



ارزیابی و پیش‌بینی کارایی شرکت‌های صنعتی با استفاده از مدل ترکیبی تحلیل پوششی داده‌ها و شبکه عصبی مصنوعی

شهناز محمدی مجد

استادیار ریاضی، واحد سنجند، دانشگاه آزاد اسلامی، سنجند، ایران

Email: shahnaz.m.majd@iau.ir

تاریخ دریافت: ۱۴۰۳/۱۱/۱۳ * تاریخ پذیرش: ۱۴۰۴/۰۱/۳۱

چکیده

در این مقاله، یک مدل ترکیبی مبتنی بر تحلیل پوششی داده‌ها (DEA) و شبکه‌های عصبی مصنوعی (ANN) برای ارزیابی و پیش‌بینی کارایی ۵۰ شرکت صنعتی فعال در بخش‌های مختلف ارائه شده است. در ابتدا، با استفاده از روش DEA، کارایی نسبی شرکت‌ها محاسبه شده و واحدهای تصمیم‌گیرنده کارا و ناکارا شناسایی گردیدند. سپس، نتایج به‌دست‌آمده از DEA به‌عنوان داده‌های هدف برای آموزش شبکه عصبی مصنوعی (ANN) استفاده شد. این مدل ANN با کشف الگوهای پنهان در داده‌ها، قادر به پیش‌بینی عملکرد آینده شرکت‌ها با دقت بالا بود. نتایج نشان می‌دهند که مدل ترکیبی DEA-ANN نه تنها امکان ارزیابی دقیق کارایی شرکت‌ها را در زمان حال فراهم می‌کند، بلکه توانایی پیش‌بینی تغییرات کارایی را در صورت تغییر ورودی‌ها نیز داراست. علاوه بر این، با استفاده از شبکه عصبی، می‌توان کارایی شرکت‌هایی که به‌طور مستقیم مورد ارزیابی قرار نگرفته‌اند را پیش‌بینی کرد. این رویکرد با ترکیب توانمندی‌های DEA در تحلیل کارایی و قابلیت‌های ANN در مدل‌سازی روابط غیرخطی، ابزاری کارآمد برای مدیران و تصمیم‌گیرندگان جهت بهبود عملکرد و تخصیص بهینه منابع به شمار می‌آید.

کلمات کلیدی: ارزیابی کارایی، پیش‌بینی عملکرد، تحلیل پوششی داده‌ها، شبکه عصبی مصنوعی، مدل ترکیبی.

۱- مقدمه

امروزه، در صنایع مختلف، تصمیم‌گیری در مورد تخصیص منابع و ارتقای بهره‌وری به داده‌ها و اطلاعات دقیق در مورد عملکرد شرکت‌ها وابسته است. از این رو ارزیابی^۱ عملکرد سازمان‌ها و شرکت‌ها به‌ویژه در صنایع رقابتی، به یکی از مهم‌ترین دغدغه‌های مدیران و سیاست‌گذاران تبدیل شده است. اندازه‌گیری کارایی^۲، ابزاری قدرتمند برای شناسایی نقاط قوت و ضعف، بهینه‌سازی منابع، و ارتقای عملکرد است. در این راستا، تحلیل پوششی داده‌ها^۳ (DEA) به‌عنوان یکی از روش‌های محبوب و مؤثر در ارزیابی عملکرد سازمان‌ها شناخته شده است. این روش توانایی اندازه‌گیری کارایی نسبی واحدهای تصمیم‌گیرنده^۴ (DMUs) را بر اساس ورودی‌ها و خروجی‌های چندگانه دارد. با توجه به ماهیت پیچیده داده‌های ورودی و خروجی در این حوزه، استفاده از روش‌های تحلیلی که قابلیت ترکیب قدرت مدلسازی خطی و غیرخطی را داشته باشند، ضروری است. روش تحلیل پوششی داده‌ها با وجود کارایی بالا محدودیت‌هایی از قبیل، حساسیت به داده‌های غیرعادی و عدم توانایی در پیش‌بینی دقیق رفتار و عملکرد واحدهای تصمیم‌گیرنده دارد.

برای غلبه بر این چالش‌ها، در سال‌های اخیر استفاده از شبکه‌های عصبی مصنوعی^۵ (ANN) به‌عنوان مکمل روش‌های سنتی DEA پیشنهاد شده است. روش‌های مبتنی بر یادگیری ماشین، به‌ویژه شبکه‌های عصبی به‌دلیل قابلیت یادگیری و تعمیم، علاوه بر اینکه می‌توانند این نقاط ضعف تحلیل پوششی داده‌ها را پوشش و تحلیل‌های دقیق‌تری ارائه دهند امکان پیش‌بینی عملکرد واحدها را با دقت بالا فراهم می‌کنند. ترکیب این دو روش، یعنی مدل ترکیبی^۶ DEA-ANN، نه تنها امکان ارزیابی دقیق‌تر کارایی واحدها را فراهم می‌کند، بلکه می‌تواند به شناسایی الگوها و عوامل مؤثر بر کارایی نیز کمک کند. تحقیقات پیشین نشان می‌دهند که روش DEA به‌طور گسترده‌ای در ارزیابی عملکرد شرکت‌ها و سازمان‌ها استفاده شده است. برای مثال، مطالعاتی در صنایع بانکی، تولیدی، بهداشت و درمان، نشان داده‌اند که این روش می‌تواند کارایی نسبی واحدها را با دقت مناسبی محاسبه کند. از سوی دیگر، روش‌های مبتنی بر شبکه‌های عصبی مصنوعی نیز به‌عنوان ابزاری برای پیش‌بینی و مدلسازی رفتارهای پیچیده معرفی شده‌اند. با این حال، تحقیقات کمتری به بررسی ترکیب این دو روش پرداخته‌اند. پژوهش حاضر با تکیه بر این خلأ تحقیقاتی، به توسعه یک مدل جهت ارزیابی و پیش‌بینی کارایی می‌پردازد. این پژوهش با هدف طراحی و پیاده‌سازی یک مدل مبتنی بر DEA و ANN انجام شده است که توانایی ارزیابی عملکرد شرکت‌های صنعتی یا تولیدی با استفاده از چند ورودی (مانند سرمایه‌گذاری، نیروی انسانی، هزینه‌ها) و چند خروجی (مانند سود خالص، فروش و بازده سرمایه) را دارد و تلاشی است برای ارتقای دقت، کارایی و قابلیت پیش‌بینی در ارزیابی عملکرد واحدهای صنعتی که می‌تواند الگویی برای سایر بخش‌ها و صنایع ارائه دهد.

۲- روش شناسی پژوهش

در دهه‌های اخیر، ارزیابی و بهینه‌سازی عملکرد واحدهای تصمیم‌گیرنده (DMUs) در صنایع مختلف به یکی از چالش‌های اصلی مدیران تبدیل شده است. ابزارهای متنوعی برای اندازه‌گیری و ارزیابی کارایی در این حوزه به‌کار گرفته شده‌اند. دو رویکرد برجسته در این زمینه تحلیل پوششی داده‌ها (DEA) و شبکه‌های عصبی مصنوعی (ANN) هستند که به‌طور گسترده‌ای در تحقیقات و کاربردهای عملی برای ارزیابی کارایی و پیش‌بینی عملکرد استفاده می‌شوند. در این بخش، پیشینه‌های مربوط به این دو روش و ترکیب آن‌ها برای ارزیابی و پیش‌بینی کارایی بررسی خواهد شد.

الف) پیشینه تحلیل پوششی داده‌ها

¹. Evaluation

². Efficiency

³. Data Envelopment Analysis

⁴. Decision Making Units

⁵. Artificial Neural Networks

⁶. Hybrid Model

تحلیل پوششی داده ها (DEA) نخستین بار توسط چارنس، کوپر و رودس معرفی شد (Charnes, Cooper & Rhodes, 1978). DEA یک روش غیرپارامتری برای ارزیابی کارایی واحدهای تصمیم گیرنده است که از ورودی ها و خروجی های متعدد برای اندازه گیری کارایی نسبی واحدها استفاده می کند. این روش، بدون نیاز به تعریف روابط خاص بین ورودی ها و خروجی ها، از برنامه ریزی خطی برای محاسبه مرز کارایی استفاده می کند همچنین قادر است واحدهای تصمیم گیرنده با ورودی ها و خروجی های مختلف را مقایسه کرده و عملکرد آن ها را در مقایسه با یک مرز کارا ارزیابی کند. در مدل های DEA، واحدهای کارا به عنوان واحدهایی شناخته می شوند که نسبت به دیگر واحدها کارایی بالاتری دارند، و واحدهای ناکارا به طور مستقیم نسبت به واحدهای کارا ارزیابی می شوند. مهم ترین مدل های DEA شامل مدل های CCR^۷ و BCC^۸ هستند. مدل CCR فرض می کند که واحدها بازده به مقیاس ثابت دارند، در حالی که مدل BCC بازدهی به مقیاس متغیر را مفروض می داند. استفاده از DEA در صنایع مختلف مانند بانکداری، سلامت، آموزش و تولید مورد توجه بسیاری از پژوهشگران قرار گرفته است (Emrouznejad and Yang, 2018).

در مقاله ای جامع به بررسی پیشرفت های اخیر در کاربرد DEA در صنایع مختلف پرداختند و کاربردهای آن را در بانکداری، بهداشت، انرژی و آموزش بررسی کردند. این پژوهش نشان می دهد که DEA توانسته است ابزاری مفید برای ارزیابی کارایی در سازمان های مختلف باشد. با این حال، از آنجایی که DEA به طور عمده روشی ایستا است، قادر به تحلیل شرایط پویا و پیش بینی عملکرد در شرایط تغییرات ورودی و خروجی نیست.

(ب) پیشینه شبکه های عصبی مصنوعی (ANN)

شبکه های عصبی مصنوعی (ANN) از دهه ۱۹۴۰ میلادی به عنوان روشی برای شبیه سازی فرآیندهای یادگیری و پردازش اطلاعات مغز انسان مطرح شدند. الگوریتم های ANN با یادگیری از داده های ورودی و خروجی، توانایی مدل سازی روابط پیچیده و غیرخطی بین این داده ها را دارند. این روش ها به ویژه در تحلیل داده های پیچیده و پیش بینی عملکرد در شرایط متغیر بسیار مفید هستند. یکی از مهم ترین الگوریتم های ANN، پس انتشار^۹ است که توسط (Rumelhart, Hinton & Williams, 1986) معرفی شد. این الگوریتم به شبکه عصبی این امکان را می دهد که با استفاده از داده های آموزشی و محاسبه خطای پیش بینی، وزن های اتصالات شبکه را به طور بهینه تنظیم کند. این ویژگی به ANN اجازه می دهد که روابط پیچیده میان ورودی ها و خروجی ها را به طور مؤثری شبیه سازی کند. شبکه های عصبی در زمینه های مختلفی مانند پیش بینی، طبقه بندی و شبیه سازی دینامیک سیستم ها به کار گرفته می شوند. برای مثال، (Jin, Li & Hu, 2016) از شبکه عصبی برای پیش بینی کارایی بیمارستان ها با استفاده از داده های مختلف مانند تعداد پزشکان، پرستاران و تجهیزات پزشکی بهره بردند و نشان دادند که این مدل می تواند عملکرد بیمارستان ها را با دقت بالاتری پیش بینی کند. با این حال، یکی از چالش های اصلی ANN، نیاز به داده های زیاد و دقیق برای آموزش مدل است. همچنین، مدل های ANN، به ویژه در شبکه های عمیق^{۱۰}، دارای ساختار پیچیده ای هستند که ممکن است تحلیل و تفسیر نتایج را برای پژوهشگران دشوار سازد.

(ج) پیشینه ترکیب DEA و ANN

ترکیب DEA و ANN به عنوان یک رویکرد نوین در ارزیابی و پیش بینی کارایی واحدهای تصمیم گیرنده در تحقیقات اخیر مورد توجه قرار گرفته است. هدف این ترکیب، استفاده از مزایای هر دو روش و رفع محدودیت های آن ها است. در مدل ترکیبی، DEA به عنوان گام نخست برای ارزیابی کارایی واحدها و شناسایی واحدهای ناکارا به کار می رود، سپس نتایج حاصل از DEA به عنوان داده های آموزشی به شبکه عصبی مصنوعی داده می شود. شبکه عصبی با یادگیری از این داده ها، می تواند روابط پیچیده و غیرخطی میان ورودی ها و خروجی ها را مدل سازی کرده و پیش بینی های دقیق تری ارائه دهد.

در مطالعه ای مدل ترکیبی DEA-ANN را برای ارزیابی عملکرد سازمان ها پیشنهاد کردند. این تحقیق نشان داد که استفاده از مدل ترکیبی باعث افزایش دقت پیش بینی ها نسبت به مدل های منفرد DEA و ANN می شود. در این مدل، ابتدا از DEA

7. Charnes, Cooper, and Rhodes

8. Banker, Charnes, and Cooper

9. Backpropagation

10. Deep Networks

برای اندازه‌گیری کارایی استفاده شده و سپس نتایج آن به‌عنوان ورودی به شبکه عصبی وارد می‌شود تا پیش‌بینی‌های دقیق‌تری انجام شود. (Wang, Zhu, & Chu, 2011)

نیز از مدل ترکیبی DEA-ANN برای ارزیابی کارایی شرکت‌های تولیدی در صنعت خودرو استفاده کردند. در این پژوهش، نتایج حاصل از DEA برای شبیه‌سازی عملکرد آینده شرکت‌ها و پیش‌بینی اثرات تغییرات در ورودی‌ها و خروجی‌ها با استفاده از ANN به‌کار گرفته شد. این مدل توانست دقت پیش‌بینی را نسبت به روش‌های سنتی DEA و ANN به‌طور مستقل افزایش دهد. استفاده از این ترکیب در تحلیل کارایی می‌تواند برای مدیریت منابع، تخصیص بهینه و تصمیم‌گیری استراتژیک مفید باشد، چراکه مدل ترکیبی به‌طور همزمان از قدرت تحلیل کارایی DEA و پیش‌بینی ANN بهره می‌برد (Sadeghi, Sadeghi & Ahmadi, 2015).

(د) مبانی نظری

تحلیل پوششی داده‌ها بر مبنای مفهوم کارایی نسبی واحدهای تصمیم‌گیرنده استوار است. این روش با استفاده از مدل‌های ریاضی و برنامه‌ریزی خطی، کارایی واحدهای مختلف را نسبت به یک مرز کارایی اندازه‌گیری می‌کند. این مرز، بیانگر بهترین عملکردهای ممکن است که دیگر واحدها نمی‌توانند از آن فراتر روند. مهم‌ترین مدل‌های DEA شامل مدل‌های CCR و BCC هستند که به‌ترتیب به‌صورت ایستا و پویا عملکرد واحدهای تصمیم‌گیرنده را ارزیابی می‌کنند. در مدل DEA، کارایی به‌طور نسبی محاسبه می‌شود، به این معنا که هر واحد باید نسبت به واحدهای کارا ارزیابی شود. علاوه بر این، مدل DEA در ارزیابی سیستم‌های پیچیده‌ای که چندین ورودی و خروجی دارند، بسیار مؤثر است و می‌تواند کارایی نسبی واحدها را در شرایط مختلف شبیه‌سازی کند. مدل ریاضی شامل حل یک مسئله برنامه‌ریزی خطی برای تعیین امتیاز کارایی هر DMU است. مدل CCR، مدل (۱)، یکی از مدل‌های معروف DEA است که کارایی یک DMU_o به‌صورت زیر محاسبه می‌کند.

$$\begin{aligned} \text{رابطه (۱)} \quad \text{Max } Z_p &= \sum_{r=1}^s u_r y_{ro} \\ \text{st: } \begin{cases} \sum_{i=1}^m v_i x_{io} = 1 \\ \sum_{r=1}^s u_r y_{rj} - \sum_{i=1}^m v_i x_{ij} \leq 0 \quad j = 1/2 \dots /n \\ u_r \geq 0 \quad r = 1/ \dots /s \\ v_i \geq 0 \quad i = 1/ \dots /s \end{cases} \end{aligned}$$

در این مدل x_{ij} ورودی i واحد j ام و y_{rj} خروجی r واحد j ام اعداد مثبت بوده و مقادیر u_r و v_i اوزان مجهول و به عبارت دیگر متغیرهای تصمیم مدل برنامه‌ریزی می‌باشند.

و مدل BCC، مدل (۲)، کارایی DMU_o به‌صورت زیر محاسبه می‌کند.

$$\begin{aligned} \text{رابطه (۲)} \quad \text{Max } Z_p &= \sum_{r=1}^s u_r y_{ro} + u_o \\ \text{st: } \begin{cases} \sum_{i=1}^m v_i x_{io} = 1 \\ \sum_{r=1}^s u_r y_{rj} - \sum_{i=1}^m v_i x_{ij} - u_o \leq 0 \quad j = 1/2 \dots /n \\ u_r \geq 0 \quad r = 1/ \dots /s \\ v_i \geq 0 \quad i = 1/ \dots /s \\ u_o \text{ free} \end{cases} \end{aligned}$$

ه) شبکه های عصبی مصنوعی (ANN)

شبکه های عصبی مصنوعی، شبیه سازی فرآیند یادگیری مغز انسان را از طریق لایه هایی از نرون ها انجام می دهند که قادرند روابط غیرخطی پیچیده را یاد بگیرند. این مدل ها از چندین لایه پردازش شامل لایه ورودی^{۱۱}، لایه پنهان^{۱۲}، و لایه خروجی^{۱۳} استفاده می کنند. مهم ترین ویژگی ANN این است که می تواند بدون نیاز به روابط ریاضی دقیق، الگوهای پیچیده ای از داده ها را شبیه سازی کند. این ویژگی باعث شده است که ANN در زمینه هایی مانند پیش بینی، شبیه سازی و بهینه سازی به طور گسترده ای استفاده شود.

شبکه عصبی استفاده شده در این پژوهش شامل معماری پیش خور^{۱۴} است. لایه ورودی نمایانگر داده های ورودی-خروجی نرمال شده ی واحدها است، لایه های پنهان روابط خطی و غیرخطی را شبیه سازی می کنند و لایه خروجی امتیازهای کارایی را پیش بینی می کند. جزئیات معماری شامل:

- لایه های پنهان: سه لایه با ۶۴، ۳۲ و ۱۶ نرون
- توابع فعال سازی^{۱۵}: ReLU: برای لایه های مخفی و خطی برای لایه خروجی
- بهینه ساز: با نرخ یادگیری ۰.۰۱/۰
- تابع هزینه: خطای مربعات میانگین^{۱۶} (MSE)
- منظم سازی: (نرخ ۲/۰) و منظم سازی L2 برای جلوگیری از بیش برآش
- آموزش: پس انتشار با اندازه دسته ۳۲ و ۱۰۰ دوره
- اعتبارسنجی: اعتبارسنجی با ۵ بار تقسیم بندی متقابل برای اطمینان از مقاومت

و) مدل پیشنهادی

در این تحقیق، از یک مدل ترکیبی شامل تحلیل پوششی داده ها (DEA) و شبکه عصبی مصنوعی (ANN) برای ارزیابی و پیش بینی کارایی شرکت ها در صنایع مختلف استفاده می کنیم. این مدل به طور خاص برای بهره برداری از مزایای هر یک از این دو روش طراحی شده است. تحلیل پوششی داده ها یک ابزار مؤثر برای ارزیابی کارایی واحدهای تصمیم گیر (DMU) ها است که با استفاده از داده های ورودی و خروجی، کارایی نسبی را محاسبه می کند. از سوی دیگر، شبکه عصبی مصنوعی قادر به مدل سازی روابط پیچیده غیرخطی است. ترکیب این دو روش، امکان تحلیل دقیق تر و پیش بینی های بهینه تر را فراهم می آورد.

ز) مراحل اجرای مدل پیشنهادی

مدل پیشنهادی شامل دو مرحله اصلی است که به ترتیب از تحلیل پوششی داده ها (DEA) برای ارزیابی کارایی و سپس از شبکه عصبی مصنوعی (ANN) برای پیش بینی و تحلیل عمیق تر عملکرد شرکت ها استفاده می شود. هر یک از این مراحل به طور مؤثر با یکدیگر ترکیب می شوند تا نتایج دقیقی به دست آید.

مرحله اول: ارزیابی کارایی با استفاده از مدل DEA

این مرحله شامل ارزیابی کارایی شرکت ها با استفاده از مدل های تحلیل پوششی داده ها است. DEA یک تکنیک غیرپارامتریک برای ارزیابی عملکرد واحدهای تصمیم گیری است که با مقایسه ورودی ها و خروجی ها، کارایی نسبی هر واحد را تعیین می کند. مراحل این بخش عبارتند از:

۱. انتخاب ورودی ها و خروجی ها: ابتدا ورودی ها و خروجی ها باید به دقت انتخاب شوند. ورودی ها معمولاً شامل هزینه ها، تعداد کارکنان و سرمایه گذاری ها و... هستند، در حالی که خروجی ها شامل فروش، سود خالص، بهره وری و بازده سرمایه گذاری و... می باشند. انتخاب صحیح این متغیرها تأثیر زیادی بر دقت نتایج خواهد داشت.

11. Input Layer

12. Hidden Layer

13. Output Layer

14. Feedforward Neural Network

15. Activation Functions

16. Mean Square Error

۲. مدیریت داده‌های نوپزی و گمشده: برای مدیریت داده‌های نوپزی و گمشده از روش‌هایی مانند حذف داده‌های پرت و جایگذاری مقادیر گمشده با میانگین گروهی استفاده شده است.
۳. استفاده از مدل‌های DEA: برای محاسبه کارایی، از مدل‌های CCR و BCC استفاده می‌شود. مدل CCR کارایی را با فرض بازده به مقیاس ثابت^{۱۷} (CRS) اندازه‌گیری می‌کند، در حالی که مدل BCC با فرض متغیر بودن بازده به مقیاس^{۱۸} (VRS) عمل می‌کند. این دو مدل به تحلیل‌گران کمک می‌کنند تا تأثیر مقیاس‌های مختلف بر کارایی شرکت‌ها را ارزیابی کنند.
۴. ارزیابی کارایی و شناسایی واحدهای ناکار: پس از محاسبه کارایی، واحدهایی که کارایی کمتر از ۱ دارند به عنوان واحدهای ناکار^{۱۹} شناسایی می‌شوند. این نتایج نمای اولیه‌ای از وضعیت عملکرد شرکت‌ها در مقایسه با یکدیگر ارائه می‌دهند.
۵. ارائه ورودی‌ها برای ANN: ورودی و خروجی‌های واحدها پس از نرمالسازی به روش Min_Max رابطه (۱) به عنوان ورودی برای مرحله بعدی که استفاده از شبکه عصبی است، به کار گرفته می‌شود. این نتایج اطلاعات اولیه‌ای در خصوص کارایی نسبی و منابع ناکارآمدی فراهم می‌آورند که می‌توانند به مدل ANN در پیش‌بینی‌ها و تحلیل‌های بعدی کمک کنند.

$$X_{normal} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad \text{رابطه (۳)}$$

مرحله دوم: پیش‌بینی با استفاده از شبکه عصبی مصنوعی (ANN)

- در این مرحله، شبکه عصبی مصنوعی برای پیش‌بینی عملکرد شرکت‌ها در آینده و شبیه‌سازی روابط پیچیده‌تر بین ورودی‌ها و خروجی‌ها به کار گرفته می‌شود. مراحل این بخش عبارتند از:
۱. طراحی و ساختار شبکه عصبی: برای انجام این مرحله، از یک شبکه عصبی چندلایه (MLP) استفاده می‌شود که از لایه‌های ورودی، مخفی و خروجی تشکیل شده است. لایه ورودی شامل داده‌های جمع‌آوری شده از مرحله قبل است که شامل ورودی‌ها و خروجی‌های نرمالسازی شده شرکت‌ها می‌باشد. این داده‌ها به شبکه عصبی داده می‌شوند تا روابط میان آن‌ها مدل‌سازی شود.
 ۲. آموزش شبکه عصبی: شبکه عصبی با استفاده از الگوریتم پس‌انتشار آموزش داده می‌شود. این الگوریتم به شبکه کمک می‌کند تا وزن‌های اتصالات میان نرون‌ها را به‌طور مؤثری به‌روزرسانی کرده و خطای پیش‌بینی را کاهش دهد. به‌طور خاص، شبکه عصبی با استفاده از داده‌های ورودی حاصل از DEA به پیش‌بینی کارایی شرکت‌ها پرداخته و قادر به شبیه‌سازی شرایط مختلف اقتصادی و صنعتی خواهد بود.
 ۳. بهینه‌سازی شبکه عصبی: در این مرحله، پارامترهای مختلف شبکه عصبی مانند تعداد لایه‌های مخفی، تعداد نرون‌ها در هر لایه و الگوریتم‌های بهینه‌سازی انتخاب می‌شوند تا مدل به بهترین دقت در پیش‌بینی‌ها دست یابد. برای جلوگیری از بیش‌برازش، از تکنیک‌هایی مانند مجموعه اعتبارسنجی و شبکه‌های عصبی پیچیده‌تر استفاده می‌شود.
 ۴. ارزیابی عملکرد مدل ANN: پس از آموزش، عملکرد شبکه عصبی با استفاده از داده‌های آزمون ارزیابی می‌شود. برای اندازه‌گیری دقت پیش‌بینی‌ها، از معیارهایی مانند میانگین مربع خطا (MSE) و ریشه میانگین مربع خطا (RMSE) استفاده می‌شود.
- مرحله سوم: ترکیب نتایج ANN و DEA
- در این مرحله، نتایج حاصل از مدل DEA و ANN به‌طور ترکیبی برای پیش‌بینی دقیق‌تر کارایی و شبیه‌سازی عملکرد شرکت‌ها استفاده می‌شود. این فرآیند به شرح زیر است:

¹⁷. Constant returns to scale

¹⁸. Variable returns to scale

¹⁹. Inefficient

۱. فرآیند آموزش: امتیازهای کارایی تولید شده توسط DEA به عنوان هدف های خروجی برای آموزش نظارتی ANN به کار می روند. متغیرهای ورودی شامل ورودی ها و خروجی های نرمال سازی شده خواهند بود.
 ۲. پردازش پس از تولید: به منظور حفظ سازگاری با اصول DEA، خروجی های ANN مقیاس بندی و تنظیم می شوند تا اطمینان حاصل شود که تمام امتیازهای پیش بینی شده در محدوده $[0/1]$ قرار دارند.
 ۳. جریان کاری ترکیبی: سیستم ترکیبی ابتدا DMU ها را با استفاده از DEA ارزیابی کرده و سپس از ANN برای اصلاح و تعمیم پیش بینی های کارایی برای DMU های جدید یا داده های دیده نشده استفاده می کند.
- در مدیریت استراتژیک، یکی از اهداف کلیدی ارزیابی و بهبود عملکرد واحدهای مختلف سازمان است تا منابع به طور بهینه تخصیص یابند و تصمیمات مؤثرتری در راستای اهداف بلندمدت اتخاذ شود. در این بخش، به بررسی استفاده از مدل ترکیبی تحلیل پوششی داده ها (DEA) و شبکه عصبی مصنوعی (ANN) برای ارزیابی کارایی واحدهای تصمیم گیری (DMU) ها در محیط های صنعتی پرداخته و نشان خواهیم داد که چگونه می توان از این مدل ها برای بهبود استراتژی های مدیریتی در سیستم های صنعتی بهره برد.
- در سیستم های صنعتی، انواع مختلفی از داده ها برای ارزیابی کارایی واحدها وجود دارد. این داده ها شامل هزینه ها، زمان های تولید، مصرف انرژی، کیفیت محصولات و دیگر شاخص های عملیاتی هستند. در این مطالعه، داده های ۵۰ واحد تولیدی از صنعت تولیدی جمع آوری شده که شامل ورودی هایی همچون مصرف انرژی، هزینه مواد اولیه و ساعات کاری کارکنان و خروجی هایی همچون درآمد کل، امتیاز کیفیت محصول و میزان تولید است. جدول (۱) داده های این شرکتها را نشان می دهد.

جدول شماره (۱): داده های ورودی و خروجی ۵۰ شرکت تولیدی

شرکت	مصرف انرژی	هزینه مواد اولیه	ساعات کاری کارکنان	درآمد کل	امتیاز کیفیت محصول	میزان تولید
۱	۲۴۹۸	۱۹۵۴۴	۱۱۲۶	۴۶۳۳۱	۸۹	۳۶۵۰
۲	۴۸۰۳	۱۶۶۲۷	۳۵۴۶	۱۹۵۸۲	۷۳	۴۴۶۶
۳	۳۹۲۸	۱۹۰۹۲	۲۲۵۷	۱۵۷۹۶	۷۵	۸۶۶۰
۴	۳۳۹۵	۱۸۴۲۲	۳۰۳۴	۲۹۵۷۸	۹۷	۳۸۵۲
۵	۱۶۲۴	۱۳۹۶۸	۴۶۳۰	۴۹۴۲۶	۸۸	۲۵۲۵
۶	۱۶۲۴	۱۸۸۲۸	۱۹۹۷	۱۹۶۸۲	۷۰	۶۰۱۱
۷	۱۲۳۲	۶۳۲۷	۲۶۴۲	۳۶۸۸۵	۷۳	۹۴۲۵
۸	۴۴۶۵	۷۹۴۰	۴۰۲۲	۴۰۴۶۵	۹۰	۷۲۶۴
۹	۳۴۰۴	۵۶۷۸	۱۹۱۵	۱۹۵۰۶	۷۰	۶۱۳۱
۱۰	۳۸۳۲	۹۸۸۰	۱۳۰۸	۳۹۱۲۹	۷۵	۱۸۷۵
۱۱	۱۰۸۲	۱۰۸۳۰	۲۱۵۹	۲۴۷۱۱	۸۶	۶۵۳۵
۱۲	۴۸۸۰	۹۰۷۰	۱۶۴۵	۳۵۲۹۲	۹۱	۹۹۱۰
۱۳	۴۳۳۰	۱۷۴۳۱	۴۷۱۹	۳۵۳۴۱	۹۰	۲۲۶۱
۱۴	۱۸۴۹	۱۰۳۵۱	۴۲۳۲	۳۱۴۳۱	۷۷	۵۶۶۵
۱۵	۱۷۲۷	۹۲۱۴	۳۵۳۴	۱۳۶۱۲	۹۱	۸۸۹۶
۱۶	۱۷۳۴	۱۳۱۴۰	۴۴۸۶	۴۳۴۱۲	۷۷	۷۶۶۷
۱۷	۲۲۱۷	۷۱۱۴	۴۲۱۵	۲۲۸۳۱	۸۰	۷۲۷۳
۱۸	۳۰۹۹	۱۷۰۳۳	۱۷۴۶	۱۷۴۶۱	۹۲	۷۳۲۲
۱۹	۲۷۲۸	۶۱۱۸	۴۵۷۰	۱۱۶۳۱	۸۹	۴۲۳۵

۳۶۴۲	۹۵	۳۳۶۳۶	۳۱۵۷	۱۹۸۰۳	۲۱۶۵	۲۰
۸۲۸۴	۹۰	۳۷۱۰۳	۴۲۳۰	۱۶۵۸۴	۳۴۴۷	۲۱
۸۲۹۱	۸۷	۱۰۶۶۴	۴۵۸۴	۷۹۸۱	۱۵۵۸	۲۲
۸۸۰۴	۷۳	۳۰۴۸۴	۲۲۷۲	۵۰۸۳	۲۱۶۹	۲۳
۹۲۱۹	۸۱	۱۹۰۶۰	۱۴۴۰	۱۷۲۳۲	۲۴۶۵	۲۴
۵۶۰۲	۷۸	۳۵۸۰۷	۱۹۱۲	۱۵۶۰۳	۲۸۲۴	۲۵
۵۵۱۴	۷۷	۱۶۹۷۵	۲۷۰۸	۱۵۹۳۵	۴۱۴۱	۲۶
۸۱۸۵	۹۹	۳۷۶۳۸	۴۲۷۲	۱۶۵۶۹	۱۷۹۹	۲۷
۶۸۵۰	۸۲	۲۵۴۶۹	۴۴۴۳	۶۱۱۱	۳۰۵۷	۲۸
۷۳۱۸	۹۷	۴۷۴۶۹	۱۰۲۸	۱۰۳۷۷	۳۳۷۰	۲۹
۸۱۶۲	۸۹	۱۵۵۰۱	۳۰۴۳	۶۷۳۸	۱۱۸۶	۳۰
۹۰۱۰	۹۴	۲۳۶۴۳	۲۶۷۰	۱۷۹۴۷	۳۴۳۰	۳۱
۴۰۴۲	۸۵	۱۴۵۳۹	۱۸۸۸	۱۴۳۴۹	۱۶۸۲	۳۲
۴۳۸۰	۸۷	۴۶۹۸۸	۱۴۷۹	۹۹۶۳	۱۲۶۰	۳۳
۱۸۴۶	۸۵	۴۵۰۹۴	۲۳۵۰	۵۹۵۳	۴۷۹۶	۳۴
۶۲۰۵	۷۶	۲۰۳۱۸	۴۷۷۲	۹۶۶۵	۴۸۶۳	۳۵
۱۳۲۳	۹۲	۳۶۳۹۹	۲۲۹۳	۹۸۷۸	۴۲۳۴	۳۶
۵۱۹۰	۷۸	۴۲۶۸۹	۳۰۷۵	۱۵۹۴۴	۲۲۱۸	۳۷
۵۸۸۴	۷۱	۳۲۲۰۸	۳۸۱۲	۱۴۵۶۳	۱۳۹۱	۳۸
۳۵۷۹	۸۹	۳۱۱۸۶	۲۴۵۵	۱۸۳۰۸	۳۷۳۷	۳۹
۶۳۱۷	۷۵	۱۹۶۷۴	۴۸۸۷	۱۲۰۸۳	۲۷۶۱	۴۰
۱۲۷۵	۹۸	۱۳۷۲۴	۴۸۵۰	۶۷۹۴	۱۴۸۸	۴۱
۱۳۳۶	۹۹	۴۵۸۸۹	۲۰۰۷	۱۵۶۹۹	۲۹۸۱	۴۲
۸۴۰۳	۹۷	۴۶۰۱۷	۲۹۸۹	۱۶۴۱۲	۱۱۳۸	۴۳
۴۲۴۲	۸۱	۳۵۳۲۴	۲۲۰۴	۱۳۴۱۹	۴۶۳۷	۴۴
۲۱۴۴	۷۰	۲۳۵۶۱	۲۱۳۹	۱۶۵۶۵	۲۰۳۵	۴۵
۵۷۰۰	۹۸	۲۳۹۶۸	۱۱۴۸	۱۲۴۰۷	۳۶۵۰	۴۶
۷۹۳۰	۸۳	۳۹۰۳۸	۳۴۳۸	۱۲۸۴۱	۲۲۴۷	۴۷
۲۹۴۲	۹۹	۴۵۸۸۴	۳۰۱۱	۱۱۴۱۳	۳۰۸۰	۴۸
۶۶۰۶	۹۹	۴۵۴۸۳	۱۲۰۶	۵۳۸۱	۳۱۸۷	۴۹
۱۷۶۸	۹۶	۴۱۱۹۵	۲۱۱۵	۶۶۱۸	۱۷۳۹	۵۰

این نوع داده‌ها در برنامه‌ریزی استراتژیک سیستم‌های صنعتی اهمیت زیادی دارند. تحلیل و ارزیابی صحیح این داده‌ها می‌تواند به مدیران کمک کند تا عملکرد واحدها را به‌درستی ارزیابی کرده و اولویت‌های بهبود را شناسایی کنند. برای مثال، مدیران می‌توانند

از این اطلاعات برای شناسایی واحدهایی که به بهینه سازی مصرف انرژی نیاز دارند، یا واحدهایی که می توانند کارایی تولید را افزایش دهند، استفاده کنند.

برای ارزیابی کارایی ۵۰ شرکت صنعتی، ابتدا از مدل های CCR و BCC استفاده شد. مدل CCR برای محاسبه کارایی با فرض ثابت بودن بازده به مقیاس (CRS) و مدل BCC برای محاسبه کارایی با فرض متغیر بودن بازده به مقیاس (VRS) به کار گرفته شدند. با استفاده از نرم افزار GAMS کارایی این شرکتها محاسبه شد. این نتایج در جدول (۲) آمده است. ارزیابی شرکتها توسط مدل های DEA نشان داد که برخی از شرکتها کارا (با کارایی ۱۰۰ درصد) هستند، در حالی که برخی دیگر نیاز به بهبود عملکرد دارند.

شرکت هایی که دارای کارایی کمتر از ۱ بودند، به عنوان واحدهای ناکارا شناسایی شدند. مدل DEA نشان داد که ۲۰ درصد از DMU ها کارا بوده و بقیه DMU ها در بازه های مختلف کارایی (بین ۰/۶ تا ۰/۹۲) قرار دارند. این اطلاعات به مدیران استراتژیک کمک می کند تا تصمیمات بهتری برای تخصیص منابع به واحدهای کارا و کاهش منابع به واحدهای ناکارا اتخاذ کنند.

جدول شماره (۲): ارزیابی شرکت ها با استفاده از مدل BCC, CCR

شرکت	کارایی CCR (CRS)	کارایی BCC (VRS)	وضعیت کارایی CCR	وضعیت کارایی BCC
۱	۱/۰۰	۱/۰۰	کارا	کارا
۲	۰/۳۵	۰/۴۴	ناکارا	ناکارا
۳	۰/۶۷	۰/۶۷	ناکارا	ناکارا
۴	۰/۵۲	۰/۶۳	ناکارا	ناکارا
۵	۰/۸۱	۱/۰۰	ناکارا	کارا
۶	۰/۷۸	۰/۸۶	ناکارا	ناکارا
۷	۱/۰۰	۱/۰۰	کارا	کارا
۸	۰/۶۶	۰/۶۷	ناکارا	ناکارا
۹	۰/۷۴	۰/۹۲	ناکارا	ناکارا
۱۰	۰/۷۱	۰/۸۵	ناکارا	ناکارا
۱۱	۱/۰۰	۱/۰۰	کارا	کارا
۱۲	۱/۰۰	۱/۰۰	کارا	کارا
۱۳	۰/۳۹	۰/۴۱	ناکارا	ناکارا
۱۴	۰/۶۵	۰/۶۵	ناکارا	ناکارا
۱۵	۰/۸۲	۱/۰۰	ناکارا	کارا
۱۶	۰/۷۳	۰/۸۲	کارا	کارا
۱۷	۰/۷۸	۰/۸۱	ناکارا	ناکارا
۱۸	۰/۷۹	۰/۸۲	ناکارا	ناکارا
۱۹	۰/۸۶	۰/۹۱	ناکارا	ناکارا
۲۰	۰/۶۰	۰/۷۱	ناکارا	ناکارا
۲۱	۰/۵۲	۰/۵۶	ناکارا	ناکارا
۲۲	۰/۸۲	۰/۸۳	ناکارا	ناکارا
۲۳	۱/۰۰	۱/۰۰	کارا	کارا
۲۴	۱/۰۰	۱/۰۰	کارا	کارا

۲۵	۰/۶۵	۰/۷۰	ناکارا	ناکارا
۲۶	۰/۴۶	۰/۵۱	ناکارا	ناکارا
۲۷	۰/۷۲	۱/۰۰	ناکارا	ناکارا
۲۸	۰/۸۱	۰/۸۵	ناکارا	ناکارا
۲۹	۱/۰۰	۱/۰۰	کارا	کارا
۳۰	۱/۰۰	۱/۰۰	کارا	کارا
۳۱	۰/۷۰	۰/۸۵	ناکارا	ناکارا
۳۲	۰/۷۶	۰/۷۸	ناکارا	ناکارا
۳۳	۱/۰۰	۱/۰۰	کارا	کارا
۳۴	۰/۹۰	۰/۹۰	ناکارا	ناکارا
۳۵	۰/۴۷	۰/۵۳	ناکارا	ناکارا
۳۶	۰/۵۹	۰/۶۳	ناکارا	ناکارا
۳۷	۰/۵۵	۰/۵۷	ناکارا	ناکارا
۳۸	۰/۶۷	۰/۸۰	ناکارا	ناکارا
۳۹	۰/۵۳	۰/۵۴	ناکارا	ناکارا
۴۰	۰/۴۶	۰/۵۱	ناکارا	ناکارا
۴۱	۱/۰۰	۱/۰۰	کارا	کارا
۴۲	۰/۷۲	۱/۰۰	ناکارا	کارا
۴۳	۱/۰۰	۱/۰۰	کارا	کارا
۴۴	۰/۴۹	۰/۵۷	ناکارا	ناکارا
۴۵	۰/۵۴	۰/۶۸	ناکارا	ناکارا
۴۶	۰/۹۲	۰/۹۷	ناکارا	ناکارا
۴۷	۰/۶۵	۰/۶۶	ناکارا	ناکارا
۴۸	۰/۶۶	۱/۰۰	ناکارا	کارا
۴۹	۱/۰۰	۱/۰۰	کارا	کارا
۵۰	۱/۰۰	۱/۰۰	کارا	کارا

پس از ارزیابی کارایی با مدل DEA، نتایج به‌دست‌آمده به‌عنوان ورودی برای آموزش شبکه عصبی مصنوعی (ANN) مورد استفاده قرار گرفت. هدف از این مرحله پیش‌بینی کارایی آینده شرکت‌ها و شبیه‌سازی شرایط مختلف اقتصادی و صنعتی بود.

- ساختار شبکه عصبی: شبکه عصبی استفاده شده از معماری پرسپترون چندلایه^{۲۰} (MLP) با سه لایه تشکیل شده است. لایه ورودی شامل داده‌های ورودی و خروجی از مدل DEA است. لایه‌های مخفی به‌طور خودکار روابط پیچیده میان ورودی‌ها و خروجی‌ها را یاد می‌گیرند، و لایه خروجی پیش‌بینی کارایی یا عملکرد آینده شرکت‌ها را انجام می‌دهد.

²⁰. Multilayer Perceptron

- آموزش شبکه عصبی: برای آموزش شبکه عصبی، از داده های حاصل از مدل DEA و ویژگی های مختلف شرکت ها استفاده شد. الگوریتم پس انتشار برای به روزرسانی وزن ها و کاهش خطای پیش بینی ها به کار گرفته شد. هدف از این مرحله پیش بینی عملکرد آینده شرکت ها بر اساس ورودی ها و خروجی ها و شبیه سازی روابط پیچیده میان آن ها بود. در این فرآیند، ورودی ها و خروجی های حاصل از مدل DEA به عنوان داده های ورودی به شبکه عصبی و کارایی محاسبه شده به عنوان خروجی ها مورد استفاده قرار گرفتند. نتایج این پیش بینی و خطای محاسبه شده در جدول (۳) آمده است.

جدول شماره (۳): نتایج کارایی پیش بینی شده با استفاده از ANN

شرکت	کارایی پیش بینی شده (با استفاده از ANN)	خطای پیش بینی (MSE)	وضعیت پیش بینی
۱	۱/۰۰	۰/۰۰	صحیح
۲	۰/۳۹	۰/۰۵	پیش بینی دقیق
۳	۰/۶۷	۰/۰۰	صحیح
۴	۰/۵۸	۰/۰۵	پیش بینی دقیق
۵	۰/۹۰	۰/۱۰	پیش بینی دقیق
۶	۰/۸۲	۰/۰۴	پیش بینی دقیق
۷	۱/۰۰	۰/۰۰	صحیح
۸	۰/۶۶	۰/۰۰	صحیح
۹	۰/۸۳	۰/۰۹	پیش بینی دقیق
۱۰	۰/۷۸	۰/۰۷	پیش بینی دقیق
۱۱	۱/۰۰	۰/۰۰	صحیح
۱۲	۱/۰۰	۰/۰۰	صحیح
۱۳	۰/۴۰	۰/۰۱	پیش بینی دقیق
۱۴	۰/۶۵	۰/۰۰	صحیح
۱۵	۰/۹۱	۰/۰۹	پیش بینی دقیق
۱۶	۰/۷۸	۰/۰۵	پیش بینی دقیق
۱۷	۰/۷۹	۰/۰۲	پیش بینی دقیق
۱۸	۰/۸۱	۰/۰۱	پیش بینی دقیق
۱۹	۰/۸۹	۰/۰۲	پیش بینی دقیق
۲۰	۰/۶۶	۰/۰۵	پیش بینی دقیق
۲۱	۰/۵۴	۰/۰۲	پیش بینی دقیق
۲۲	۰/۸۳	۰/۰۰	صحیح
۲۳	۱/۰۰	۰/۰۰	صحیح
۲۴	۱/۰۰	۰/۰۰	صحیح
۲۵	۰/۶۷	۰/۰۳	پیش بینی دقیق
۲۶	۰/۴۹	۰/۰۲	پیش بینی دقیق
۲۷	۰/۸۶	۰/۱۴	پیش بینی دقیق
۲۸	۰/۸۳	۰/۰۲	پیش بینی دقیق

۲۹	۱/۰۰	۰/۰۰	صحیح
۳۰	۱/۰۰	۰/۰۰	صحیح
۳۱	۰/۷۸	۰/۰۷	پیش‌بینی دقیق
۳۲	۰/۷۷	۰/۰۱	پیش‌بینی دقیق
۳۳	۱/۰۰	۰/۰۰	صحیح
۳۴	۰/۹۰	۰/۰۰	صحیح
۳۵	۰/۵۰	۰/۰۳	پیش‌بینی دقیق
۳۶	۰/۶۱	۰/۰۲	پیش‌بینی دقیق
۳۷	۰/۵۶	۰/۰۱	پیش‌بینی دقیق
۳۸	۰/۷۴	۰/۰۷	پیش‌بینی دقیق
۳۹	۰/۵۳	۰/۰۱	پیش‌بینی دقیق
۴۰	۰/۴۹	۰/۰۳	پیش‌بینی دقیق
۴۱	۱/۰۰	۰/۰۰	صحیح
۴۲	۰/۸۶	۰/۱۴	پیش‌بینی دقیق
۴۳	۱/۰۰	۰/۰۰	صحیح
۴۴	۰/۵۳	۰/۰۴	پیش‌بینی دقیق
۴۵	۰/۶۱	۰/۰۷	پیش‌بینی دقیق
۴۶	۰/۹۵	۰/۰۳	پیش‌بینی دقیق
۴۷	۰/۶۵	۰/۰۱	پیش‌بینی دقیق
۴۸	۰/۸۳	۰/۱۷	پیش‌بینی دقیق
۴۹	۱/۰۰	۰/۰۰	صحیح
۵۰	۱/۰۰	۰/۰۰	صحیح

۳ - نتایج و بحث

نتایج به‌دست‌آمده از مدل‌های ANN و DEA به شرح زیر قابل تحلیل است:

۱. دقت پیش‌بینی مدل ANN: بر اساس خطای پیش‌بینی که با استفاده از معیار میانگین مربع خطا (MSE) اندازه‌گیری شد، مدل ANN توانست پیش‌بینی‌هایی با دقت بالاتر نسبت به نتایج مدل DEA ارائه دهد. میانگین خطای پیش‌بینی در این مطالعه برابر با ۰/۰۱ بود که نشان‌دهنده دقت بالای مدل ANN در پیش‌بینی کارایی شرکت‌ها می‌باشد.
۲. کارایی شرکت‌ها: نتایج مدل DEA نشان می‌دهد که تقریباً ۳۰ درصد از شرکت‌ها در وضعیت کارا قرار دارند و مابقی شرکت‌ها نیاز به بهبود عملکرد دارند. در مقابل، مدل ANN نشان می‌دهد که بیشتر شرکت‌ها می‌توانند در آینده به وضعیت بهتری دست یابند، به‌ویژه در صورتی که بهبودهایی در ورودی‌ها مانند سرمایه‌گذاری و هزینه‌ها اعمال شود.
۳. تأثیر ورودی‌ها بر خروجی‌ها: مدل ANN قادر به شبیه‌سازی روابط پیچیده و غیرخطی میان ورودی‌ها و خروجی‌ها است. این توانایی به مدیران کمک می‌کند تا درک بهتری از تأثیرات تغییرات در ورودی‌ها بر خروجی‌ها داشته باشند و تصمیمات استراتژیک خود را بر اساس این تحلیل‌ها بهبود بخشند.
۴. مزیت ترکیب DEA و ANN: ترکیب مدل‌های ANN و DEA باعث افزایش چشمگیر دقت پیش‌بینی‌ها شد. در حالی که DEA به‌طور دقیق وضعیت کارایی فعلی شرکت‌ها را ارزیابی می‌کند، مدل ANN توانسته است پیش‌بینی‌های

دقیق تری برای آینده ارائه دهد و شبیه سازی هایی از تغییرات کارایی در شرایط مختلف ورودی ایجاد کند. نتایج پیش بینی ها پس از آموزش شبکه عصبی نشان داد که این مدل در پیش بینی کارایی آینده شرکت ها به ویژه در مواجهه با تغییرات ورودی ها دقت بالاتری دارد.

۵. ارزیابی عملکرد مدل ANN : مدل ANN با استفاده از معیارهای میانگین مربع خطا (MSE) و ریشه میانگین مربع خطا (RMSE) ارزیابی شد. نتایج نشان داد که این مدل توانست پیش بینی هایی با دقت بالاتر نسبت به مدل DEA به طور مجزا ارائه دهد. این پیش بینی ها به تحلیلگران و مدیران کمک می کند تا تصمیمات استراتژیک بهتری اتخاذ کنند و روندهای اقتصادی و صنعتی را به طور دقیق تری درک کنند. در نهایت، مدل ترکیبی DEA و ANN راهکاری مؤثر برای ارزیابی و پیش بینی کارایی شرکت ها در صنایع پیچیده و پویا فراهم می آورد. این مدل نه تنها شبیه سازی دقیق تری از عملکرد شرکت ها ارائه می دهد، بلکه قادر به تحلیل روندهای آینده و تغییرات احتمالی نیز هست، که این امر به مدیران در تصمیم گیری های استراتژیک کمک می کند.

۶. رفع چالش های داده های ناقص و نویزی با ANN : استفاده از ANN در ارزیابی کارایی می تواند به مدیران کمک کند تا چالش های ناشی از داده های نویزی یا ناقص را برطرف کرده و ارزیابی های دقیق تری از عملکرد واحدها انجام دهند. این موضوع به ویژه در صنایع تولیدی که داده ها به طور مداوم به روز می شوند و تحت تأثیر عوامل مختلف قرار دارند، اهمیت زیادی دارد. نتایج مدل ANN می تواند به تخصیص بهینه تر منابع، بهبود فرآیندها و ارتقای کیفیت تصمیم گیری های استراتژیک کمک کند.

۷. چالش های محاسباتی و مزایای استفاده از مدل ANN : در سیستم های صنعتی که با داده های حجیم و پیچیده روبه رو هستند، پیچیدگی های محاسباتی یکی از چالش های اصلی به شمار می آید. بنابراین، مدل های ANN ممکن است نیازمند منابع سخت افزاری و زمان زیادی برای آموزش باشند. با این حال، مزایای استفاده از این مدل ها در بهبود دقت ارزیابی ها و پیش بینی های کارایی، می تواند این چالش ها را توجیه پذیر کند. در مدیریت راهبردی، بهره برداری از مدل های ANN می تواند به مدیران کمک کند تا تصمیمات بهتری در خصوص بهبود بهره وری و تخصیص منابع اتخاذ کنند، حتی اگر هزینه های محاسباتی بالاتر باشد.

۴-منابع

- Alavi, H. (2019). Efficiency prediction considering nonlinear impacts of time delays in data envelopment analysis. *Journal of Iranian Industrial Management*, 11(3), 45–58.
- Bahrami, F., Abbasi, M., & Rahimi, S. (2022). Combining data envelopment analysis models and machine learning algorithms for evaluating the efficiency of decision-making units considering undesirable outputs. *Journal of Industrial Management and Systems*, 14(4), 23-35.
- Banker, R. D., Charnes, A., & Cooper, W. W. (1984). Some models for estimating technical and scale inefficiencies in data envelopment analysis. *Management Science*, 30(9), 1078–1092.
- Charnes, A., Cooper, W. W., & Rhodes, E. (1978). Measuring the efficiency of decision-making units. *European Journal of Operational Research*, 2(6), 429–444.
- Emrouznejad, A., & Yang, G. (2018). A survey and analysis of the first 40 years of scholarly literature in DEA: 1978–2016. *Socio-Economic Planning Sciences*, 61, 4–8.
- Fallah, H., Karimi, N., & Rezaei, A. (2023). A hybrid model of data envelopment analysis and artificial neural networks for evaluating the efficiency of pharmaceutical companies. *Journal of Industrial Management Technology*, 12(1), 45–59.
- Feng, L., & Wei, C. (2021). Developing and training artificial neural networks using bootstrap data envelopment analysis for best performance modeling of sawmills in Ontario. *Journal of Modelling in Management*, 16(3), 765–785.

- Jin, Y., Li, Y., & Hu, J. (2016). Applying artificial neural networks to predict hospital efficiency in the context of health care reform. *Health Care Management Science*, 19(4), 302–314.
- Kao, C., & Liu, S. (2004). Predicting performance improvement using DEA and ANN. *Computers & Operations Research*, 31(10), 1875–1886.
- Nadri, K., & Rostami, A. (2021). A model for improving comparative performance evaluation of companies using artificial neural networks and data envelopment analysis. In *Proceedings of the National Conference on New Technologies in Management and Industrial Engineering*, 15(3), 67–78.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536.
- Sadeghi, J., Sadeghi, S., & Ahmadi, A. (2015). Evaluating the efficiency of automotive companies using a hybrid DEA-ANN model. *Journal of Industrial Engineering International*, 11(3), 389–402.
- Sharifi, R., & Mohammadi, M. (2020). Applying a hybrid approach of data envelopment analysis and artificial neural networks in evaluating the performance of Iran Darou pharmaceutical company. *Journal of Iranian Industrial Management Research*, 10(2), 89–104.
- Wang, T., Zhu, Q., & Chu, J. (2011). Using data envelopment analysis and neural networks for efficiency evaluation and prediction. *Mathematical and Computer Modelling*, 54(11–12), 2760–2771.
- Zhang, J., & Lin, C. (2020). Performance evaluation of industrial firms using DEA and DECORATE ensemble method. *Expert Systems with Applications*, 143, 113048.

Evaluation and Prediction of the Efficiency of Industrial Companies Using a Hybrid Model of Data Envelopment Analysis and Artificial Neural Networks

Shahnaz Mohammadi Majd

Assistant Professor of Mathematics, Sanandaj Branch, Islamic Azad University, Sanandaj, Iran

Email: shahnaz.m.majd@iau.ir

Abstract

This paper presents a hybrid model based on Data Envelopment Analysis (DEA) and Artificial Neural Networks (ANN) to evaluate and predict the efficiency of 50 industrial companies operating in various sectors. Initially, DEA was employed to calculate the relative efficiency and identify efficient and inefficient decision-making units. Subsequently, the results obtained from DEA were used as target data to train the Artificial Neural Network (ANN). The ANN model, by uncovering hidden patterns in the data, was able to predict the future performance of companies with high accuracy. The results demonstrate that the DEA-ANN hybrid model not only provides a precise assessment of companies' current efficiency but also predicts efficiency changes in the event of input variations. Additionally, by utilizing the trained neural network, it is possible to predict the efficiency of companies that have not been directly evaluated. This approach, combining the strengths of DEA in efficiency analysis and the capabilities of ANN in modeling nonlinear relationships, offers an effective tool for managers and decision-makers to improve performance and optimize resource allocation.

Keywords: Artificial Neural Network, Data Envelopment Analysis, Efficiency Evaluation, Hybrid Model, Performance Prediction.