran.

^{**}Associate Prof., Department of industrial management, Central Tehran Branch, Islamic Azad University, Tehran, Iran (Corresponding Author)

Email: dr.mafshar@gmail.com

^{**}Prof., Department of industrial management, Science and Research Branch, Islamic Azad University, Tehran, Iran.