



Paper Type: Original Article



Comparing Inverse Data Envelopment Analysis Models with Artificial Intelligence-Based Hybrid Models in Financial Resources Forecasting

Akram Mohsenikia^{1,*}, Ghasem Tohidi¹, Masoud Sanei¹ , Behrooz Daneshian¹, Shabnam Rezavian²

¹ Department of Mathematics, Central Tehran Branch, Islamic Azad University, Tehran, Iran; mohsenikia@gmail.com; ghatohidi@yahoo.com; M_sanei@iauctb.ac.ir; Be_daneshian@iauctb.ac.ir.

² Department of Mathematics, South Tehran Branch, Islamic Azad University, Tehran, Iran; sh_razavyan@azad.ac.ir.

Citation:



Mohsenikia, A., Tohidi, Gh., Sanei, M., Daneshian, B., & Rezavian, Sh. (2025). Comparing inverse data envelopment analysis models with artificial intelligence-based hybrid models in financial resources forecasting. *Management sciences and decision analysis*, 3(1), 43-50.

Received: 06/03/2024

Reviewed: 20/07/2024

Revised: 12/06/2024

Accepted: 11/04/2024

Abstract

Purpose: This paper aims to compare Inverse Data Envelopment Analysis models with Artificial Intelligence-based hybrid models in forecasting and allocating financial resources, particularly in banking sectors.

Methodology: The study first employs traditional Inverse DEA models and then integrates them with AI techniques including Particle Swarm Optimization, Multiple Linear Regression, and Artificial Neural Networks. These models are evaluated through a case study using real data from five bank branches.

Findings: The results reveal that hybrid models, especially Inverse DEA+ANN, outperform classical methods in optimizing input resources and reducing costs. ANN provided the most accurate forecasts due to its ability to capture nonlinear patterns. PSO also significantly reduced costs while maintaining model accuracy.

Originality/Value: This research introduces a novel approach by combining classical DEA methods with AI algorithms to enhance resource allocation accuracy. The proposed hybrid framework serves as a practical decision-support tool in financial and banking environments.

Keywords: Inverse DEA, Artificial intelligence, Financial resource forecasting, Artificial neural network, PSO, Multiple linear regression.



Corresponding Author: mohsenikia@gmail.com



10.22105/msda.v3i2.79



Licensee. **Management Sciences and Decision Analysis**. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0>).



مقایسه مدل‌های تحلیل پوششی داده‌های معکوس با مدل‌های ترکیبی مبتنی بر هوش مصنوعی در پیش‌بینی منابع مالی

اکرم محسنی کیا^{۱*}، قاسم توحیدی^۱، مسعود صانعی^۱، بهروز دانشیان^۱، شبنم رضویان^۲

^۱ گروه ریاضی، واحد تهران مرکز، دانشگاه آزاد اسلامی، تهران، ایران.

^۲ گروه ریاضی، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران.

چکیده

هدف: این مقاله با هدف مقایسه مدل‌های تحلیل پوششی داده‌های معکوس و مدل‌های ترکیبی مبتنی بر هوش مصنوعی در پیش‌بینی و تخصیص منابع مالی طراحی شده است. تمرکز اصلی بر افزایش دقت و کارایی پیش‌بینی منابع موردنیاز در شعب بانکی است.

روش‌شناسی پژوهش: در این پژوهش ابتدا از مدل‌های کلاسیک *Inverse DEA* برای پیش‌بینی منابع استفاده شده و سپس این مدل‌ها با الگوریتم‌های *AI* نظیر *PSO*، رگرسیون چندمتغیره و شبکه عصبی مصنوعی ترکیب شده‌اند. عملکرد این مدل‌ها در یک مطالعه موردی با استفاده از داده‌های واقعی پنج شعبه بانکی ارزیابی شده است.

یافته‌ها: نتایج نشان می‌دهد مدل‌های ترکیبی به‌ویژه *Inverse DEA + ANN* عملکرد بهتری در بهینه‌سازی ورودی‌ها و کاهش هزینه‌ها دارند. مدل *ANN* به دلیل توانایی در شناسایی الگوهای غیرخطی، بهترین نتایج را در تخصیص منابع ارائه داده است. مدل *PSO* نیز دقت بالایی داشته و هزینه‌ها را به‌صورت مؤثری کاهش داده است.

اصالت/ارزش افزوده علمی: نوآوری این تحقیق در ترکیب روش‌های کلاسیک *DEA* با الگوریتم‌های هوش مصنوعی برای دستیابی به تخصیص منابع دقیق‌تر و کاراتر است. این ترکیب نه تنها قابلیت پیش‌بینی دقیق را افزایش می‌دهد، بلکه ابزار مفیدی برای تصمیم‌گیری در سیستم‌های مالی و بانکی فراهم می‌کند.

کلیدواژه‌ها: *Inverse DEA*، هوش مصنوعی، پیش‌بینی منابع مالی، شبکه عصبی مصنوعی، *PSO*، رگرسیون چندمتغیره.

۱- مقدمه

در سال‌های اخیر، روش‌های DEA^1 به‌عنوان ابزاری موثر برای ارزیابی و بهینه‌سازی عملکرد دستگاه‌ها و واحدهای تصمیم‌گیرنده^۲ در صنایع مختلف معرفی شده است [1-4]. مدل‌های تحلیل پوششی داده‌های معکوس^۳ که به‌طور ویژه در تخصیص بهینه منابع ورودی به دستگاه‌ها برای دستیابی به خروجی‌های مطلوب طراحی شده‌اند، به یکی از ابزارهای پرکاربرد در ارزیابی عملکرد تبدیل شده‌اند. با این حال مدل‌های *Inverse DEA* به دلیل پیچیدگی در پیش‌بینی منابع مالی و تخصیص دقیق منابع، ممکن است همیشه نتایج بهینه را ارائه ندهند.

¹ Data Envelopment Analysis (DEA)

² Decision-Making Units (DMU)

³ Inverse DEA

برای حل این چالش‌ها، ترکیب مدل‌های *Inverse DEA* با الگوریتم‌های هوش مصنوعی^۱ می‌تواند عملکرد بهتری را ارائه دهد. الگوریتم‌هایی مانند بهینه‌سازی ازدحام ذرات^۲ و یادگیری ماشین^۳ به دلیل توانایی بالای خود در جستجو و بهینه‌سازی پارامترها، در این ترکیب به‌طور ویژه کاربرد دارند [5]. این مقاله به بررسی مدل‌های ترکیبی *Inverse DEA* پرداخته، سپس به مقایسه نتایج حاصل از هریک از مدل‌ها در پیش‌بینی منابع مالی موردنیاز برای دستیابی به کارایی مطلوب در شعب بانکی می‌پردازد [6].

۲- مفاهیم پایه‌ای

در این بخش، مفاهیم اساسی *Inverse DEA* و روش‌های هوش مصنوعی؛ از جمله الگوریتم *PSO* و *ML* که برای حل مسایل پیچیده و بهینه‌سازی در زمینه‌های مختلف به‌کار می‌روند، به‌طور خلاصه مرور می‌شوند.

۲-۱- مدل‌های *Inverse DEA*

Inverse DEA یک ابزار کارآمد در برنامه‌ریزی برای تخمین ورودی‌ها و خروجی‌ها است که اولین بار توسط ژانگ و چوی [7] مطرح گردید، سپس وی و همکاران [8] استفاده از این تکنیک را توسعه دادند و از آن برای پاسخ به سوالات زیر استفاده نمودند:

۱. در میان گروهی از *DMUs* متجانس، در صورت نیاز به افزایش ورودی‌ها میزان افزایش خروجی‌های تولیدشده با حفظ کارایی جاری واحدها، چه میزان خواهد بود؟
۲. در میان گروهی از *DMUs* متجانس، در صورت نیاز به افزایش خروجی‌ها میزان افزایش ورودی‌های مصرف‌شده با حفظ کارایی جاری واحدها، چه میزان خواهد بود؟

برای پاسخ به این سوالات، از مدل برنامه‌ریزی خطی چندهدفه^۴ در حالتی که ورودی‌ها افزایش می‌یابند و درصدد تخمین خروجی‌ها هستیم استفاده می‌شود. فرض کنید بردار ورودی DMU_0 از x_{i0} به $x'_{i0} = x_{i0} + \Delta x_{i0}$ & $(i = 1, \dots, m)$ افزایش یافته باشد که در آن $\Delta x_0 = (\Delta x_{i0}, \Delta x_{20}, \dots, \Delta x_{m0}) \geq 0$ و $\Delta x_0 \neq 0$. هدف آن است که حداکثر امکان افزایش در بردار خروجی یعنی $\Delta y_r (r = 1, \dots, s)$ تخمین زده شود به‌طوری‌که نمره کارایی واحد جدید، یعنی $DMU'_0 = (x'_{i0}, y'_{r0}) = (x_{i0} + \Delta x_{i0}, y_{r0} + \Delta y_{r0})$ بدون تغییر باقی‌مانده و برابر با مقدار کارایی قبلی باشد. مدل *Inverse DEA* ارائه‌شده برای تخمین خروجی‌ها به‌صورت زیر است [8]:

$$\begin{aligned} \max \quad & (\Delta y_{10}, \Delta y_{20}, \dots, \Delta y_{s0}), \\ \text{s.t.} \quad & \sum_{i=1}^m \lambda_j x_{ij} \leq \theta_0^* (x_{i0} + \Delta x_{i0}), \quad i = 1, \dots, m, \\ & \sum_{i=1}^m \lambda_j y_{rj} \geq y_{r0} + \Delta y_{r0}, \quad r = 1, \dots, s, \\ & \lambda_j \geq 0, \quad j = 1, \dots, n, \\ & \Delta y_{r0} \geq 0, \quad r = 1, \dots, s. \end{aligned} \quad (1)$$

که در آن θ_0^* متناظر با کارایی *CCR* واحد تحت ارزیابی DMU_0 در ماهیت ورودی است و مقادیر $x_{ij} (i = 1, \dots, m)$ و $y_{rj} (j = 1, \dots, s)$ مقادیری معلوم هستند و هدف تخمین سطح خروجی $\Delta y_0 = (\Delta y_{10}, \Delta y_{20}, \dots, \Delta y_{s0}) \geq 0$ با حفظ کارایی DMU_0 است.

حال فرض کنید این بار، بردار خروجی DMU_0 از y_{r0} به $y'_{r0} = y_{r0} - \Delta y_{r0} (r = 1, \dots, s)$ کاهش یافته باشد که در آن بردار $\Delta y_0 \geq 0$ و $\Delta y_0 \neq 0$. هدف آن است که حداکثر امکان کاهش در بردار ورودی $\Delta x_0 = (\Delta x_{i0}, \Delta x_{20}, \dots, \Delta x_{m0}) \geq 0$ تخمین زده شود به‌طوری‌که نمره کارایی واحد جدید، یعنی

¹ Artificial Intelligent (AI)

² Particle Swarm Optimization (PSO)

³ Machine Learning (ML)

⁴ Multi-Objective Linear Programming (MOLP)

تخمین حداکثر امکان کاهش در بردار ورودی به صورت زیر خواهد بود [8]:
 $DMU'_o = (x'_o, y'_o) = (x_o + \Delta x_o, y_o + \Delta y_o)$ بدون تغییر باقی مانده و برابر با مقدار کارایی قبلی یعنی θ_o^* باشد. مدل *Inverse DEA* ارایه شده برای

$$\begin{aligned} \max \quad & (\Delta x_{1o}, \Delta x_{2o}, \dots, \Delta x_{mo}), \\ \text{s.t.} \quad & \sum_{i=1}^m \lambda_j x_{ij} \leq \theta_o^* (x_{io} - \Delta x_{io}), \quad i = 1, \dots, m, \\ & \sum_{i=1}^m \lambda_j y_{rj} \geq y_{ro} - \Delta y_{ro}, \quad r = 1, \dots, s, \\ & \lambda_j \geq 0, \quad j = 1, \dots, n, \\ & \Delta x_{io} \geq 0, \quad i = 1, \dots, m. \end{aligned} \quad (2)$$

که در آن θ_o^* متناظر با کارایی واحد تحت ارزیابی DMU_o است و مقادیر $x_{ij} (i = 1, \dots, m)$ ، $y_{rj} (j = 1, \dots, s)$ و $\Delta y_{ro} (r = 1, \dots, s)$ مقادیر معلوم هستند و هدف تخمین بردار $\Delta x_o = (\Delta x_{1o}, \Delta x_{2o}, \dots, \Delta x_{mo})$ با حفظ کارایی DMU_o است.

۲-۲- الگوریتم PSO

الگوریتم *PSO* یک روش بهینه‌سازی مبتنی بر جمعیت (رفتار اجتماعی پرندگان و ماهی‌ها) است که از حرکت و تعامل تعدادی ذره در فضای جستجو برای یافتن بهینه‌ترین راه حل استفاده می‌کند. الگوریتم *PSO* شامل چند مرحله ساده ولی موثر است که به طور خلاصه شامل موارد زیر است:

۱. مقداردهی اولیه: در این مرحله، مکان و سرعت اولیه ذرات به صورت تصادفی در فضای جستجو تعیین می‌شود. همچنین، بهترین موقعیت هر ذره و بهترین موقعیت در کل جمعیت نیز مشخص می‌شوند.
۲. به روز رسانی سرعت: سرعت هر ذره در هر مرحله بر اساس تجربه خودش و اطلاعات دریافتی از سایر ذرات به روزرسانی می‌شود. این به روز رسانی به صورت زیر است:

$$v_i(t+1) = w \cdot v_i(t) + c_1 \cdot r_1 \cdot (p_i(t) - x_i(t)) + c_2 \cdot r_2 \cdot (g(t) - x_i(t)). \quad (3)$$

که در آن $v_i(t+1)$ سرعت جدید ذره در گام $t+1$ است. w ضریب اینرسی، c_1 و c_2 ضرایب یادگیری (معمولاً بین ۱ تا ۲) و r_1 و r_2 مقادیر تصادفی بین ۰ و ۱ هستند. $p_i(t)$ بهترین موقعیت شخصی ذره i تاکنون و $g(t)$ بهترین موقعیت کل گروه از ذرات تا گام t است.

۳. به روز رسانی موقعیت: موقعیت هر ذره با استفاده از سرعت به روز رسانی شده، به شکل زیر تغییر می‌کند:

$$x_i(t+1) = x_i(t) + v_i(t+1), \quad (4)$$

که در آن $x_i(t+1)$ موقعیت جدید ذره i است.

۴. ارزیابی و به روز رسانی بهترین موقعیت‌ها: پس از به روز رسانی موقعیت‌ها، ذرات بر اساس تابع هدف ارزیابی می‌شوند و بهترین موقعیت شخصی و بهترین موقعیت کلی به روز می‌شود.

۵. تکرار: مراحل به روز رسانی سرعت و موقعیت تا زمانی که یکی از شرایط توقف مانند رسیدن به تعداد تکرار مشخص یا پیدا کردن یک راه حل بهینه برآورده شود، تکرار می‌شوند.

۲-۳- الگوریتم ML

ML نوعی هوش مصنوعی است که در بین متخصصان استفاده می‌شود و به برنامه‌های نرم‌افزاری اجازه می‌دهد تا در پیش‌بینی نتایج خروجی دقیق‌تر عمل کنند، بدون اینکه به طور مستقیم برای انجام این کار برنامه‌ریزی شده باشند. در این روش الگوریتم‌ها با تحلیل داده‌ها، الگوها را شناسایی کرده و برای پیش‌بینی یا طبقه‌بندی اطلاعات جدید استفاده می‌کنند.

رگرسیون چندمتغیره^۱ و شبکه عصبی مصنوعی^۲ دو مدل مهم از یادگیری ماشین هستند که برای تحلیل و پیش‌بینی داده‌ها در مسایل مختلف مانند اقتصاد، پزشکی، مهندسی و علوم داده استفاده می‌شوند. MLR^3 برای مدل‌سازی روابط خطی و ANN برای الگوهای پیچیده و غیرخطی مناسب است.

۱-۳-۲-MLR

MLR یک تکنیک آماری است که برای مدل‌سازی رابطه خطی بین یک متغیر وابسته (خروجی) و چندین متغیر مستقل (ورودی) استفاده می‌شود. این روش از رگرسیون خطی برای تحلیل داده‌ها و پیش‌بینی استفاده می‌کند، اما برخلاف رگرسیون خطی ساده که تنها یک متغیر ورودی دارد، در رگرسیون چندمتغیره، چندین متغیر ورودی می‌توانند وارد مدل شوند.

معادله کلی رگرسیون چندمتغیره به شکل زیر است:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon \quad (۴)$$

که در آن Y متغیر وابسته (خروجی) است که باید پیش‌بینی شود. $X_1, X_2, \dots, X_n$ متغیرهای مستقل (ورودی) هستند. β_0 عرض از مبدا است که مقدار پیش‌بینی شده برای Y زمانی که همه متغیرهای ورودی صفر باشند. $\beta_1, \beta_2, \dots, \beta_n$ ضرایب مدل هستند که تاثیر هر یک از متغیرهای ورودی را روی متغیر خروجی نشان می‌دهند. ε خطای مدل است که نشان‌دهنده تفاوت بین مقدار پیش‌بینی شده و مقدار واقعی است.

۲-۳-۲-ANN

یکی از مهم‌ترین وظایف مدیریت، تصمیم‌گیری است و مهم‌ترین عنصر تصمیم‌گیری، اطلاعات مناسب است. اطلاعاتی که بتواند آینده را بهتر ترسیم نماید منجر به تصمیم‌گیری بهتری خواهد شد. ابزارهای مختلف کمی و کیفی برای تصمیم‌گیری و تامین اطلاعات وجود دارد که یکی از روش‌های کیفی که به عنوان یکی از شاخه‌های AI مطرح است، ANN است. این مدل‌های محاسباتی تحت تاثیر ساختار و عملکرد مغز انسان طراحی شده‌اند تا الگوها و داده‌های پیچیده را پردازش و تجزیه و تحلیل کنند. شبکه‌های عصبی برای حل مسایل متنوعی، مانند دسته‌بندی الگو، خوشه‌یابی، تخمین تابع، پیش‌بینی، بهینه‌سازی، حافظه انجمنی و کنترل در مدیریت به کار می‌رود. یک شبکه عصبی پرسپترون چندلایه‌ای^۴ یکی از انواع ANN است که یک مدل یادگیری عمیق است و از چندین لایه عصبی متصل به هم برای حل مسایل پیچیده استفاده می‌کند. این شبکه شامل سه لایه اصلی است:

۱. لایه ورودی: این لایه داده‌های ورودی را دریافت می‌کند و به لایه‌های بعدی منتقل می‌کند.
۲. لایه‌های پنهان: داده‌ها از لایه ورودی به لایه‌های پنهان منتقل شده و در این لایه‌ها پردازش می‌شوند. تعداد این لایه‌ها می‌تواند متغیر باشد. هر نرون در این لایه به تمام نرون‌های لایه قبلی و بعدی متصل است.
۳. لایه خروجی: در این لایه، پیش‌بینی نهایی یا تصمیم‌گیری نهایی انجام می‌شود.

۳- مدل‌های ترکیبی AI و $Inverse DEA$

مدل‌های $Inverse DEA$ در کنار هوش مصنوعی می‌تواند تصمیم‌گیری دقیق‌تر، بهینه‌سازی منابع و افزایش کارایی سازمانی را ممکن کند. مدل‌های $Inverse DEA$ به طور معمول برای تخصیص منابع و ارزیابی کارایی تصمیم‌گیری واحدهای مختلف مورد استفاده قرار می‌گیرند. با این حال، این مدل‌ها در بسیاری از موارد به ورودی‌ها و خروجی‌های دقیق و بهینه‌شده نیاز دارند تا نتایج قابل اعتمادی ارائه دهند. در اینجا، AI می‌تواند نقشی کلیدی ایفا کند [9].

ترکیب روش‌های AI و $Inverse DEA$ موجب می‌شود که مدل‌ها بتوانند با استفاده از داده‌های پویا و متغیرهای پیچیده، شرایط واقعی اقتصادی و مالی را بهتر شبیه‌سازی کنند. بسیاری از مدل‌های متداول DEA به فرضیات ثابت و داده‌های ایستا وابسته‌اند، در حالی که مدل‌های مبتنی بر AI می‌توانند تغییرات محیطی،

¹ Multiple Linear Regression

² Artificial Neural Networks (ANN)

³ Multiple Linear Regression (MLR)

⁴ Multi Layer Perceptron

روندهای جدید بازار و رفتارهای پویا را در تحلیل خود لحاظ کنند. در نتیجه ترکیب این دو روش، تصمیم‌گیری‌های هوشمندانه‌تر و تخصیص منابع موثرتری را در محیط‌های مالی و سازمانی فراهم می‌کند [10].

بر اساس مقاله‌کندی و همکاران [11]، الگوریتم *PSO* به‌عنوان یک روش فرا ابتکاری مبتنی بر جمعیت، برای حل مسایل پیچیده و چندبعدی طراحی شده است. بر اساس نظر منگ [12] این الگوریتم، به دلیل توانایی جستجوی سراسری و همگرایی سریع، در ترکیب با مدل‌های *Inverse DEA* می‌تواند به بهبود دقت در تخصیص منابع و افزایش بهره‌وری تصمیم‌گیری کمک کند. علاوه بر این، بر اساس بررسی‌های انجام‌شده توسط هایکن [13]، روش‌های *ML* مانند *MLR* و *ANN* به‌طور گسترده برای تحلیل الگوهای پیچیده و غیرخطی در داده‌های مالی مورد استفاده قرار گرفته‌اند. این الگوریتم‌ها، مشابه *PSO*، در ترکیب با مدل‌های *Inverse DEA* می‌توانند دقت تخصیص منابع را افزایش داده و بهینه‌سازی تصمیمات اقتصادی و مالی را بهبود بخشند.

مدل ترکیبی *Inverse DEA + PSO* به‌عنوان یک روش پیشرفته در بهینه‌سازی استفاده می‌شود که از ترکیب ویژگی‌های *DEA* و *PSO* بهره می‌برد. در این مدل ابتدا با استفاده از *Inverse DEA*، ورودی‌ها یا خروجی‌ها به‌گونه‌ای تنظیم می‌شوند که کارایی واحد به حداکثر برسد، سپس با استفاده از *PSO*، پارامترهای ورودی و خروجی بهینه برای رسیدن به بهترین نتیجه (کارایی) جستجو می‌شود.

یکی از چالش‌های اصلی مدل‌های *Inverse DEA* این است که تعیین مقدار ورودی‌ها و خروجی‌های بهینه برای یک سطح مشخص از کارایی، پیچیده و زمان‌بر است. روش‌های *ML* مانند *ANN* می‌توانند الگوهای پنهان در داده‌ها را کشف کرده و مقادیر مناسب را برای *DEA* پیش‌بینی کنند. به‌طور مثال، *ANN* می‌تواند با یادگیری از داده‌های تاریخی، خروجی‌های مورد انتظار را برای یک واحد تصمیم‌گیری خاص ارایه دهد که این امر موجب می‌شود مدل‌های *Inverse DEA* با دقت بیشتری عمل کنند و تخصیص منابع بهینه‌تری انجام شود.

ترکیب روش‌های هوش مصنوعی و *Inverse DEA*، نه تنها باعث افزایش دقت پیش‌بینی و مدل‌سازی سیستم‌های مالی می‌شود، بلکه با شناسایی الگوهای پنهان در داده‌ها، امکان بهینه‌سازی تخصیص منابع و بهبود کارایی سازمان‌ها را در محیط‌های تصمیم‌گیری پیچیده فراهم می‌کند. این رویکردهای ترکیبی می‌توانند کارایی سازمانی را افزایش داده، هزینه‌ها را کاهش داده و بهره‌وری را به حداکثر برسانند. در این رویکرد ابتدا *Inverse DEA* مقدار اولیه را تعیین می‌کند، سپس *ML* با استفاده از داده‌های قبلی، بهینه‌ترین مقادیر را پیش‌بینی می‌کند؛ بنابراین، استفاده از هوش مصنوعی در کنار *Inverse DEA* نه تنها دقت محاسبات را افزایش می‌دهد، بلکه امکان مدیریت بهینه‌تر منابع، کاهش هزینه‌ها و افزایش کارایی سازمان‌ها را نیز فراهم می‌سازد. این ترکیب، راهکاری موثر برای بهبود عملکرد سیستم‌های اقتصادی و مالی در دنیای واقعی محسوب می‌شود.

۴- تخصیص منابع مالی به شعب بانک با استفاده از مدل‌های ترکیبی *Inverse DEA* و *AI*

در این بخش تحلیل دقیقی از مدل‌های *Inverse DEA* و ترکیب آن با الگوریتم‌های *AI* نظیر *PSO* و *ML* (و *ANN*) در صنعت بانکداری ایران مورد مطالعه قرار می‌دهیم، سپس نتایج حاصل از هریک از این روش‌ها را مقایسه می‌کنیم.

برای بررسی دقیق، مورد مطالعه را شامل ۵ شعبه بانک با سه ورودی (X_1, X_2, X_3) و دو خروجی (y_1, y_2) در نظر می‌گیریم. شاخص‌ها عبارتند از:

X_1 : هزینه‌های عملیاتی.

X_2 : تعداد کارمندان شعبه.

X_3 : میزان بودجه تخصیص یافته به هر شعبه.

y_1 : مشتریان جذب شده.

y_2 : تسهیلات پرداختی هر شعبه.

θ : کارایی.

همچنین اطلاعات مربوط به شاخص‌ها برای هر شعبه در جدول ۱ زیر آورده شده است:

جدول ۱- اطلاعات مربوط به ورودی‌ها و خروجی‌های شعب بانک.

Table 1- Information related to bank branch inputs and outputs.

شعبه بانک	X_1	X_2	X_3	y_1	y_2	θ
1	120	15	10	500	5.0	0.85
2	150	18	15	600	6.5	0.90
3	180	20	12	700	7.0	1.00
4	110	12	8	450	4.5	0.80
5	140	16	11	550	5.5	0.88

مدیریت بانک قصد دارد تعداد مشتریان جذب شده در شعبه ۱ را از ۵۰۰ نفر به ۸۰۰ نفر افزایش دهد، درحالی‌که کارایی فعلی شعبه (۰/۸۵) حفظ شود؛ بنابراین، به منظور یافتن منابع مالی موردنیاز با فرض حفظ کارایی از دو روش استفاده می‌کنیم:

۱. مدل *Inverse DEA*.

۲. مدل ترکیبی *Inverse DEA* مبتنی بر هوش مصنوعی.

۴-۱- مدل *Inverse DEA*

از طریق حل مدل *Inverse DEA* در ماهیت ورودی، ورودی‌های جدید مساله به صورت زیر به دست می‌آید:

$$X_1 = 160, \quad X_2 = 20, \quad X_3 = 14,$$

که افزایش ورودی‌ها به ترتیب به میزان ۳۳٪، ۳۳٪ و ۴۰٪ را نشان می‌دهد.

۴-۲- مدل ترکیبی *Inverse DEA* مبتنی بر AI

۴-۲-۱- مدل ترکیبی *Inverse DEA + PSO*

فرآیند حل به این صورت است که در ابتدا *Inverse DEA* مقدار اولیه را پیشنهاد می‌دهد، سپس *PSO* این مقادیر را با توجه به تابع هدف (کاهش هزینه‌ها و حفظ کارایی) اصلاح می‌نماید. درواقع *PSO* به عنوان یک الگوریتم هوش مصنوعی بهینه‌ترین مقادیر ورودی‌ها را برای حفظ کارایی در سطح ۰/۸۵ و دستیابی به ۸۰۰ مشتری با حداقل هزینه به دست می‌آورد.

برای حل این مساله، پارامترهای *PSO* شامل تعداد ذرات ۵۰، تعداد تکرار ۲۰۰، ضریب اینرسی ۰/۷ و ضرایب c_1 و c_2 برابر با ۱/۵ ($C_1=C_2=1.5$) می‌باشند در این مدل، مقدار ورودی‌های جدید (X_1, X_2, X_3) را با حفظ کارایی اولیه (۰/۸۵) تخمین می‌زنیم. ورودی‌های جدید عبارت‌اند از:

$$X_1 = 140, \quad X_2 = 17, \quad X_3 = 11,$$

که کاهش ورودی‌ها به ترتیب به میزان ۱۰٪، ۱۵٪ و ۲۱٪ را نشان می‌دهد، لذا مدل ترکیبی *Inverse DEA + PSO* مقدار بهینه‌تری نسبت به مدل *Inverse DEA* ارائه داد، لذا هزینه‌ها نیز نسبت به قبل کاهش می‌یابد.

۴-۲-۱- مدل ترکیبی *Inverse DEA + ML*

در این مرحله از دو مدل از مدل‌های *ML* شامل *MLR* و *ANN* برای تخمین ورودی‌ها استفاده می‌کنیم.

Inverse DEA + MLR

ابتدا *Inverse DEA* مقدار اولیه را تعیین می کند، سپس *MLR* با استفاده از داده های قبلی، بهینه ترین مقادیر را پیش بینی می کند. در این مدل، مقدار ورودی های جدید (X_1, X_2, X_3) را با حفظ کارایی اولیه (۰/۸۵) تخمین می زنیم. ورودی های جدید عبارت اند از:

$$X_1 = 148, \quad X_2 = 18, \quad X_3 = 12.$$

ملاحظه می شود که این مدل نسبت به مدل *Inverse DEA* نتایج بهتری را ارائه می کند، اما نتایج حاصل از این مدل نسبت به *PSO* میزان ورودی های بیشتری را تخمین زد که متعاقبا هزینه بیشتری نسبت به آن خواهد داشت.

Inverse DEA + ANN

ابتدا *Inverse DEA* مقدار اولیه را تعیین می کند، سپس *ANN* با استفاده از داده های قبلی، بهینه ترین مقادیر را برای افزایش مشتریان به ۸۰۰ نفر پیش بینی می کند. در اینجا *MLP* به کار رفته که پیش بینی دقیق تری نسبت به مدل خطی ارائه می دهد. برای حل این مساله پارامترهای شبکه عصبی شامل دو لایه پنهان با ۱۰ و ۵ نورون، تابع فعال سازی *ReLU* و الگوریتم بهینه سازی *Adam* می باشند.

در این مدل مقدار ورودی های جدید (X_1, X_2, X_3) را با حفظ کارایی اولیه (۰/۸۵) تخمین می زنیم. ورودی های جدید عبارت اند از:

$$X_1 = 140, \quad X_2 = 16, \quad X_3 = 10.5.$$

ملاحظه می گردد که این مدل ترکیبی، مقدار بهینه بهتری نسبت به *MLR* و *PSO* ارائه می دهد، زیرا روابط غیرخطی را نیز در نظر می گیرد.

به طور کلی می توان نتایج حاصل از محاسبات مدل های به کار رفته را به صورت جدول زیر خلاصه نمود:

جدول ۲- نتایج محاسبات.

Table 2- Calculation results.

مدل	X_3	X_2	X_1	کاهش هزینه نسبت به مدل Inverse DEA
Inverse DEA	14	20	160	-
Inverse DEA+PSO	11	17	142	%10
Inverse DEA+MLR	12	18	148	%7
Inverse DEA+ANN	10.5	16	140	%12

اگر هدف مدیریت بانک فقط یافتن یک مقدار تقریبی سریع برای تخصیص منابع باشد، مدل *Inverse DEA* یا *MLR* می تواند به راحتی مورد استفاده قرار گیرد ولی اگر هدف کاهش هزینه ها با حفظ دقت باشد، الگوریتم *PSO* گزینه مناسبی است، زیرا علاوه بر اینکه یک مقدار بهینه ارائه داده، هزینه ها را نیز کاهش می دهد و اگر هدف بهینه سازی پیشرفته و دقیق باشد، *ANN* بهترین گزینه است، زیرا می تواند بهترین مقدار ورودی ها را برای کاهش هزینه ها ارائه دهد؛ بنابراین، استفاده از *Inverse DEA + ANN* موجب حداکثر کاهش هزینه ها بدون کاهش کارایی می شود. در نهایت پیشنهاد می شود یک مدل ترکیبی از *PSO* و *ANN* استفاده شود، زیرا *PSO* می تواند مقدار اولیه را تخمین بزند و *ANN* دقت بهینه سازی را افزایش دهد. این ترکیب می تواند بهترین عملکرد را ارائه دهد و هزینه ها را نیز به حداقل برساند.

۵- نتیجه گیری

مدل های *Inverse DEA* و *AI* هر کدام دارای ویژگی ها، مزایا و معایب خاص خود هستند. ترکیب *Inverse DEA* با الگوریتم های *AI* یک رویکرد نوآورانه برای بهبود تخصیص منابع و افزایش کارایی است. در حالی که مدل های *Inverse DEA* برای تحلیل های ساده و شفاف مناسب هستند، مدل های *AI* توانایی مدل سازی روابط پیچیده تر و پیش بینی دقیق تر را دارند. ترکیب این دو رویکرد می تواند به نتایج بهتری در پیش بینی منابع مالی و دستیابی به کارایی مطلوب منجر شود. برای بهره برداری کامل از هر دو مدل، نیاز به تحلیل دقیق داده ها و انتخاب مناسب ترین ترکیب آن ها برای مسایل خاص وجود دارد. مدل ترکیبی *Inverse DEA + PSO* یک روش موثر برای بهینه سازی و ارزیابی کارایی است که می تواند به ویژه در موقعیت هایی که نیاز به تنظیم ورودی ها و خروجی ها برای بهبود عملکرد وجود دارد بسیار مفید باشد. این ترکیب از قدرت مدل های *DEA* و توانمندی های الگوریتم *PSO* برای جستجوی بهینه، می تواند به تصمیم گیرندگان در راستای بهبود کارایی و کاهش هزینه ها کمک کند. مدل ترکیبی

Inverse DEA + MLR یک روش نوآورانه است که از قدرت هر دو تکنیک *DEA* و *MLR* بهره می‌برد. این مدل به‌ویژه زمانی مفید است که بخواهیم کارایی واحدهای تصمیم‌گیری را بهبود دهیم و در عین حال رابطه پیچیده بین ورودی‌ها و خروجی‌ها را مدل‌سازی کنیم. با استفاده از این مدل می‌توان تصمیمات بهینه‌تری در زمینه بهینه‌سازی عملکرد و تخصیص منابع اتخاذ کرد مدل ترکیبی *Inverse DEA + ANN* یک رویکرد قدرتمند و نوآورانه برای بهبود و تحلیل کارایی است که از ترکیب قدرت *DEA* و *ANN* بهره می‌برد. این مدل به‌ویژه در مواقعی مفید است که نیاز به بهینه‌سازی ورودی‌ها و خروجی‌ها به‌گونه‌ای داریم که روابط پیچیده و غیرخطی بین آن‌ها باید مدل‌سازی و شبیه‌سازی شوند. با استفاده از این مدل، می‌توان کارایی واحدهای تصمیم‌گیرنده را بهبود بخشید و تصمیمات بهینه‌تری در راستای تخصیص منابع و کاهش هزینه‌ها اتخاذ کرد. در این مقاله، ترکیب *Inverse DEA* با روش‌های *AI* مانند *ML* و *PSO* برای پیش‌بینی منابع مالی مورد نیاز برای دستیابی به بهره‌وری مطلوب در شعب بانکی مورد بررسی قرار گرفت. نتایج نشان می‌دهد که مدل‌های ترکیبی می‌توانند تخصیص منابع ورودی بهینه‌تری ارائه دهند که منجر به دستیابی به خروجی‌های مطلوب با دقت بیشتر می‌شود. به‌ویژه، ترکیب *Inverse DEA* با الگوریتم‌های *ML* بهترین نتایج را در پیش‌بینی منابع ورودی داشت، لذا از مزایای ترکیب *Inverse DEA* با روش‌های *AI* می‌توان افزایش دقت، مدیریت پیچیدگی داده‌ها، بهینه‌سازی سریع‌تر، یادگیری غیرخطی پیچیده، افزایش توانمندی در تصمیم‌گیری و کاهش زمان آموزش را نام برد. این ترکیب‌ها به مدل‌ها این امکان را می‌دهند که داده‌ها را بهتر تحلیل کرده، روابط پیچیده‌تری را شبیه‌سازی کرده و تصمیمات بهینه‌تری اتخاذ کنند.

در مقایسه با مدل‌های *Inverse DEA* که صرفاً از روابط خطی و داده‌های ورودی/خروجی استفاده می‌کنند، ترکیب این مدل‌ها با *ML* و *PSO* توانسته است بهبود قابل توجهی در پیش‌بینی تخصیص منابع به‌وجود آورد. *PSO* به جستجوی راه‌حل‌های بهینه کمک می‌کند، *MLR* روابط خطی بین داده‌ها را شناسایی می‌کند و *ANN* می‌تواند روابط غیرخطی و پیچیده را مدل‌سازی کند. این ترکیب از قدرت الگوریتم‌های *AI* برای جستجوی فضای بهینه استفاده می‌کند و قادر است تخصیص‌های دقیق‌تری ارائه دهد که منجر به بهبود کارایی و نهایتاً بهره‌وری در شعب بانکی می‌شود. برای مطالعات آینده می‌توان از ترکیب *Inverse DEA* و الگوریتم‌های *AI* نظیر الگوریتم‌های ژنتیک^۱ و سایر الگوریتم‌های یادگیری عمیق^۲ نیز استفاده نمود.

منابع

- [1] 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. <https://doi.org/10.1287/mnsc.30.9.1078>
- [2] Charnes, A., Cooper, W. W., & Rhodes, E. (1978). Measuring the efficiency of decision making units. *European journal of operational research*, 2(6), 429–444. [https://doi.org/10.1016/0377-2217\(78\)90138-8](https://doi.org/10.1016/0377-2217(78)90138-8)
- [3] 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. <https://doi.org/10.1016/j.seps.2017.01.008>
- [4] Tone, K., & Tsutsui, M. (2009). Network DEA: A slacks-based measure approach. *European journal of operational research*, 197(1), 243–252. <https://doi.org/10.1016/j.ejor.2008.05.027>
- [5] Poli, R., Kennedy, J., & Blackwell, T. (2007). Particle swarm optimization: An overview. *Swarm intelligence*, 1, 33–57. <https://doi.org/10.1007/s11721-007-0002-0>
- [6] Paradi, J. C., Rouatt, S., & Zhu, H. (2011). Two-stage evaluation of bank branch efficiency using data envelopment analysis. *Omega*, 39(1), 99–109. <https://doi.org/10.1016/j.omega.2010.04.002>
- [7] Zhang, X. S., & Cui, J. C. (1999). A project evaluation system in the state economic information system of china an operations research practice in public sectors. *International transactions in operational research*, 6(5), 441–452. <https://doi.org/10.1111/j.1475-3995.1999.tb00166.x>
- [8] Wei, Q., Zhang, J., & Zhang, X. (2000). An inverse DEA model for inputs/outputs estimate. *European journal of operational research*, 121(1), 151–163. [https://doi.org/10.1016/S0377-2217\(99\)00007-7](https://doi.org/10.1016/S0377-2217(99)00007-7)
- [9] Wu, J., Zhu, Q., An, Q., Chu, J., & Ji, X. (2016). Resource allocation based on context-dependent data envelopment analysis and a multi-objective linear programming approach. *Computers & industrial engineering*, 101, 81–90. <https://doi.org/10.1016/j.cie.2016.08.025>
- [10] Li, F., Zhu, Q., & Liang, L. (2019). A new data envelopment analysis based approach for fixed cost allocation. *Annals of operations research*, 274, 347–372. <https://doi.org/10.1007/s10479-018-2819-x>
- [11] Eberhart, R., & Kennedy, J. (1995). Particle swarm optimization. *Proceedings of the IEEE international conference on neural networks* (Vol. 4, pp. 1942–1948). Citeseer. <https://doi.org/10.1109/ICNN.1995.488968>
- [12] Meng, M. (2014). A hybrid particle swarm optimization algorithm for satisficing data envelopment analysis under fuzzy chance constraints. *Expert systems with applications*, 41(4), 2074–2082. <https://doi.org/10.1016/j.eswa.2013.09.007>
- [13] Haykin, S. (1994). *Neural networks: A comprehensive foundation*. Prentice Hall PTR. <https://dl.acm.org/doi/abs/10.5555/541500>

¹ Genetic Algorithms (GA)

² Deep Learning