



پژوهش‌های نوین در تصمیم‌گیری

دوره ۸، شماره ۴، زمستان ۱۴۰۲، صص ۱۲۲-۱۴۶

نوع مقاله: پژوهشی

ارائه مدل ترکیبی تحلیل پوششی داده‌ها و شبکه عصبی مصنوعی جهت رتبه‌بندی کارایی شرکت‌های دارویی

مصطفی ابراهیم‌پور ازبری^{۱*}، آیدا فلاح‌پور مبارکی^۲

۱. دانشیار، گروه مدیریت، دانشکده مدیریت و اقتصاد، دانشگاه گیلان، گیلان، ایران

۲. دانشجوی دکتری مدیریت تولید و عملیات، گروه مدیریت، دانشکده مدیریت و اقتصاد، دانشگاه گیلان، گیلان، ایران

تاریخ پذیرش: ۱۴۰۱/۱۰/۰۱

تاریخ دریافت: ۱۴۰۲/۰۶/۱۹

چکیده

یکی از انواع مدل‌هایی که برای سنجش کارایی و پشتیبانی تصمیم استفاده می‌شود، تحلیل پوششی داده‌ها است. اما با توجه به تمام محاسن، کاستی‌هایی از جمله ضعف تفکیک‌پذیری واحدها، رتبه‌بندی متفاوت رویکردهای مختلف و حساسیت نسبت به داده‌های پرت نیز دارد که سبب ایده‌ی تلفیق آن با شبکه‌های عصبی مصنوعی شده است. شبکه عصبی به صورت فزاینده‌ای در رویکردهای مبتنی بر مدل و داده برای غنی‌سازی قابلیت‌های تحلیلی و پیش‌بینی و در نتیجه بهبود تصمیم‌گیری استفاده می‌شود. پژوهش حاضر یک مدل برای ارزیابی کارایی واحدها با تلفیق شبکه‌های عصبی ارائه می‌دهد. بخش مورد مطالعه، شرکت‌های دارویی فعال در اوراق بورس بهادار تهران است. ابتدا داده‌های هزینه، درآمد و سود شرکت‌های دارویی برای سال ۱۳۹۶ الی ۱۴۰۰ از سایت کدال جمع‌آوری و نرمال‌سازی شد. سپس برای ایجاد مدل، کارایی ۴ مدل بازده به مقیاس متغیر شامل مدل BCC ورودی‌محور و خروجی-محور، مدل SBM و مدل RAM تحلیل پوششی داده‌ها در طی سال‌های ۱۳۹۶ الی ۱۴۰۰ در گمز محاسبه شد و مقادیر کارایی این ۴ مدل به عنوان بردار آموزش و داده‌های هزینه، درآمد و سود سال ۱۳۹۶ الی ۱۴۰۰ به عنوان ورودی شبکه عصبی وارد متلب شد. برای تعمیم آموزش، از داده‌های سال ۱۴۰۱ استفاده شد. نتایج نشان داد که مرز کارایی آموزش داده شده شبکه حاصل ۴ مدل تحلیل پوششی داده‌ها، تقریب جامع‌تر و دقیق‌تری از کارایی را برای رتبه‌بندی شرکت‌های دارویی نشان می‌دهد. نتایج این پژوهش به شرکت‌های دارویی در زمینه‌های سرمایه‌گذاری، تخصیص منابع، پیش‌بینی نتایج سیاست‌ها و برنامه‌ریزی به صورت شفاف و دقیق‌تر کمک می‌کند.

کلیدواژه‌ها: تحلیل پوششی داده‌ها، شبکه عصبی مصنوعی، شرکت‌های دارویی، کارایی



۱- مقدمه و بیان مسئله

اغلب گفته می‌شود که صنایع داروسازی و بیوتکنولوژی که نشان دهنده دانش پیشرفته و فناوری اطلاعات هستند، بهترین چشم‌اندازها را برای رشد در قرن بیست و یکم دارند. با وجود این، شرکت‌های دارویی نیز با رقابت شدیدی روبرو هستند. از این رو بر به حداکثر رساندن کارایی آن‌ها تاکید شده است [۱]. سنجش کارایی واحدهای مشابه، نه تنها به شناسایی کاستی‌های واحد کمک می‌کند، بلکه با رفع یا به حداقل رساندن آن نواقص، به توسعه آن واحد نیز کمک می‌کند و در نتیجه کل کشور را توسعه می‌دهد [۳]. رویکردهای مختلفی در رابطه با اندازه‌گیری کارایی مطرح شده‌اند. این رویکردها در قالب دو رویکرد پارامتریک و ناپارامتریک طبقه‌بندی شده‌اند که تابع تولید مرز تصادفی (SFA)^۱ و تحلیل پوششی داده‌ها (DEA)^۲، به ترتیب شناخته شده‌ترین مدل‌های استفاده شده در این رویکرد است [۳]. دسته اول، روش‌های پارامتریک، تابع تولید مرز تصادفی، با اختلال‌های آماری نظیر متغیرهای تصادفی سازگاری دارد اما ضروری است که فرم تابعی و نوع توزیع برای آن در نظر گرفته شود که در تعیین رتبه کارایی واحدها تاثیرگذار است. دسته دوم یا روش‌های ناپارامتریک، تحلیل پوششی داده‌ها، نیاز به تابع تولید ندارند و عملکرد یک بنگاه یا واحد تصمیم گیرنده را با بهترین عملکرد بالفعل بنگاه‌های داخل آن صنعت بررسی می‌کنند [۴]. در مدل‌های DEA، ابتدا مجموعه امکان تولید با روش‌های برنامه‌ریزی خطی بدست آمده، سپس یک مرز کارایی و مجموعه‌ای از واحدهای ناکارا ایجاد می‌شوند [۵]. مدل‌های DEA، به بازده به مقیاس ثابت و بازده به مقیاس متغیر تقسیم می‌شوند. بازده به مقیاس متغیر به معنای این است که مدل نسبت به بازده به مقیاس ثابت پوشش فشرده‌تری از داده‌ها را در نظر می‌گیرد [۶]. اولین مدل‌ها در DEA مدل‌های CCR^۳ و BCC^۴ هستند که بازده هر واحد تصمیم به عنوان حداکثر نسبت خروجی وزن‌دار به ورودی‌های وزن‌دار به دست می‌آید، مشروط بر اینکه نسبت مشابه برای همه واحدهای تصمیم کمتر یا مساوی یک باشد. مدل RAM^۵، یکی دیگر از انواع مدل‌های تحلیل پوششی داده‌ها از انواع مدل‌های جمعی و غیرشعاعی می‌باشد [۷]. از مدل‌های توسعه یافته

^۱ Stochastic frontier analysis (SFA)

^۲ Data envelopment Analysis (DEA)

^۳ Charnes, Cooper and Rhodes (CCR)

^۴ Banker, Charnes and Cooper (BCC)

^۵ The range adjusted measure (RAM)



DEA، مدل^۱ SBM است که طی پژوهش‌هایی در سال ۲۰۰۱ منتشر شد. این مدل به طور مستقیم از متغیرهای کمکی استفاده می‌کند و بر کاهش ورودی‌ها و افزایش خروجی‌ها به طور همزمان تاکید دارد [۵]. علیرغم محبوبیت DEA، دارای کاستی‌هایی نیز است که استفاده از آن را محدود می‌کند [۸]. مرز کارایی در این مدل‌ها به عوامل پرت و تصادفی بسیار حساس است [۹]. اگر در داده‌ها مقادیر پرت وجود داشته باشد، می‌تواند موجب جابه‌جایی مرز کارایی بدست آمده شود و نتایج تحلیل پوششی داده‌ها را منحرف سازد [۵]. همچنین، هر بار که یک واحد تصمیم‌گیری جدید اضافه می‌شود، کل واحدهای تصمیم‌گیری باید مجدداً ارزیابی شوند که ممکن است تضاد ارزیابی جدیدی با ارزشیابی اولیه ایجاد کند. بنابراین، استفاده ساده از روش DEA برای ارزیابی کارایی در صورت افزایش واحد، باعث افزایش حجم کار می‌شود، به طور مکرر کارایی را تغییر می‌دهد و سردرگمی برای بخش مدیریت ایجاد می‌کند [۱۰]. رویکردهای کلاسیک DEA کارایی نسبی^۲ DMUها را تعیین می‌کنند، اما آن‌ها قادر به رتبه‌بندی تفکیک‌پذیر برای واحدهای کارآمد نیستند [۲]. اگر تعداد زیادی از واحدها به طور کارا (با امتیازی یکسان) طبقه‌بندی شوند، در نتیجه بین آن‌ها تفاوتی وجود نخواهد داشت، این مشکل در مدل‌های بازده به مقیاس متغیر معمولاً از واحدهای کارآمد در مدل بازده به مقیاس ثابت بیشتر است [۱۱]. بنابراین چندین محقق ترکیب شبکه‌های عصبی^۳ و تحلیل پوششی داده‌ها را پیشنهاد داده‌اند [۹]. شبکه‌های عصبی مصنوعی روش داده‌کاوی مناسبی برای موقعیت‌هایی است که در آن رابطه بین متغیرهای ورودی و خروجی ناشناخته است و زمانی که بیشتر از توضیح به پیش‌بینی نیاز است [۱۲]. شبکه‌های عصبی مصنوعی، به‌ویژه مدل شبکه عصبی پس انتشار^۴ (BPNN)، مجموعه‌های وزنی را جستجو می‌کنند تا بهترین تناسب را از طریق مجموعه داده‌های مشاهده شده شکل دهند [۸]. شبکه عصبی می‌تواند بر مشکل مرز موثر خطی DEA غلبه کند و از طریق آموزش و شبیه‌سازی، مرز موثر DEA را تقریب می‌زند. این مرز مؤثر صاف، پیوسته و ثابت است و می‌تواند در برابر مقادیر شدید تحمل بیشتری داشته باشد. هنگامی که یک واحد ارزیابی جدید برای مقایسه معرفی می‌شود، مرز موثر اصلی تحت تاثیر قرار نمی‌گیرد [۱۰]. مرز این روش، برخلاف مرز روش‌های

^۱ Slacks based measure (SBM)
^۲ decision-making units

^۳ Artificial Neural Networks
^۴ Backpropagation Neural Networks



ناپارامتریک، لزوماً قطعی نیست و بنابراین حساسیت این مرز کمتر از مرزهای ناپارامتریک است [۹].

شرکت‌های دارویی نقشی مهمی در سلامت و رفاه افراد جامعه دارند اما اهمیت اقتصادی این صنعت نیز بسیار مهم است زیرا آن‌ها در برخی از فعالیت‌های مشترک و در مراحل خاصی از زنجیره ارزش با یکدیگر رقابت می‌کنند. از این رو این شرکت‌ها باید تلاش کنند تا سطح بهره‌وری و کارایی خود را افزایش داده تا به یک دارایی استراتژیک تبدیل شود [۱۳]. برای اجرای موثر سیاست‌های ارتقا کارایی و بهره‌وری، ابتدا لازم است که سازمان به خوبی کارایی را بسنجد و اثرات سیاست‌های خود را بر آن مشاهده کند. ترکیب تحلیل پوششی داده‌ها و شبکه عصبی مصنوعی، با غلبه بر نقاط ضعف تحلیل پوششی داده‌ها از جمله عدم تفکیک پذیری واحدها [۱] [۱۱]، مرز با ثبات‌تری از کارایی را ارائه می‌دهد، اما حتی بعد غلبه بر نقاط ضعف آن، هر کدام از مدل‌های اشاره شده DEA، با توجه به ویژگی‌های خود، رتبه‌بندی متفاوتی از کارایی واحدها ارائه می‌دهند. کدام یک از مدل‌های DEA، کارایی را با دقت بیشتری تخمین می‌زنند؟ سازمان، اجرای سیاست‌های خود را بر مبنای کدام مدل DEA بگذارد؟ پژوهش‌هایی که تاکنون در زمینه ادغام تحلیل پوششی داده‌ها و شبکه‌های عصبی برای سنجش کارایی انجام شده است، رویکرد پیش‌بینی کارایی با یک مدل یا چند مدل بصورت قیاسی برای ترکیب شبکه عصبی مصنوعی با کارایی تحلیل پوششی داده‌ها را داشته‌اند. جواب این سوالات که در نهایت رتبه‌بندی واحدها برای کارایی بازده به مقیاس متغیر کدام است و مرز یکتا کارایی کدام است، نامشخص است. برای پاسخ به سوالات فوق و پر کردن این شکاف تحقیقاتی، در این پژوهش سعی شده است که با استفاده از مدل‌های بازده به مقیاس متغیر تحلیل پوششی داده‌ها از قبیل BCC ورودی‌محور، خروجی‌محور، مدل SBM و مدل RAM، کارایی واحدهای تصمیم‌گیرنده شبیه‌سازی شود. در این پژوهش سعی شده است که مدلی ترکیبی ارائه شود که تنها با آموزش شبکه با چندین بردار کارایی تحلیل پوششی داده‌ها در بازده به مقیاس متغیر، در نهایت مرز کارایی یکتایی از خروجی مدلی ترکیبی بدست آید. این مرز کارایی خروجی مدلی ترکیبی، مقادیر کارایی را با دقت و اطمینان بیشتر نشان می‌دهد و به تصمیم‌گیرنده دید روشنی در زمینه رتبه‌بندی واحدها می‌دهد.



۲- مبانی نظری و پیشینه پژوهش

۲-۱- تحلیل پوششی داده‌ها

انتشار مدل پایه‌ای تحلیل پوششی داده‌ها تحت عنوان مدل CCR توسط چارنز^۱ و همکاران (۱۹۷۸) به عنوان نقطه ظهور این تکنیک شناخته می‌شود [۱۴]. مدل BCC برخلاف مدل CCR که فرض بازده به مقیاس ثابت دارد، فرض بازده به مقیاس متغیر در نظر گرفته شده است. دوگان مدل BCC ورودی محور و خروجی محور در رابطه‌ی ۱ و ۲ نشان داده شده است [۱۵].

(۱)

$$\begin{aligned} \min z &= \theta \\ \text{s.t.} \quad & \sum_{j=1}^n \lambda_j x_{ij} - x_i \theta \leq 0 \quad i=1,2,\dots,m \\ & \sum_{j=1}^n \lambda_j y_r \geq y_r \quad r=1,2,\dots,s \\ & \sum_{j=1}^n \lambda_j = 1 \\ & \lambda_j \geq 0 \quad j=1,2,\dots,n \end{aligned}$$

(۲)

$$\begin{aligned} \max z &= \phi \\ \text{s.t.} \quad & \sum_{j=1}^n \lambda_j x_{ij} \leq x_i \quad i=1,2,\dots,m \\ & \sum_{j=1}^n \lambda_j y_{rj} - \phi y_r \geq 0 \quad r=1,2,\dots,s \\ & \sum_{j=1}^n \lambda_j = 1 \\ & \lambda_j \geq 0 \quad j=1,2,\dots,n \end{aligned}$$


^۱ Charnes



مدل RAM یکی از انواع مدل‌های تحلیل پوششی داده‌ها می‌باشد که برای اولین بار در سال ۱۹۹۹ ارائه شده است و از انواع مدل‌های جمعی و غیرشعاعی است که توانایی محاسبه کارایی را دارد [۷]. تون^۱ مدل SBM را گسترش داد که خروجی‌های غیرمنتظره را در نظر می‌گیرد. این مدل به طور موثر مشکل ارزیابی کارایی در خروجی نامطلوب را حل می‌کند. علاوه بر این، متعلق به مدل غیرشعاعی و غیر زاویه‌گرای مدل DEA است که از تاثیر ناشی از تفاوت بین انتخاب شعاعی اجتناب می‌کند [۱۶].

۲-۲- شبکه‌های عصبی

شبکه‌های عصبی را با اغماض زیاد می‌توان الگوهای الکترونیکی از ساختار عصبی مغز انسان نامید. مکانیسم فراگیری و آموزش مغز بر اساس تجربه استوار است. الگوی ریاضی نرون‌ها شبیه الگوی طبیعی است [۱۷]. مدل یک شبکه عصبی تک نرون با یک ورودی و چند ورودی در شکل ۱ نشان داده شده است. p و a به ترتیب ورودی و خروجی را نشان می‌دهد [۱۸].



شکل ۱. شبکه عصبی مصنوعی

در طراحی ساختار و معماری شبکه عصبی، تعداد عناصر بردار ورودی از صورت مسئله مورد بررسی مشخص شده و با انتخاب طراح نیست، ولی تعیین تعداد لایه‌ها، تعداد نرون‌های اولیه، نوع ارتباطات بین نرون‌ها، نوع تابع تبدیل و از این قبیل در انتخاب طراح است و بنابراین در شبکه‌های عصبی یک طراحی بهینه برای معماری شبکه ضروری به نظر می‌رسد [۱۸].

^۱ Tone



۲-۳- مدل تحلیل پوششی داده‌های عصبی

در این پژوهش، مدل ترکیبی از تحلیل پوششی داده‌ها و شبکه عصبی مصنوعی برای رتبه‌بندی کارایی شرکت‌های دارویی ارائه شده است. به این صورت که برای بدست آوردن یک مرز کارایی پیوسته در بازده به مقیاس متغیر، داده‌های کارایی چهار مدل تحلیل پوششی داده‌ها از جمله BCC و رودی‌محور، خروجی‌محور و مدل SBM و مدل RAM به عنوان بردار آموزشی به شبکه عصبی داده شد. سپس پس از آموزش شبکه عصبی مصنوعی، رتبه‌بندی یکتایی از بازده به مقیاس متغیر شرکت‌های دارویی بدست آمد. در ادامه به برخی از پژوهش‌های انجام شده در ارتباطات با ادبیات پژوهش اشاره شده است:

چانگ یه و همکاران^۱ (۲۰۲۴)، با استفاده از مدل ترکیبی تحلیل پوششی داده‌ها و شبکه عصبی مصنوعی به ارزیابی رویدادهای بزرگ ورزشی برای پیش‌بینی کارایی کشورهای شرکت کننده در بازی‌های آسیایی از سال ۱۹۹۹ الی ۲۰۲۳ پرداختند. یافته‌ها نشان داد که مدل ارائه شده برای تشخیص، برنامه‌ریزی، نظارت و بازنگری تاثیرات اقدامات اجرایی رویدادهای ورزشی با دقت بیشتر، کاربرد دارد [۱۹]. سان و سو^۲ (۲۰۲۳)، پژوهشی با هدف ارزیابی کارایی اکولوژی سبز کشاورزی برای توسعه پایدار و کاهش آلودگی ناشی از ضایعات کشاورزی انجام دادند. در این پژوهش، ابتدا یک سیستم شاخص ارزیابی مبتنی بر تئوری‌های کارایی اقتصاد سبز و رشد اقتصادی برای کارایی اکولوژی سبز اقتصادی ایجاد شد بعد با استفاده از تحلیل پوششی داده‌ها، کارایی کلی اکولوژی چین از ۲۰۰۲ تا ۲۰۲۱ بررسی شد. سپس شاخص‌های سیاست، مالی، ارتباطات، اجتماعی و سایر جنبه‌ها را برای ساخت مدل ترکیبی تحلیل پوششی داده‌ها و شبکه عصبی پس انتشار اضافه شد. نتایج این پژوهش نشان داد که از سال ۲۰۰۲ الی ۲۰۲۱، کارایی اکولوژی سبز، ۱۱/۷۸ درصد افزایش داشته است و در نهایت اثربخشی و دقت شبکه عصبی پس انتشار از طریق مقایسه با DEA تایید [۲۰]. ژونگ و همکاران^۳ (۲۰۲۱)، پژوهشی برای بررسی ابر کارایی بانک‌های روستایی چین انجام دادند. ابتدا با مدل SBM، کارایی برای ساخت مرز موثر نسبی داده‌ها استفاده شد. سپس با الگوریتم‌های یادگیری ماشین برای ساخت یک مدل رگرسیون و ایجاد یک مرز موثر مطلق استفاده شد. پس از مقایسه، شبکه عصبی پس

^۱ Chang Yeh et al
^۲ Sun and sui

^۳ Zhong et al



انتشار بهترین عملکرد را نشان داد و از این مدل برای پیش‌بینی و ارزیابی عملکرد پایدار بانک‌ها استفاده شد [۱۰]. ژو و همکاران^۱ (۲۰۲۱)، پژوهشی با هدف بررسی الگوریتم‌های یادگیری ماشین و تحلیل پوششی داده‌ها بصورت ترکیبی به اندازه‌گیری و پیش‌بینی کارایی شرکت‌های تولیدی چین پرداختند. در این پژوهش ۴ الگوریتم یادگیری ماشین از قبیل الگوریتم ژنتیک ادغام شده با شبکه عصبی مصنوعی، شبکه عصبی پس انتشار، ماشین بردار پشتیبان و ماشین بردار پشتیبان بهبود یافته با مدل CCR ترکیب شد و نتایج مدل‌ها با نمرات کارایی DEA در سال ۲۰۱۶ مقایسه شد. نتایج تجربی نشان داد که میانگین دقت کارایی پیش‌بینی حدود ۹۴ درصد است و عملکرد الگوریتم‌های ژنتیک ادغام شده با شبکه عصبی شامل شبکه عصبی پس انتشار، ماشین بردار پشتیبان بهبود یافته و ماشین بردار پشتیبان به ترتیب از خوب به ضعیف رتبه‌بندی شدند [۲۱]. شریفی و رضاییان^۲ (۲۰۱۶)، پژوهشی با استفاده از تحلیل پوششی داده‌ها عصبی جهت رتبه‌بندی ۲۵ پارک صنعتی استان مازندران انجام دادند. در این پژوهش با مدل CCR خروجی محور، کارایی واحدها در ۲۰۱۱-۲۰۱۲ بدست آمد و بعد از آموزش شبکه، پارک‌های صنعتی با توجه به داده‌های ۲۰۱۳-۲۰۱۲ و با توجه به قابلیت پیش‌بینی شبکه، رتبه‌بندی شدند [۲۲]. نمکین و همکاران (۱۴۰۰)، پژوهشی با هدف ارائه مدل ترکیبی از تحلیل پوششی داده و شبکه عصبی مصنوعی برای ارزیابی کارایی ۵۰۰ شعبه بانکی انجام دادند. نتایج نشان داد که مدل ارائه شده، دقت بالا و زمان محاسباتی کمتری دارد [۸]. در پژوهش دیگری، همایونفر و همکاران (۱۴۰۰)، یک رویکرد ترکیبی از تحلیل پوششی داده‌ها و شبکه عصبی مصنوعی برای ارزیابی عملکرد شرکت داروسازی ایران با استفاده از کارت‌های ارزیابی متوازن با فرض بازده به مقیاس ثابت و دیدگاه خروجی محور انجام دادند و با استفاده از الگوریتم شبکه عصبی به پیش‌بینی عملکرد پرداخته شد و خروجی شبکه با سایر الگوریتم‌های ماشین (الگوریتم درخت تصمیم، بیز ساده، ماشین بردار پشتیبان و k نزدیک‌ترین همسایه) مقایسه شد [۳]. کاظمی و فائزی‌راد (۱۳۹۶)، به کمک مدل SBM به ارزیابی کارایی واحدهای فولاد کشور پرداختند و خروجی آن را با آموزش به شبکه‌های عصبی با هدف پیش‌بینی کارایی در سال‌های آتی مقایسه کردند. پس از پیاده‌سازی ساختارهای مختلف از شبکه‌های عصبی، در نهایت یک شبکه عصبی بازگشتی با ده نورون در لایه پنهان با الگوریتم آموزش بیزی،

^۱ Zhu et al

^۲ Sharifi and Rezaeian



بهترین عملکرد را برای پیش‌بینی کارایی واحدها بدست آورد [۵]. اجلی و صفری (۱۳۹۰)، با اشاره به ضعف قدرت تفکیک پذیری واحدها در تحلیل پوششی داده‌ها، پژوهشی برای رتبه بندی شرکت‌های گاز ۲۳ استان با استفاده از مدل مضربی CCR و روش اندرسون-پیترسون (AP)^۱ و در نهایت ترکیب با شبکه‌های عصبی مصنوعی برای غلبه بر ضعف تحلیل پوششی داده‌ها انجام دادند و سپس با استفاده از مدل ترکیبی NN-DEA به پیش‌بینی عملکرد شرکت‌های گاز پرداختند. نتایج نشان داد که مدل، قدرت محاسبه و تفکیک-پذیری شرکت‌ها را از لحاظ کارایی دارد [۱۸].

۲-۳-۱- ساختار و معماری شبکه عصبی Neuro-DEA


در این پژوهش، از یک شبکه پرسپترون چند لایه^۲ (یک شبکه عصبی پیشخور)^۳ برای پیش‌بینی عملکرد واحدهای تصمیم‌گیرنده استفاده شده است تا به عنوان یک شبیه‌ساز بتواند عملکرد واحدها را در سال‌های آینده پیش‌بینی نماید. یک شبکه عصبی پیشخور به دلیل معماری ساده و موفقیت اثبات شده مدل برای حل مسائل تقریبی ترجیح داده می‌شود. این مدل شبکه شامل اجزای زیر است: لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی که به خروجی مورد نظر سیستم اشاره دارد [۱۲]. در مورد سایر معماری‌های مدل‌های شبکه عصبی مصنوعی، به عنوان مثال می‌توان به شبکه عصبی بازگشتی^۴ و یا کانولوشنی^۵ اشاره کرد. این مدل شبکه‌های عصبی برای بهبود دقت پیش‌بینی کوتاه‌مدت و بسیار کوتاه‌مدت استفاده می‌شوند. شبکه عصبی بازگشتی قادر به نگه داشتن حافظه بلندمدت و کوتاه‌مدت هستند تا روابط بین مقادیر را از سری زمانی استخراج کند و شبکه عصبی کانولوشنی قادر به یادگیری خودکار ویژگی‌ها هستند [۲۳]. از آنجایی که با توجه به هدف پژوهش، به ویژگی‌های شبکه عصبی مانند نگه داشتن حافظه یا توانایی یادگیری خودکار ویژگی‌ها نیازی نیست، از یک شبکه پرسپترون چند لایه استفاده می‌شود. توپولوژی شبکه عصبی پیشخور، یک شبکه ارسال چند سطحی است که از گره‌های سطح ورودی و گره‌های سطح خروجی، با حداقل یک گره لایه پنهان تشکیل شده است. در شبکه عصبی پیشخور، نورون‌های یک لایه به هم متصل نیستند و نورون‌های لایه‌های مجاور با وزن به هم متصل می‌شوند. هنگام ورود اطلاعات به شبکه عصبی پیشخور، داده‌ها

^۱ Anderson Peterson Method
^۲ Multilayer Perceptron (MLP)
^۳ Feedforward Neural Network

^۴ Recurrent Neural Network
^۵ Convolutional Neural Network



از گره سطح ورودی به گره سطح اول پنهان (نرون مصنوعی) منتقل می‌شود و سپس اطلاعات به قسمت پنهان بعدی منتقل می‌شود. اطلاعات یک لایه در یک زمان منتقل می‌شود و این کار ادامه می‌یابد تا در نهایت به سطح خروجی منتقل شود [۲۰]. همچنین لازم به ذکر است که کاربرد موفقیت‌آمیز شبکه عصبی پیشخور برای هر مشکلی به معماری شبکه مربوط می‌شود. تئوری مربوطه بیان می‌کند که شبکه‌های تنها با یک لایه پنهان می‌توانند نتایج دقیق‌تری ارائه دهند [۱۲]. در ساختار تک لایه، همه واحدها به یکدیگر متصل هستند که از قدرت محاسباتی بالقوه‌تری نسبت به ساختارهای چندلایه با ساختار سلسله‌مراتبی برخوردار است [۲۴]. یک شبکه پیشخور با یک لایه پنهان، یک شبکه با سه لایه شامل لایه ورودی، پنهان و یک لایه خروجی است. شبکه از این جهت پیشخور است که هیچ یک از وزن‌ها به واحد ورودی یا خروجی لایه قبلی باز نمی‌گردد. چنین شبکه‌ای به طور کامل متصل است زیرا هر واحد، مقداری ورودی به هر واحد در لایه بعدی اختصاص می‌دهد [۱۹]. معماری این شبکه در شکل ۲، نشان داده شده است [۱۸]. در ساختار شبکه‌های عصبی پیشخور، نورون‌ها در یک لایه پنهان، نقش مهمی در ارتباط غیرخطی بین متغیرهای ورودی و خروجی دارند، بنابراین الگوهای پیچیده را یاد می‌گیرند. تعداد لایه‌های پنهان و نورون‌ها به پیچیدگی الگوهای داده‌ها و سطح دقت مطلوب بستگی دارد، با این حال، ادبیات نشان می‌دهد که یک لایه پنهان در اکثر برنامه‌ها با تعداد متغیر نورون‌ها بسته به کاربردها کافی است [۸]. کارکرد شبکه مورد نظر تخمین تابع اندازه‌گیری کارایی و تعمیم آن برای سال‌های بعدی است. همچنین در موضوع تقریب‌ساز جهانی، نشان داده شده است که شبکه‌های پیشخور با یک لایه مخفی با توابع زیگموئیدی در لایه میانی و توابع تبدیل خطی، در لایه خروجی قادرند توابع مختلف را با هر درجه تقریب، تقریب بزنند زیرا توابع پیوسته فرض شده است [۱۸] [۳] [۲۵]. تعداد نورون‌های لایه ورودی و خروجی برابر با تعداد ورودی و بردار هدف است اما در مورد تعداد نورون‌های میانی نمی‌توان با قطعیت گفت که اگر کم باشد شبکه با مشکل مواجه خواهد شد و اگر زیاد باشد پیچیدگی محاسباتی خواهد داشت. تعداد نورون‌ها در لایه پنهان باید با استفاده از روش آزمون و خطا در طول آموزش مدل آزمایش شود [۲۵]. دلیل انتخاب تابع زیگموئیدی در لایه میانی قرار دادن خروجی نورون‌های میانی بین صفر و یک است. خطی‌سازی لایه خروجی نیز یک نگاهت یک به یک بین ورودی و خروجی نورون لایه آخر ایجاد می‌کند که کارایی را نشان می‌دهد [۱۸].



شکل ۲. شبکه پیشخور تک لایه

۲-۳-۲- الگوریتم یادگیری شبکه Neuro-DEA

پس از انتخاب معماری شبکه، نوبت انتخاب الگوریتم یادگیری شبکه است. در فرآیند یادگیری لایه‌های میانی یا لایه‌های پنهان اطلاعات دریافتی از لایه ورودی را پردازش کرده و روی لایه خروجی قرار می‌دهند. سه مرحله اصلی برای حل مسائل در شبکه‌های عصبی مصنوعی وجود دارد: آموزش، اعتبارسنجی و آزمایش. هر شبکه عصبی مصنوعی با گرفتن مثال‌ها یاد می‌گیرد. یادگیری شبکه زمانی اتفاق می‌افتد که وزن ارتباط بین لایه‌ها تغییر کند به طوری که تفاوت بین مقادیر پیش‌بینی شده و محاسبه شده کم باشد. با دستیابی به این شرایط، یادگیری کامل شده است. وزن‌ها حافظه و دانش کار را بیان می‌کنند. اعتبارسنجی توانایی شبکه را برای ارائه پاسخ معتبر برای ورودی‌های جدید که به مجموعه داده آموزشی تعلق ندارند نشان می‌دهد. همچنین آزمایش باعث بهبود عملکرد شبکه مذکور می‌شود [۹]. در این پژوهش از الگوریتم پس انتشار خطا که یک الگوریتم گرادیان کاهشی است برای آموزش شبکه استفاده شده است از انواع الگوریتم‌های پس انتشار خطا می‌توان به الگوریتم گرادیان مزدوج^۱ و الگوریتم لوبرت-مارکوارد^۲ اشاره کرد. این شبکه از داده‌های سال ۱۳۹۶ الی ۱۴۰۰ برای یادگیری استفاده کرده و الگوی یادگیری را بر اساس معماری شبکه و الگوریتم‌های یادگیری فرا می‌گیرد و با توجه به الگوهای یاد گرفته شده توان تعمیم آن برای داده‌های همان واحدها در سال‌های بعدی را دارد. در این مطالعه از داده‌های سال ۱۴۰۱ برای تعمیم آموزش استفاده شده است. خروجی

^۱ Conjugate Gradient

^۲ Levenberg – Marquardt



عددی بین صفر و یک است که مقادیر کارایی را نشان می‌دهد. داده‌های شبکه از ورودی‌ها و خروجی‌های واحدها تشکیل شده است. از یادگیری با ناظر استفاده می‌کند و بردار یادگیری آن کارایی‌هایی است که قبلاً با استفاده از گمز^۱ بدست آمده است. معیار خطایی تعریف شده که با کمینه کردن آن، مقدار بهینه شبکه (وزن‌های سیناپسی) بدست می‌آید (mse). وقتی که شبکه الگو را یاد گرفت می‌توان از آن به عنوان یک ابزار محاسباتی برای پیش‌بینی کارایی در سال‌های آتی استفاده کرد. با توجه به ادبیات، اکثر مطالعات الگوریتم‌های خود را با استفاده از بیش از ۷۰ درصد داده‌های قابل دسترس آموزش دادند. ۳۰ درصد باقی‌مانده از داده‌ها به طور مساوی بین اعتبارسنجی و مجموعه‌های آزمایشی تقسیم می‌شود [۲۵]. در این پژوهش نیز، داده‌ها به صورت تصادفی در متلب^۲، برای آموزش ۷۰ درصد و ۳۰ درصد مساوی بین اعتبارسنجی و آزمایش تقسیم شدند.

۳- روش تحقیق

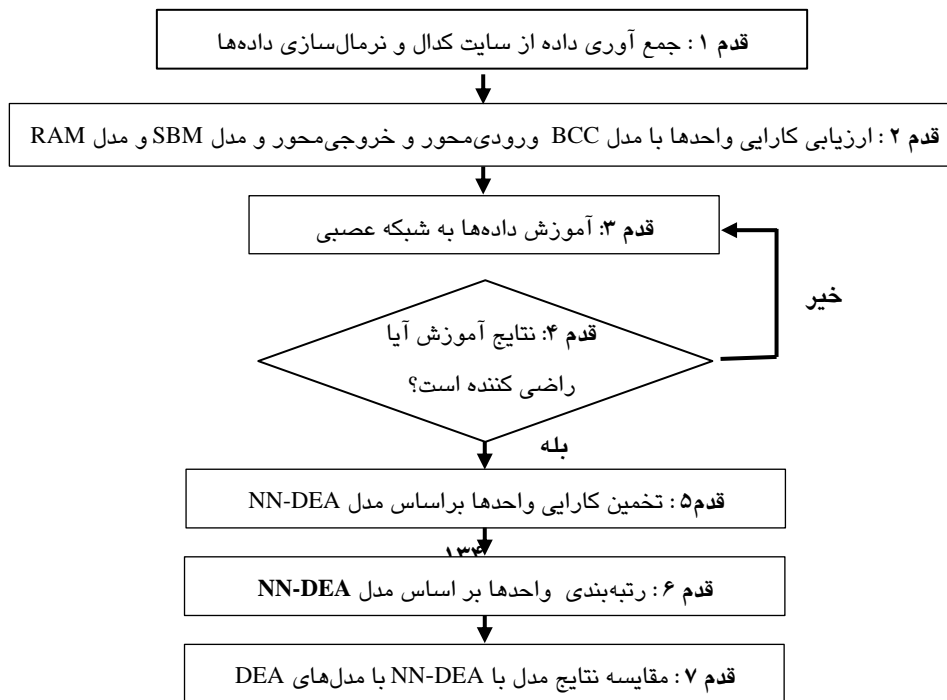
هدف از انجام این پژوهش، رتبه‌بندی شرکت‌های دارویی با استفاده از مدل تلفیقی تحلیل پوششی داده‌ها و شبکه‌های عصبی مصنوعی از لحاظ کارایی یکتا بازده به مقیاس متغیر است. جامعه آماری پژوهش، شرکت‌های دارویی فعال در سازمان بورس اوراق بهادار تهران است. محدودیت‌های زیر جهت همگن‌سازی داده‌ها لحاظ شده است: (۱) شرکت‌های مورد بررسی تکنیکی و تولیدی، عضو بورس باشند یعنی در فرابورس یا در انتظار بورس نباشند. (۲) اطلاعات کامل و تفصیلی صورت‌های مالی سالانه هر یک از شرکت‌ها همراه با سود خالص و هزینه‌ها در سال‌های ۱۳۹۶ الی ۱۴۰۱ موجود باشد. شرکت‌های دارویی نقش مهمی در سلامت و رفاه افراد دارند. این موضوع امروزه اهمیت ویژه‌ای دارد. همانطور که همه‌گیری کووید-۱۹ نشان داده است، هیچ کشوری از ظهور بیماری‌های جدید مصون نیست [۲۵]. چنین احتمالی، اهمیت بررسی و ارتقا کارایی شرکت‌های دارویی را به عنوان معیاری برای افزایش سرمایه‌گذاری در این بخش نشان می‌دهد. در این پژوهش مدل ارائه شده از لحاظ ریاضی توسعه داده شده است. برای ارائه مدل ترکیبی، ابتدا داده‌های شرکت‌های دارویی از سایت کدال اوراق بورس بهادار تهران جمع‌آوری شد. سه مدل هزینه که بیشترین نقش را در میزان خروجی‌های شرکت‌های

^۱ GAMS

^۲ MATLAB



دارویی داشتند اعم از هزینه دستمزد، هزینه استهلاک و هزینه مواد مستقیم انتخاب شدند و خروجی‌های پژوهش برای بررسی کارایی اقتصادی با توجه به رقابت بین شرکت‌های دارویی، درآمد و سود خالص سازمان در نظر گرفته شد. سپس داده‌ها بین صفر و یک نرمال‌سازی و استاندارد شدند. بعد از نرمال‌سازی داده‌ها، کارایی واحدها با توجه به مدل‌های انتخاب شده تحلیل پوششی داده‌ها از جمله BCC ورودی‌محور، خروجی‌محور، مدل SBM و مدل RAM در نرم‌افزار گمز محاسبه شد. مقادیر ورودی و خروجی تحلیل پوششی داده‌ها سال ۱۳۹۶ الی ۱۴۰۰ (هزینه دستمزد، هزینه استهلاک، هزینه مواد مستقیم، درآمد و سود خالص) به عنوان ورودی‌های شبکه به ترتیب وارد نرم‌افزار متلب شد و مقدار کارایی بدست آمده از نرم‌افزار گمز برای سال‌های مختلف به عنوان بردار خروجی و آموزشی شبکه وارد شد. در قدم بعدی عملکرد آموزش شبکه بررسی شد، همچنین تعداد نورون‌های لایه پنهان در این قسمت با توجه به نحوه عملکرد شبکه تعیین شد. بعد از رسیدن به مقدار خطای کمینه آموزش شبکه، داده‌های ورودی و خروجی سال ۱۴۰۱ شامل هزینه دستمزد، هزینه مواد مستقیم، درآمد و سود خالص سال ۱۴۰۱ برای تعمیم آموزش وارد شبکه شد. بعد از اجرای مدل، برداری از کارایی برای ۳۰ شرکت دارویی بدست آمد که کارایی بدست آمده، کارایی واحدها در بازده به مقیاس متغیر است و این کارایی، عملکرد واحدها را با دقت بیشتری و رتبه‌بندی واحدی نشان می‌دهد. روند پیشبرد این پژوهش در شکل ۳ منعکس شده است.



شکل ۳. چارچوب پیشبرد روند پژوهش



۴- یافته‌های پژوهش

۴-۱- گام اول: جمع‌آوری داده

هزینه‌های مواد مستقیم، هزینه حقوق و هزینه استهلاک برای ورودی و درآمد و سود خالص برای خروجی شرکت‌های داروسازی از بورس اوراق بهادار تهران از کدال برای سال‌های ۱۳۹۶ الی ۱۴۰۱ جمع‌آوری شد. جامعه آماری پژوهش شامل ۳۰ شرکت دارویی می‌باشد. قبل از ورود به گام دوم، داده‌های جمع‌آوری شده با استفاده از روش نرمال‌سازی لاروس^۱ در فاصله (۱، ۰) استانداردسازی شدند. رابطه ۳، روش نرمال‌سازی داده‌های لاروس را نشان می‌دهد [۳]. اما جهت ارایه، آمار کاربردی و خلاصه داده‌ها برای ورودی هزینه دستمزد هر واحد (میانگین، میانه و انحراف معیار) در جدول ۱ تا سه رقم اعشار ارائه شده است. سایر آمار کاربردی داده‌ها و جزییات داده‌ها در پیوست قرا داده شده است.

(۳)

$$X = x \times m + b$$

$$m = \frac{H - L}{\max(x)L + \min(x)H}$$

$$b = \frac{\max(x)L + \min(x)H}{\max(x) - \min(x)}$$

جدول ۱. خلاصه آماری متغیر هزینه دستمزد سال‌های ۱۳۹۶ الی ۱۴۰۱

DMU	میانگین	میانه	انحراف معیار	DMU	میانگین	میانه	انحراف معیار
۱	۰.۱۸۴	۰.۱۷۹	۰.۰۲۴	۱۶	۰.۲۵۵	۰.۲۴۱	۰.۰۵۰
۲	۰.۲۴۲	۰.۲۴۰	۰.۰۵۸	۱۷	۰.۲۱۴	۰.۲۱۵	۰.۰۲۳
۳	۰.۲۰۰	۰.۱۹۸	۰.۰۲۲	۱۸	۰.۱۱۰	۰.۱۰۴	۰.۰۲۰
۴	۰.۲۹۶	۰.۲۹۴	۰.۰۲۳	۱۹	۰.۰۶۴	۰.۰۶۳	۰.۰۰۸
۵	۰.۱۲۵	۰.۱۲۳	۰.۰۱۵	۲۰	۰.۱۶۵	۰.۱۵۲	۰.۰۵۲
۶	۰.۱۲۴	۰.۱۲۱	۰.۰۱۳	۲۱	۰.۰۸۱	۰.۰۸۱	۰.۰۱۳
۷	۰.۰۳۵	۰.۰۲۲	۰.۰۱۴	۲۲	۰.۰۹۱	۰.۰۹۶	۰.۰۳۴

^۱Larose



انحراف معیار	میانه	میانگین	DMU	انحراف معیار	میانه	میانگین	DMU
۰.۰۷۲	۰.۱۸۷	۰.۱۵۰	۲۳	۰.۰۱۶	۱.۰۲۲	۱.۰۲۳	۸
۰.۰۳۱	۰.۱۱۴	۰.۱۲۳	۲۴	۰.۳۰۷	۰.۲۶۴	۰.۴۰۱	۹
۰.۰۲۹	۰.۱۱۵	۰.۱۲۸	۲۵	۰.۰۳۵	۰.۲۶۱	۰.۲۹۶	۱۰
۰.۰۴۱	۰.۲۲۲	۰.۲۳۹	۲۶	۰.۰۳۳	۰.۰۸۳	۰.۰۸۷	۱۱
۰.۰۳۸	۰.۲۰۴	۰.۲۱۶	۲۷	۰.۰۲۰	۰.۱۵۹	۰.۱۶۶	۱۲
۰.۰۳۷	۰.۲۱۴	۰.۲۱۸	۲۸	۰.۰۶۹	۰.۵۴۸	۰.۵۶۹	۱۳
۰.۰۲۲	۰.۲۰۶	۰.۲۱۳	۲۹	۰.۰۱۲	۰.۰۵۳	۰.۰۵۸	۱۴
۰.۰۲۰	۰.۱۳۱	۰.۱۳۴	۳۰	۰.۰۱۹	۰.۱۲۳	۰.۱۲۷	۱۵

۴-۲- گام دوم: ارزیابی مقدار کارایی واحدها

مقادیر کارایی واحدها با استفاده از نرم‌افزار گمز در سال‌های ۱۳۹۶ الی ۱۴۰۰ بدست آمد. جدول ۲ و ۳، مقادیر کارایی را تا سه رقم اعشار برای سال ۱۳۹۶ و ۱۳۹۷ نشان می‌دهد که همانطور که در جدول مشاهده می‌شود نمی‌توان به یک رتبه‌بندی واحد رسید. داده‌های کارایی سال‌های ۱۳۹۸، ۱۳۹۹ و ۱۴۰۰ در پیوست آورده شده است. همچنین با اینکه از روش‌های مختلفی برای رتبه‌بندی واحدها و حل مشکل عدم قدرت تفکیک پذیری واحدها وجود دارد، هر کدام ایرادات خود را دارند. به عنوان نمونه، روش اندرسون-پیترسون (AP) یکی از روش‌های رتبه‌بندی است. در ارزیابی به این روش واحد تحت بررسی از ارزیابی حذف می‌شود و این باعث می‌شود عدد اختصاص یافته واحدهای کارا در این مدل بزرگتر مساوی ۱ شود [۲۶]. با توجه به کاستی‌های اشاره شده در مورد تحلیل پوششی داده‌ها و اشاره به این موضوع که مهم‌ترین عنصر تصمیم‌گیری، اطلاعات مناسب است. اطلاعاتی که بتواند آینده بهتر را ترسیم کند، منجر به تصمیم‌گیری‌های بهتر خواهد شد. با ادغام مدل‌های مختلف تحلیل پوششی داده‌ها با شبکه عصبی مصنوعی می‌توان، مقدار کارایی قابل اطمینان‌تری را بدست آورد.

جدول ۲. کارایی سال ۱۳۹۶ و ۱۳۹۷ (۱۵ واحد اول)

۱۳۹۷	BCC-in	BCC-out	SBM	RAM	۱۳۹۶	BCC-in	BCC-out	SBM	RAM
۱	۰.۷۹۷	۰.۷۶۳	۱	۰.۳۱۶	۱	۱	۱	۱	۱
۲	۱	۱	۱	۱	۲	۰.۷۴۴	۰.۷۹۰	۱	۰.۴۲۷
۳	۱	۱	۱	۱	۳	۰.۸۷۵	۰.۸۵۹	۰.۷۳۸	۰.۷۹۲



۱۳۹۷	BCC-in	BCC-out	SBM	RAM	۱۳۹۶	BCC-in	BCC-out	SBM	RAM
۴	۰.۸۶۸	۰.۸۹۱	۰.۷۲۱	۰.۷۶۲	۴	۰.۸۳۱	۰.۸۳۵	۰.۶۹۳	۰.۷۶۴
۵	۰.۸۵۷	۰.۷۹۴	۰.۷۰۳	۰.۷۳۰	۵	۰.۷۸۴	۰.۷۷۰	۰.۷۱۸	۰.۷۶۷
۶	۰.۸۹۷	۰.۷۹۹	۰.۵۸۳	۰.۶۸۱	۶	۰.۸۷۰	۰.۸۴۵	۰.۷۰۴	۰.۸۵۰
۷	۱	۱	۱	۱	۷	۱	۱	۱	۱
۸	۱	۱	۱	۱	۸	۱	۱	۱	۱
۹	۱	۱	۱	۱	۹	۰.۹۰۹	۰.۹۵۰	۱	۰.۵۷۵
۱۰	۱	۱	۱	۱	۱۰	۱	۱	۱	۱
۱۱	۰.۶۷۵	۰.۶۰۵	۰.۵۱۱	۰.۵۴۴	۱۱	۱	۱	۱	۱
۱۲	۰.۹۰۰	۰.۹۰۰	۰.۸۶۱	۰.۹۱۳	۱۲	۰.۸۰۳	۰.۸۹۵	۰.۴۱۵	۰.۶۹۴
۱۳	۱	۱	۰.۹۲۱	۱	۱۳	۱	۱	۰.۹۷۸	۱
۱۴	۱	۱	۰.۸۰۱	۱	۱۴	۰.۷۹۹	۰.۷۷۵	۰.۷۰۱	۰.۸۲۲
۱۵	۱	۱	۱	۱	۱۵	۱	۱	۱	۱


جدول ۳. کارایی سال ۱۳۹۶ و ۱۳۹۷ (۱۵ واحد دوم)

۱۳۹۷	BCC-in	BCC-out	SBM	RAM	۱۳۹۶	BCC-in	BCC-out	SBM	RAM
۱۶	۰.۸۲۲	۰.۸۵۶	۰.۸۰۰	۰.۸۳۷	۱۶	۰.۸۸۹	۰.۹۲۵	۰.۸۱۲	۰.۸۵۱
۱۷	۰.۹۴۹	۰.۹۵۰	۰.۹۱۰	۰.۹۰۴	۱۷	۱	۱	۰.۹۹۲	۱
۱۸	۰.۷۱۶	۰.۶۰۵	۰.۴۵۲	۰.۵۷۵	۱۸	۰.۷۹۹	۰.۷۶۳	۰.۶۳۵	۰.۷۸۶
۱۹	۰.۹۵۰	۰.۶۹۳	۰.۵۲۰	۰.۷۲۹	۱۹	۱	۱	۰.۸۸۰	۱
۲۰	۱	۱	۰.۹۳۸	۱	۲۰	۰.۶۸۷	۰.۶۶۶	۰.۸۹۶	۰.۴۴۵
۲۱	۰.۸۹۶	۰.۷۶۴	۰.۶۱۹	۰.۷۴۱	۲۱	۰.۹۸۱	۰.۹۴۹	۰.۸۷۰	۰.۹۷۱
۲۲	۰.۹۳۷	۰.۶۵۵	۰.۴۸۳	۰.۶۷۲	۲۲	۰.۸۷۶	۰.۷۳۷	۰.۶۵۴	۰.۸۳۵
۲۳	۰.۶۰۱	۰.۵۸۱	۰.۴۵۵	۰.۴۲۸	۲۳	۰.۶۴۵	۰.۶۱۹	۰.۵۰۹	۰.۶۳۰
۲۴	۰.۶۳۸	۰.۳۰۲	۱	۰.۴۷۲	۲۴	۰.۶۶۴	۰.۶۲۹	۰.۵۶۵	۰.۷۳۷
۲۵	۱	۱	۱	۱	۲۵	۰.۶۰۵	۰.۷۷۴	۰.۵۳۳	۰.۶۱۱
۲۶	۱	۱	۱	۱	۲۶	۱	۱	۱	۱
۲۷	۰.۷۶۱	۰.۷۴۱	۰.۶۷۵	۰.۵۱۱	۲۷	۰.۴۶۱	۰.۶۵۶	۰.۳۷۳	۰.۵۳۶
۲۸	۱	۱	۱	۱	۲۸	۰.۹۵۵	۰.۹۵۳	۰.۸۷۳	۰.۸۶۹
۲۹	۰.۷۹۲	۰.۷۵۱	۰.۷۱۴	۰.۵۸۵	۲۹	۰.۸۳۸	۰.۸۲۱	۰.۶۷۴	۰.۸۰۶
۳۰	۱	۱	۱	۱	۳۰	۱	۱	۱	۱



۳-۴- گام سوم: آموزش شبکه عصبی

شبکه مدل پیشخور شبکه عصبی با یک لایه پنهان در این پژوهش در نظر گرفته شده است. بر طبق، بردارهای ورودی و خروجی واحدهای تصمیم گیرنده و هدف بردار کارایی BCC ورودی محور و خروجی محور، مدل SBM و مدل RAM، شبکه آموزش داده شد. شکل ۳ مدل شبکه عصبی را از خروجی متلب نشان می‌دهد.



شکل ۳. معماری شبکه عصبی مصنوعی پژوهش


۴-۴- گام چهارم: نتایج آموزش آیا راضی کننده است؟

در آخر تعداد نورون‌های لایه پنهان با توجه به مقدار خطای کمتر و همگرایی بیشتر میان آزمایش، آموزش و اعتبارسنجی آن مشخص شدند. تقسیم داده‌های آموزش، اعتبارسنجی و آزمایش به صورت تصادفی با نسبت ۷۰ ۱۵ ۱۵ انتخاب شد. نورون‌های لایه پنهان با آزمون و خطا، ۳۰ نورون تعیین شد. هر دو الگوریتم پس انتشار خطا، الگوریتم گرادیان مزدوج و الگوریتم لونیتر-مارکوارد برای آموزش شبکه، عملکرد آن‌ها بررسی شد و در تعداد نورون-های متفاوت، الگوریتم گرادیان مزدوج نتایج بهتری را ارائه داد. شکل ۴ نتیجه آموزش شبکه، شکل ۵ عملکرد شبکه بر مبنای میانگین مجذور خطا و شکل ۶، مقدار پراکندگی داده‌ها را در خروجی متلب نشان می‌دهد.

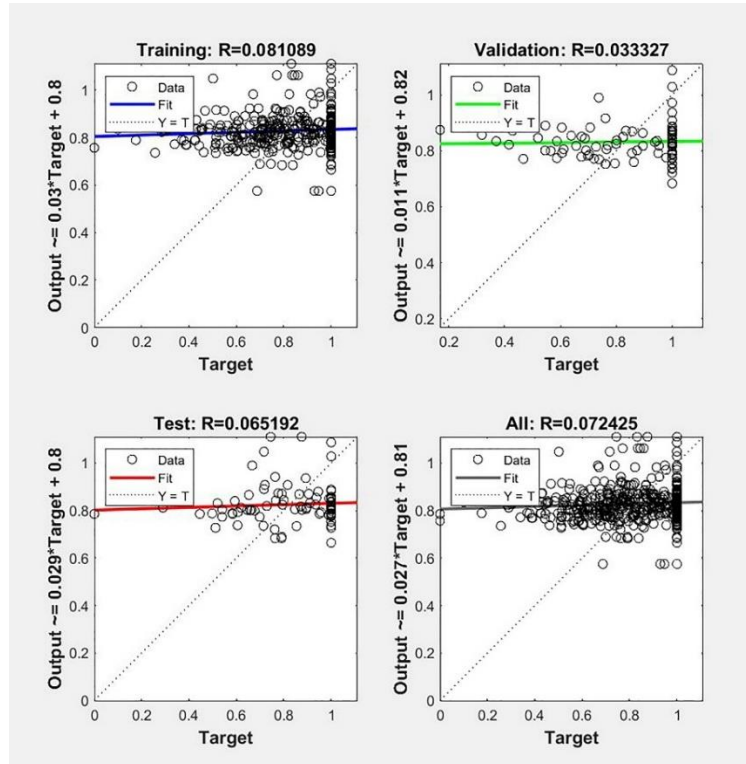


Progress			
Epoch:	0	17 iterations	1000
Time:		0:00:00	
Performance:	0.951	0.0405	0.00
Gradient:	3.09	0.0156	1.00e-066
Validation Checks:	0	6	6

شکل ۴. نتیجه آموزش شبکه



شکل ۵. عملکرد شبکه بر مبنای میانگین مجذور خطا



شکل ۶. پراکندگی داده‌ها

۴-۵- گام پنجم، شش و هفتم: تخمین کارایی بر اساس مدل و رتبه‌بندی واحدها و مقایسه آن‌ها

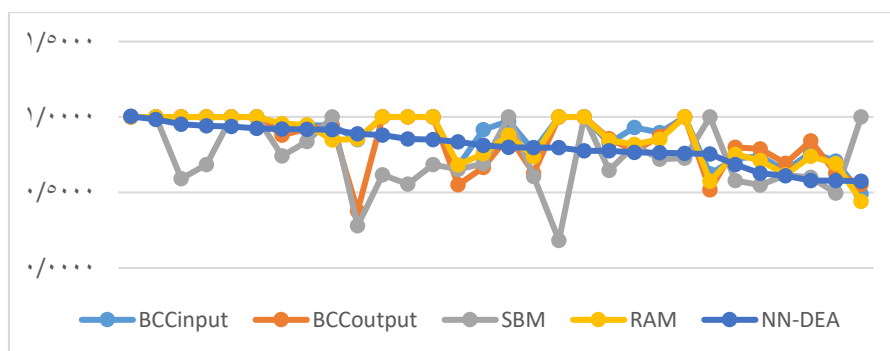
باتوجه به آموزش داده شده به شبکه عصبی، شبکه کارایی واحدها در سال ۱۴۰۱ مربوطه تخمین زد. کارایی بدست آمده، کارایی ترکیب ۴ مدل تحلیل پوششی داده‌ها را نشان می‌دهد. جدول ۳ رتبه‌بندی کارایی نهایی شرکت‌های دارویی را تا سه رقم اعشار نشان می‌دهد. شکل ۶ مقایسه کارایی شبکه عصبی تلفیقی برای بازده به مقیاس متغیر با کارایی موارد استخراج شده از تحلیل پوششی داده‌ها را در سال ۱۴۰۱ نشان می‌دهد. همانطور که مشاهده می‌شود مرز کارایی بدست آمده در بازده به مقیاس متغیر واحدها، یک خط پیوسته و ثابت از کارایی



را برخلاف رویکردهای مختلف تحلیل پوششی داده‌ها نشان می‌دهد. با توجه به شکل ۶، بر مبنای جامعه آماری پژوهش، شرکت ۲ بهترین کارایی و شرکت ۳ ضعیف‌ترین کارایی را نشان می‌دهد.

جدول ۴. رتبه‌بندی کارایی واحدها

رتبه	DMU	NN-DEA	رتبه	DMU	NN-DEA
۱	شرکت ۲	۰.۹۷۳	۱۶	شرکت ۱۰	۰.۸۲۳
۲	شرکت ۱۳	۰.۹۴۴	۱۷	شرکت ۱۸	۰.۸۰۳
۳	شرکت ۹	۰.۹۳۷	۱۸	شرکت ۲۰	۰.۸۰۴
۴	شرکت ۵	۰.۸۹۹	۱۹	شرکت ۱	۰.۸۰۲
۵	شرکت ۲۸	۰.۸۹۴	۲۰	شرکت ۱۹	۰.۸۰۰
۶	شرکت ۲۳	۰.۸۷۶	۲۱	شرکت ۲۲	۰.۷۹۷
۷	شرکت ۳۰	۰.۸۶۷	۲۲	شرکت ۱۱	۰.۷۹۶
۸	شرکت ۱۲	۰.۸۶۳	۲۳	شرکت ۱۷	۰.۷۹۴
۹	شرکت ۲۶	۰.۸۶۲	۲۴	شرکت ۱۴	۰.۷۸۶
۱۰	شرکت ۲۹	۰.۸۵۷	۲۵	شرکت ۱۵	۰.۷۷۵
۱۱	شرکت ۲۵	۰.۸۵۶	۲۶	شرکت ۶	۰.۷۶۷
۱۲	شرکت ۴	۰.۸۵۴	۲۷	شرکت ۷	۰.۷۶۶
۱۳	شرکت ۲۷	۰.۸۵۴	۲۸	شرکت ۸	۰.۷۶۲
۱۴	شرکت ۱۶	۰.۸۲۹	۲۹	شرکت ۲۱	۰.۷۵۰
۱۵	شرکت ۲۴	۰.۸۲۶	۳۰	شرکت ۳	۰.۷۳۸



شکل ۷. مرز کارایی NN-DEA در مقایسه با تحلیل پوششی داده‌ها چهار مدل



۵- نتیجه‌گیری و پیشنهادات

یکی از موارد مورد توجه سازمان‌ها مبحث کارایی است که در این پژوهش به آن پرداخته شد. در این پژوهش، مدل ترکیبی از تحلیل پوششی داده‌ها و شبکه عصبی مصنوعی برای رتبه‌بندی کارایی شرکت‌های دارویی ارائه شد. مدل ارائه شده بدین شرح بود که برای بدست آوردن مرز یکتایی از کارایی واحدها و یک رتبه‌بندی واحد، داده‌های کارایی ۴ مدل تحلیل پوششی داده‌ها (BCC ورودی‌محور، خروجی‌محور، مدل SBM و مدل RAM) به عنوان بردار آموزشی و داده‌های مربوط به هزینه‌ها، سود و درآمد شرکت‌های دارویی به عنوان داده‌های ورودی به شبکه داده شد. نتایج پژوهش نشان داد که کارایی تخمین زده شده توسط شبکه، مرز پیوسته و تفکیک‌پذیری از واحدها را نشان می‌دهد. با توجه به شکل ۶ به عنوان نمونه، شرکت ۳۰ (رتبه ۷) با مدل BCC ورودی‌محور، کارایی ۰.۹۳۳۹، با مدل BCC خروجی‌محور کارایی ۰.۸۸۰۸، با مدل SBM مقدار کارایی ۰.۷۴۱۱ و با مدل RAM کارایی ۰.۹۵۶۵ است. در هنگام رتبه‌بندی سایر واحدها در کنار شرکت ۳۰، به کدام آمار و رتبه‌بندی کارایی می‌توان اکتفا کرد؟ شرکت دارویی ۳۰، برای ارزیابی و اعمال سیاست‌های بهره‌وری یا کارایی خود در رتبه‌بندی‌های متفاوت کنار سایر شرکت‌ها، کدام خط کارایی را باید در نظر بگیرد؟ در این پژوهش نشان داده شده است که با توجه به خاصیت شبکه‌های عصبی مصنوعی و قدرت تعمیم‌یادگیری آن، می‌توان به مرز یکتایی از کارایی در نتیجه به رتبه‌بندی واحدی از شرکت-های دارویی رسید. پژوهش‌هایی که تاکنون در ارتباط با ادبیات پژوهش انجام شده‌اند که بخشی از آن در قسمت بررسی پیشینه پژوهش اشاره شد، فاقد این نوآوری بوده‌اند. بسیاری از آن‌ها فقط مدل‌های ترکیبی از تحلیل پوششی داده‌ها و یادگیری عمیق اجرا کرده‌اند که یا شامل انواع مدل‌های هوش مصنوعی و یک مدل از تحلیل پوششی داده‌ها بود یا شامل یک یا دو مدل از تحلیل پوششی داده‌ها و ترکیب آن با شبکه عصبی مصنوعی بوده است. نتایج این پژوهش رتبه‌بندی دقیق‌تری از کارایی را ارائه می‌دهد. استفاده از این رتبه‌بندی برای شرکت‌های دارویی به شرح زیر می‌تواند مفید باشد:

شرکت‌های دارویی سرمایه‌گذاری زیادی در بخش تحقیق و توسعه خود انجام می‌دهند. استفاده از اطلاعات و رتبه‌بندی صحیحی از کارایی از این حیث می‌تواند ارزشمند باشد که به جذب سرمایه‌گذاران خارجی، با ارزیابی و انتخاب شرکت‌های دارویی مناسب سرمایه‌گذاری



بر پایه تحلیل درست، کمک کند. همچنین خود مدیران شرکت‌های دارویی برای بررسی نحوه تخصیص منابع و بررسی تأثیرات تصمیمات سرمایه‌گذاری یا تغییرات مدیریتی آن‌ها بر کارایی می‌تواند مفید باشد. به عنوان یک مثال ساده، شرکت ۱۹، اگر هدفش برای سال آینده اعمال سیاست افزایش صادرات یا سرمایه‌گذاری در بخش ظرفیت تولید باشد، نتیجه اعمال سیاست آن بر کارایی با توجه به کدام مدل می‌تواند صحیح باشد؟ مدل ارائه شده در بازده به مقیاس متغیر این امکان را فراهم می‌کند که رتبه‌بندی دقیق‌تری در شرایط واقعی محیط، ارائه دهد و ریسک سازمان را کاهش دهد. همچنین با انتخاب ورودی‌های متفاوت و بررسی نتایج مختلف در رتبه‌بندی‌های متفاوت اما یکتا و ارزشمندتر، سازمان می‌تواند علت ناکارا بودن خود و بخش ناکارای سازمان خود را شناسایی و اصلاح کند یا میزان سرمایه‌گذاری خود را در بخش‌های مختلف بهینه کند. ارزیابی صحیح کارایی و در نتیجه رتبه‌بندی نزدیک به واقعیت محیطی، به بودجه‌بندی بخش‌های مختلف سازمان نیز کمک می‌کند. سازمان با بررسی مقدار مختلف ورودی و خروجی و تأثیر آن بر کارایی خود در مقایسه با سایر رقیبان، برنامه‌ریزی با کارایی بهتری داشته باشد. در نتیجه این امر، نظارت بر امور سازمانی تقویت شده و اصلاح و بازنگری در سیاست‌ها بهتر انجام می‌گیرد. این موضوع به عنوان مثال می‌تواند در جلوگیری از راه-اندازی پروژه‌هایی که به شکست و زیان منجر می‌شود کمک کند.

پیشنهاد می‌شود در این زمینه مطالعات بیشتری انجام شود و به غیر مدل‌های بررسی شده در این پژوهش، با مدل‌های بیشتری مرز کارایی تخمین زده شود یا از مدل‌های بدون ورودی استفاده شود. پیشنهاد می‌شود این موضوع در بخش زنجیره‌تامین نیز تحلیل شود.

۶- منابع

- [۱] You, T., Chen, X., & Holder, M. E. "Efficiency and its determinants in pharmaceutical industries: ownership, R&D and scale economy". *Applied Economics*, ۴۲(۱۷), ۲۰۱۰, ۲۲۱۷-۲۲۴۱. <https://doi.org/10.1080/00036840701765445>
- [۲] Panwar, A., Olfati, M., Pant, M., & Snasel, V. "A Review on the ۴۰ Years of Existence of Data Envelopment Analysis Models: Historic Development and Current Trends". *Archives of Computational Methods in Engineering*, ۲۰۲۲, ۱-۳۰. <https://doi.org/10.1007/s11831-022-09770-3>



- [۳] Homayounfar M, Salahi F, Daneshvar A, Khatami Firouzabadi S M A. "Applying a Hybrid DEA-ANN Approach in Evaluation of Balanced Efficiency of the Tehran Stock Exchange Pharmaceutical Companies"; ۱۸ (۳). jor ۲۰۲۱ :۷۳-۹۲ URL: <http://jamlu.liau.ac.ir/article-۱-۱۹۰۸-fa.html> [in Persian]
- [۴] Taghavifard, M. T., Amiri, M., & Mozafari, R. "Measuring the Managerial Efficiency of Bank Branches: A Three-Stage DEA Analysis (In Melli Bank of Iran)". *Modern Research in Decision Making*, 2(۱), ۲۰۱۷, ۵۱-۷۲. [in Persian]
- [۵] Kazemi, M., & Faezrad, M. "Efficiency Estimation using Nonlinear Influences of Time Lags in DEA Using Artificial Neural Networks". *Industrial Management Journal*, ۱۰(۱), ۲۰۱۸. ۱۷-۳۴. doi: ۱۰.۲۲۰۵۹/imj.۲۰۱۸,۱۲۹۱۹۲,۱۰۰۶۸۹۸ [in Persian]
- [۶] Mohebbi, H., azar, A., Heidari, A., & Khadivar, A. "Designing a Mathematical Model for Optimum Assignment in the Two-stage Green Supply Chain using Network Data Envelopment Analysis and Electrical Circuits". *Industrial Management Studies*, ۱۷(۵۴), ۲۰۱۹, ۱-۲۳. [https://doi: ۱۰,۲۲۰۵۴/jims.۲۰۱۹,۴۲۹۶,۱۱۵۲](https://doi.org/10.22054/jims.2019,4296,1152) [in Persian]
- [۷] Ramzaniyan, M. R., Yakideh, K., & Mohammadi Bazghaleh, N. "Providing an Appropriate Model for Improving Multi-Criteria Inventory Classification Using SBM Model (Case Study: Pars Khazar Industrial Company)". *Industrial Management Journal*, ۱۲(۳), ۲۰۲۰, ۴۸۵-۵۰۱. [https://doi.org/10,22059/imj. ۲۰۲۱,۲۸۸۹۴۳,۱۰۰۷۶۵۲](https://doi.org/10.22059/imj.2021,288943,1007652)
- [۸] Kwon, H. B., Lee, J., & Roh, J. J. " Best performance modeling using complementary DEA-ANN approach: Application to Japanese electronics manufacturing firms". *Benchmarking: an international journal*, ۲۳(۳), ۲۰۱۶, ۷۰۴-۷۲۱. [https://doi.org/10,1108/BIJ-09-2014-0083](https://doi.org/10.1108/BIJ-09-2014-0083)
- [۹] Namakin, A., Najafi, S. E., Fallah, M., & Javadi, M. "A New Hybrid Methodology Based on Data Envelopment Analysis and Neural Network for Optimization of Performance Evaluation". *International Journal of Industrial Mathematics*, ۱۳(۴), ۲۰۲۱. ۳۹۵-۴۰۹. <https://dorl.net/dor/http://dorl.net/dor/20,1001,1,20080621,2021,13,3,4,1>
- [۱۰] Zhong, K., Wang, Y., Pei, J., Tang, S., & Han, Z. "Super efficiency SBM-DEA and neural network for performance evaluation". *Information Processing & Management*, ۵۸(۶), ۲۰۲۱, ۱۰۲۷۲۸. [https://doi.org/10,1016/j.ipm.۲۰۲۱,۱۰۲۷۲۸](https://doi.org/10.1016/j.ipm.2021,102728)
- [۱۱] mansouri, E., & fazli, L. "Providing a model based on input efficiency profile model to evaluate the performance quality of higher education centers". *Modern Research in Decision Making*, ۶(۳), ۲۰۲۱, ۱۸۹-۲۱۳. <https://dorl.net/dor/20,1001,1,24766291,1400,6,3,8,0> [in Persian]
- [۱۲] Tsolas, I. E., Charles, V., & Gherman, T. "Supporting better practice benchmarking: A DEA-ANN approach to bank branch performance



- assessment". *Expert Systems with Applications*, ۱۶۰, ۲۰۲۰, ۱۱۳۵۹۹. <https://doi.org/10.1016/j.eswa.2020.113599>
- [۱۳] Díaz, R. F., & Sanchez-Robles, B. "Non-parametric analysis of efficiency: An application to the pharmaceutical industry". *Mathematics*, ۸(۹), ۲۰۲۰, ۱۵۲۲. <https://doi.org/10.3390/math8091522>
- [۱۴]omid, A., Azar, A., Dehghan Nayeri, M., Moghbel, A. "Developing a network Data Envelopment Analysis approach to compare the environmental efficiency of active industries in Tehran". *Management Research in Iran*, ۲۵(۳), ۲۰۲۱, ۱۹۳-۲۱۶. <https://dorl.net/dor/20.1001.1.2322200.1400.25.3.8.2> [in Persian]
- [۱۵] Montazeri, J., Yazdani, R., & Kaviani, M. "Analysis of Relationship between the Performance and Efficiency Based on CCR And BCC Models in the Iranian Insurance Industry: Tobit's Approach". *Innovation Management and Operational Strategies, I(1)*, ۲۰۲۰, ۵۷-۷۲. <https://dorl.net/dor/20.1001.1.27821345.1399.1.1.5.4> [in Persian]
- [۱۶] Zhang, Z., Xiao, Y., & Niu, H. "DEA and Machine Learning for Performance Prediction". *Mathematics*, ۱۰(۱۰), ۲۰۲۲. ۱۷۷۶. <https://doi.org/10.3390/math10101776>
- [۱۷] Ramezani, M., Ramezanzpour, E., & Pourbakhsh, H. "New Approaches in Forecasting Using Neuro-Fuzzy Networks (Case Study: The Crude Oil Price)". *Management Research in Iran*, ۱۵(۳), ۲۰۲۱, ۱۴۹-۱۶۹. <https://dorl.net/dor/20.1001.1.2322200.1390.15.3.7.1> [in Persian]
- [۱۸] Ajalli, M., & Safari, H., "Analysis of th Technical Efficiency of the Decision making use of the synthetic model of performance predictor neural networks, and data envelopment analysis (Case study: GAS national co. of IRAN)". *Advances in industrial engineering (Jornal of Industrial Engineering*, ۴۵(۱), ۲۰۱۱), pp ۱۳-۲۹. <https://sid.ir/paper/166389/en> [in Persian]
- [۱۹] Yeh, C. C., Peng, H. T., & Lin, W. B. "Achievement Prediction and Performance Assessment System for Nations in the Asian Games". *Applied Sciences*, ۱۴(۲), ۲۰۲۴, ۷۸۹. <https://doi.org/10.3390/app14020789>
- [۲۰] Sun, Q., & Sui, Y. J. "Agricultural Green Ecological Efficiency Evaluation Using BP Neural Network-DEA Model". *Systems*, ۱۱(۶), ۲۰۲۳, ۲۹۱. <https://doi.org/10.3390/systems11060291>
- [۲۱] Zhu, N., Zhu, C., & Emrouznejad, A. "A combined machine learning algorithms and DEA method for measuring and predicting the efficiency of Chinese manufacturing listed companies". *Journal of Management Science and Engineering*, 6(۴), ۲۰۲۱, ۴۳۵-۴۴۸. <https://doi.org/10.1016/j.jmse.2020.10.001>
- [۲۲] Sharifi, M., & Rezaeian, J. "Efficiency evaluation of Mazandaran Industrial parks by using neuro-DEA approach". *International Journal of Industrial and Systems Engineering*, ۲۳(۱), ۲۰۱۶, ۱۱۱-۱۲۳. <https://doi.org/10.1504/IJISE.2016.070803>



- [۲۳] [Eskandari, H., Imani, M., & Parsa Moghadam, M.](#), "Short-Term Load Forecasting By Learning Load Characteristics Using Deep Convolutional and Recurrent Networks". ELECTRONIC INDUSTRIES, ۱۲(۲), ۲۰۲۱, ۳۵-۴۶. SID. <https://sid.ir/paper/۹۵۳۱۱۴/en> [in Persian]
- [۲۴] S. Sreekumar S.S. Mahapatra, "Performance modeling of Indian business schools: a DEA-neural network approach", Benchmarking: An International Journal, Vol. ۱۸ Iss ۲, ۲۰۱۱, pp. ۲۲۱ - ۲۳۹. <http://dx.doi.org/۱۰.۱۱۰۸/۱۴۶۳۵۷۷۱۱۱۱۲۱۶۸۵>
- [۲۵] Jauhar, S. K., Zolfagharinia, H., & Amin, S. H. "A DEA-ANN-based analytical framework to assess and predict the efficiency of Canadian universities in a service supply chain context". Benchmarking: An International Journal. ۲۰۲۲. <https://doi.org/۱۰.۱۱۰۸/BIJ-۰۸-۲۰۲۱-۰۴۵۸>
- [۲۶] Banihashemi, S. A., & Najafi, S. S. "Introducing the new development approach of DEA and TOPSIS for performance rating (Case study of cement companies listed on the stock exchange)". Journal of Quality Engineering and Management, ۷(۱), ۲۰۱۷. ۶۹-۸۱. <https://dorl.net/dor/۲۰.۱۰۰۱.۱.۲۳۲۲۱۳۰۵.۱۳۹۶.۷.۱.۶.۱> [in Persian]