

Efficiency Estimation using Nonlinear Influences of Time Lags in DEA Using Artificial Neural Networks

Mostafa Kazemi

*Corresponding author, Prof. of Management, Faculty of Economic and Administrative Sciences, Ferdowsi University of Mashhad, Mashhad, Iran. E-mail: kazemi@um.ac.ir

Mohammadali Faezirad

Ph.D. Candidate in Management-Operational Research, Faculty of Economic and Administrative Sciences, Ferdowsi University of Mashhad, Mashhad, Iran. E-mail: faezirad@mail.um.ac.ir

Abstract

Objective: One of the common methods for the assessment of an organization's efficiency is comparison with other competitors. However, some researchers have studied the efficiency of a unit within itself during different periods of time and it is used to investigate the performance trend of the unit during previous times. The purpose of this research is to forecast the performance of a unit using the previous time series of its performance.

Methods: This research conducts comparison and efficiency analysis of a unit during different time periods using SBM and DEA models. And then, the outcome is considered as the training elements of an ANN, so efficiency of future time steps can be estimated for that unit.

Results: An industrial unit in Steel industry was studied in this research and its decreasing performance trend during ten years has been presented after efficiency measurements. Implementing different structures of ANNs, finally, we found out that a recurrent neural network with 10 neurons in a hidden layer and Bayesian Regularization algorithm had the best performance for future forecasting of efficiency.

Conclusion: The most important achievement of this study is efficiency forecasting for organizations' future using the existing data with regards to the influences of previous time steps on current efficiency by a nonlinear approach. It would lead to providing a clear image of the organization's future as represented for the case of this paper.

Keywords: Data Envelopment Analysis (DEA), Artificial Neural Networks (ANN), Performance analysis, Time series forecasting, SBM.

Citation: Kazemi, M., Faezirad, M. (2018). Efficiency Estimation using Nonlinear Influences of Time Lags in DEA Using Artificial Neural Networks. *Industrial Management Journal*, 10(1), 17-34. (in Persian)

Industrial Management Journal, 2018, Vol. 10, No.1, pp. 17-34

DOI: 10.22059/imj.2018.129192.1006898

Received: August 1, 2015; Accepted: August 8, 2017

© Faculty of Management, University of Tehran

پیش‌بینی کارایی به کمک تأثیرپذیری غیرخطی از تأخیرهای زمانی در تحلیل پوششی داده‌ها با شبکه‌های عصبی مصنوعی

مصطفی کاظمی

* نویسنده مسئول، استاد گروه مدیریت، دانشکده علوم اداری و اقتصاد، دانشگاه فردوسی مشهد، مشهد، ایران. رایانامه:
kazemi@um.ac.ir

محمدعلی فائضی راد

دانشجوی دکتری مدیریت تحقیق در عملیات، دانشکده علوم اداری و اقتصاد، دانشگاه فردوسی مشهد، مشهد، ایران. رایانامه:
faezirad@mail.um.ac.ir

چکیده

هدف: یکی از شیوه‌های مرسوم ارزیابی کارایی هر سازمان یا بنگاه، مقایسه آن با سایر رقبا یا نمونه‌های متناظر آن است. با این حال، در برخی پژوهش‌ها به سنجش کارایی یک واحد در مقایسه با خود در مرور زمان پرداخته شده و روند عملکرد یک واحد نسبت به گذشته خود ارزیابی شده است. هدف پژوهش جاری، پیش‌بینی کارایی یک واحد با استفاده از استفاده از سری‌های زمانی عملکرد گذشته آن است.

روش: این پژوهش به کمک مدل SBM و با استفاده از روش تحلیل پوششی داده‌ها به مقایسه و سنجش کارایی یک واحد در گام‌های زمانی مختلف پرداخته و خروجی آن را به عنوان عناصر آموزش یک شبکه عصبی مصنوعی در نظر گرفته است تا کارایی گام‌های زمانی بعدی پیش‌بینی شود.

یافته‌ها: مورد مطالعه این پژوهش، یک واحد صنعتی بزرگ در صنعت فولاد کشور است که پس از سنجش کارایی، روند نزولی عملکرد آن طی ده سال ارائه شده است. با پیاده‌سازی ساختارهای مختلف از شبکه‌های عصبی مصنوعی، در نهایت یک شبکه عصبی بازگشته با ۱۰ نرون در لایه پنهان با الگوریتم آموزش پس‌انتشار بیزی توانست بهترین عملکرد را در پیش‌بینی کارایی آتی این واحد صنعتی کسب کند.

نتیجه‌گیری: مزیت اساسی این پژوهش، ارائه پیش‌بینی کارایی برای آینده سازمان بر اساس داده‌های موجود و با در نظر گرفتن تأثیر عوامل دوره‌های زمانی قبلی در کارایی دوره کنونی با رویکردی غیرخطی است. این موضوع موجب خواهد شد که تصویر روشن‌تری از عملکرد آتی سازمان فراهم آید، همان‌طور که در مورد مطالعه پژوهش حاضر، این موضوع رخ داده است.

کلیدواژه‌ها: تحلیل پوششی داده‌ها (DEA)، شبکه عصبی مصنوعی، ارزیابی عملکرد، پیش‌بینی سری زمانی، مدل SBM.

استناد: کاظمی، مصطفی؛ فائضی راد، محمد علی (۱۳۹۷). پیش‌بینی کارایی به کمک تأثیرپذیری غیرخطی از تأخیرهای زمانی در تحلیل پوششی داده‌ها با شبکه‌های عصبی مصنوعی. *فصلنامه مدیریت صنعتی*, ۱۰(۱)، ۱۷-۳۴.

فصلنامه مدیریت صنعتی، ۱۳۹۷، دوره ۱۰، شماره ۱، صص. ۱۷-۳۴

DOI: 10.22059/imnj.2018.129192.1006898

دریافت: ۱۳۹۴/۰۵/۱۷، پذیرش: ۱۳۹۶/۰۵/۱۷

© دانشکده مدیریت دانشگاه تهران

مقدمه

ارزیابی کارایی و اندازه‌گیری عملکرد یکی از مهم‌ترین عوامل تحلیل سازمان‌های امروزی است. اندازه‌گیری عملکرد اصطلاحی است که درباره آن بحث و بررسی بسیاری شده ولی به ندرت تعریف روشی از آن ارائه می‌شود. به طور خلاصه می‌توان اظهار کرد که اندازه‌گیری عملکرد به معنای فرایند کمی کردن افعال است که فرایند کمی کردن را اندازه‌گیری گویند (نیلای، گرگوری و پلاتس، ۱۹۹۵).

تحلیل پوششی داده‌ها^۱ به عنوان ابزاری محبوب در اندازه‌گیری عملکرد و تجزیه و تحلیل آن تلقی می‌شود. این ابزار، از زمان پیدایش آن در سال ۱۹۷۰ رشد مداوم و توأمی در مطالعات نظری و تجربی داشته است، از این رو هم از بُعد ذاتی غنی شده و هم در ابعاد تجربی و عملیاتی، پژوهش‌های کاربردی فراوانی را صورت داده است (کوان و لی، ۲۰۱۵). تکنیک‌های کلاسیک تحلیل پوششی داده‌ها، کارایی متجانس را در یک زمان خاص محاسبه می‌کنند. از این رو، در این پژوهش به منظور پیش‌بینی کارایی آتی واحد تصمیم مدنظر، تأثیرات مربوط به کارایی متجانس زمان‌های پیشین نیز به صورت تأخیر^۲ در مدل سری زمانی ظاهر می‌شود. این امر موجب می‌شود که تأثیرپذیری کارایی از شرایط کنونی واحد تصمیم نباشد، بلکه شرایط پیشین در این موضوع تأثیرگذار باشند. همین موضوع مسئله اصلی پژوهش را تشکیل می‌دهد. این پژوهش تلاش می‌کند تا با استفاده از داده‌های پیشین مربوط به عملکرد سازمان به تخمین و پیش‌بینی روند آتی سازمان پیردازد. اهمیت این مسئله زمانی روش‌تر می‌شود که عدم ادارک و توانایی پیش‌بینی آینده سازمان توانایی تصمیم را از مدیران گرفته باشد، در حالی که طیف وسیعی از عملکرد پیشین در بانک‌های اطلاعاتی سازمان وجود دارد و می‌تواند مبنای تصمیم‌سازی باشد.

اگرچه در اغلب مطالعات کاربردی DEA، هر DMU نمایان‌گر یک واحد تصمیم است، اما در برخی مطالعات فقط یک واحد تصمیم بررسی شده و DMU‌ها نمایان‌گر مقاطع زمانی خواهند بود. چنین رفتاری موجب می‌شود که بتوان یک واحد تصمیم را نسبت به عملکرد آن در مقاطع زمانی مختلف با خودش مقایسه کرد. این عمل در نهایت ارزیابی زمانی مربوط به یک واحد تصمیم را فراهم خواهد آورد، اگرچه می‌توان چنین ارزیابی را برای چندین واحد به صورت توأم می‌داند. این امر علاوه بر ایجاد قدرت مقایسه آن واحد با خودش طی زمان، این امکان را ایجاد می‌کند که بتوان کارایی آتی را بر اساس روند کارایی گذشته آن تخمین زد. چنین رویکردی بر پایه پیش‌بینی سری‌های زمانی بنا شده و در این پژوهش، شبکه عصبی مصنوعی به عنوان ابزار تحلیل سری زمانی ذکر شده به کار گرفته می‌شود. به طور خلاصه، از این پژوهش چهار ویژگی مهم به دست خواهد آمد:

۱. توانایی مقایسه واحد مدنظر با خودش طی زمان (در مقاطع گام‌های سری زمانی) ایجاد می‌شود.

1. Data envelopment analysis

2. Lag

۲. به دلیل ایجاد سری زمانی (مشتمل بر کارایی‌ها، ورودی‌ها و خروجی‌های سیستم) قدرت پیش‌بینی کارایی آتی ایجاد خواهد شد.
۳. با توجه به ماهیت سری زمانی و تأثیرپذیری از گام‌های پیشین، تأثیرات ورودی‌ها و خروجی‌های مقاطع زمانی قبلی در کارایی امروز دخیل می‌شوند که این موضوع موجب رعایت زمان بر بودن تأثیرات در نگاه DEA می‌شود.
۴. به دلیل استفاده از شبکه‌های عصبی مصنوعی، بین شاخص‌ها روابط غیرخطی در نظر گرفته می‌شود و همین موضوع موجب نزدیک‌تر شدن تحلیل‌ها به واقعیت موجود در دنیای پیرامون خواهد شد. زیرا دنیای پیرامون ما اساساً دنیایی پیچیده با عوامل مختلف بوده و روابط خطی در این فضای پیچیده جای کمتری خواهند داشت. در پایان، با استفاده از خروجی شبکه مصنوعی توانایی تحلیل و پیش‌بینی کارایی آینده فراهم خواهد شد که در بخش نتایج و روش‌شناسی به جزئیات آن اشاره شده است.

پیشنهاد پژوهش

اندازه‌گیری کارایی می‌تواند پشتونه مهمی برای برنامه‌ریزی آتی سازمان‌ها باشد. در روش‌های معمول اندازه‌گیری کارایی، عملکرد یک سازمان‌های با سایر سازمان‌های مشابه مقایسه شده و در نهایت به آگاهی از سطح و میزان کارایی منجر می‌شود. در این بین، رویکرد تحلیل پوششی داده‌ها راچی را برای اندازه‌گیری کارایی به حساب می‌آید، اما به طور سنتی برای مقایسه کارایی چندین DMU استفاده می‌شود (علی‌نژاد، ۱۳۹۷). رویکرد دیگری که تغییرات عامل زمان را برای روی یک واحد در نظر گرفته و DMU‌ها را بر اساس همان واحد در بستر زمان می‌سازد، وجود دارد (پولدر و گواچ، تکاویچ و جانکویچ، ۲۰۱۶). کوپر، دنگ، گو، لی و ترال (۲۰۰۱) در پژوهشی این رویکرد از تحلیل پوششی داده‌ها را برای صنایع چین در سال‌های ۱۹۸۱ تا ۱۹۹۷ اجرا کردند. جهانشاهلو و خدابخشی نیز چنین مدلی را برای صنعت پارچه چین در همین بازه سال‌ها پیاده‌سازی کردند (جهانشاهلو و خدابخشی، ۲۰۰۴). در مدلی دیگر اشرفی، سیو، لی و لی (۲۰۱۳) کارایی صنعت هتلداری سنگاپور را در بازه ۱۹۹۵ تا ۲۰۱۰ با استفاده از همین رویکرد DEA سنجیدند. سیفرت و ژو (۱۹۹۸) در پژوهشی به اجرای مدل وزن دارشده DEA برای بررسی بهره‌وری صنایع چینی طی سال‌های ۱۹۵۳ تا ۱۹۹۰ پرداختند. همچنین در پژوهشی که حجازی، انواری رستمی و مقدسی (۱۳۸۷) به انجام رسانند، این مدل را با رویکرد مدل SBM برای بهره‌وری بانک توسعه صادرات در سال‌های ۱۳۷۳ تا ۱۳۸۴ به کار بستند.

ضعف تحلیل پوششی داده‌ها در استفاده از داده‌های پیشین برای پیش‌بینی آینده و فقدان رویکرد آینده‌نگر آن موجب شده است که ترکیبات مختلفی از آن با روش‌های آینده‌نگر ایجاد شود (شعبان‌پور، یوسفی و فرضی‌پور، ۲۰۱۷). ترکیب تحلیل پوششی داده‌ها و شبکه‌های عصبی مصنوعی از دو دهه پیش با پژوهش‌هایی در حوزه نتایج روش DEA و مقایسه آن با نتایج شبکه‌های عصبی آغاز شد (آتاناسوفلوس و کورام، ۱۹۹۶) که از جمله آن‌ها یک مدل کارایی با داده‌های سری زمانی بود که تحلیل شد و نتایج حاصل از آن به شباهت خروجی شبکه عصبی مصنوعی با حداقل مربعات معمولی اصلاح شده و روش DEA تأکید می‌کرد (کاستا و مارکلوس، ۱۹۹۷). تا به امروز پژوهش‌های گوناگونی با ترکیب

روش ANN و DEA صورت گرفته که اغلب بر پایه ترکیب یا مقایسه بوده است (اجلی و صفری، ۱۳۹۰). از جمله پژوهش‌های مبتنی بر ترکیب DEA و ANN، ارائه رویکردهایی در پردازش سری‌های زمانی به منظور پیش‌بینی و تخمین آن‌ها است. سیلوا، آلوس، دی ماتوس نتو و فریرا در سال ۲۰۱۴ مقاله‌ای ارائه کردند که در آن تخمین تابعی که شبکه عصبی مصنوعی برای برآورد سری زمانی پیشنهاد می‌کند، با روش DEA ارزیابی می‌شود. بهترین برآذش با رویکرد DEA انتخاب شده و پارامترهای آن به عنوان بهترین عملکرد ترکیبی شبکه عصبی و الگوریتم‌های فرگشتی (EA)^۱ در نظر گرفته شده است. در پژوهش دیگری، به منظور تخمین تابع تقاضا از ترکیب ANN، تحلیل مؤلفه‌های PCA) و DEA استفاده شده است. در این پژوهش، یک الگوریتم جامع هوش مصنوعی برای تحلیل روند سری زمانی بی‌ثبات برای داده‌های مصرف برق ارائه شده که در آن تحلیل پوششی داده‌ها به منظور مقایسه ساختارهای مختلف آموزش شبکه عصبی که بر اساس داده‌های موجود پیشنهاد می‌شود، به کار رفته است (خیرخواه، آزاده، صابری، آذرون و شکوری، ۱۳۲۰). همچنین، کوان با ارائه پژوهشی در صنعت راه‌آهن ایالات متحده به بررسی پیوند شبکه‌های عصبی و تحلیل پوششی داده‌ها به منظور مدل‌سازی عملکرد پرداخت و با ارائه یک مدل دو بخشی بر فقدان توانایی پیش‌بینی در DEA با کمک شبکه عصبی BPNN غلبه کرد (کوان، ۱۷۰۲). در پژوهش تازه‌ای، با استفاده از ترکیب تحلیل پوششی داده‌های پویا و شبکه عصبی به منظور پیش‌بینی کارایی آتی واحدهای تصمیم طی یک مدل چندمرحله‌ای استفاده شده است تا در نهایت DEA بتواند به طور همزمان واحدهای تصمیم را در گذشته، حال و آینده ارزیابی کند (شعبان‌پور و همکاران، ۱۷۰۲).

روش‌شناسی پژوهش

تحلیل پوششی داده‌ها (DEA) در سال ۱۹۷۸ توسط چارنز و همکاران معرفی شد (کوان و لی، ۲۰۱۵) و امروزه به عنوان یکی از محبوب‌ترین روش‌های اندازه‌گیری عملکرد گسترش یافته است. این روش، یک تکنیک اندازه‌گیری کمی برای کارایی (یا ناکارایی) نسبی واحدهای ناکارا در برابر واحدهای کارا است که کلیه این واحدها دارای شاخص‌های ورودی و خروجی یکسان و سیستم تبدیل ورودی و خروجی مشابه هستند (کاظمی، ابراهیمپور و ایل‌بیگی، ۱۳۹۲). مدل‌های DEA میزان توانایی هر واحد تصمیم (DMU) را در تبدیل ورودی‌ها به خروجی‌ها ارزیابی کرده و این میزان توانایی را تحت عنوان «کارایی» گزارش می‌کند. به بیان دقیق‌تر در این روش، ابتدا مجموعه امکان تولید با روش‌های برنامه‌ریزی خطی به دست آمده، سپس یک مرز کارایی (واحدهای کارا روی آن قرار می‌گیرند) و مجموعه‌ای از واحدهای ناکارا ایجاد می‌شوند (علیرضایی، افشاریان و تسلیمی، ۱۳۸۶).

مبانی DEA یک برنامه‌ریزی خطی ناپارامتریک است که بهره‌وری نسبی چندین واحد تصمیم (DMU) را ارزیابی می‌کند (ما، ۲۰۱۵). از تحلیل پوششی داده‌ها برخلاف رویکرد مرسوم آن، که چندین DMU را در یک بازه زمانی یا چند بازه زمانی به صورت نسبی با یکدیگر مقایسه می‌کند، رویکرد خاصی وجود دارد که مقدار کارایی را برای یک DMU در

1. Evolutionary Algorithms
2. Decision Making Unit

چندین دوره زمانی نسبت به خود محاسبه می‌کند تا توانایی ارزیابی عملکرد یک واحد نسبت به خود آن واحد در بستر زمان ایجاد شود که در پیاده‌سازی ریاضی آن به مدل پنجره شباهت پیدا می‌کند (کوپر، سیفورد و ژو، ۲۰۱۱).

یکی از مدل‌های توسعه‌یافته DEA، مدل SBM^۱ است که طی پژوهش‌هایی در سال ۲۰۰۱ منتشر شد. این مدل به طور مستقیم از متغیرهای کمکی (مازاد ورودی‌ها و کمبود خروجی‌ها) استفاده می‌کند و بر کاهش ورودی‌ها و افزایش خروجی‌ها به طور همزمان تمرکز دارد. مدل SBM در نهایت برای هر DMU یک مقدار اسکالر را به عنوان کارایی گزارش می‌کند (تون، ۲۰۰۱). ویژگی مهم SBM آن است که به دلیل اینکه بسیاری از سازمان‌ها به منظور افزایش بهره‌وری خود نمی‌توانند صرفاً از کاهش ورودی‌ها یا افزایش خروجی‌ها استفاده کنند، این روش برای تعدیلات همزمان ورودی‌ها و خروجی‌ها توسعه داده شده است (حجازی و همکاران، ۱۳۸۷). یکی از مزایای مهم SBM عدم حساسیت آن به ابعاد و مقیاس شاخص‌ها است و همین موضوع نیاز به نرم‌الایز کردن مقادیر را از بین می‌برد (شکینی، ونانسی، پیری و چیکوری، ۲۰۱۸).

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی (ANN)^۲، ابزاری برای مدل‌سازی هوشمند ناپارامتریک مبتنی بر داده هستند که روابط غیرخطی را آموخته و بین متغیرهای ورودی و خروجی ارتباط برقرار می‌کنند (کوان، ۲۰۱۷). شبکه‌های عصبی مصنوعی مانند شبکه‌های عصبی بیولوژیک پیچیده نیستند، اما دو شباهت اساسی به آن‌ها دارند. نخست شباهت ساختمان و اجزای تشکیل‌دهنده آن‌هاست و شباهت دیگر ارتباط بین نرون‌ها است که تعیین کننده شیوه کار شبکه خواهد بود (هاگان، دیموث و بیل، ۲۰۰۲). به طور کلی، می‌توان گفت که شبکه‌های عصبی از لایه‌های نرونی تشکیل شده است به طوری که این نرون‌ها از طریق ورودی‌های خود با جهان واقعی در ارتباط هستند و از طریق خروجی‌های خویش جهان واقعی را می‌سازند (تسای و لیو، ۲۰۰۹).

یکی از متدائل‌ترین شبکه‌ها، شبکه عصبی پرسپترون با الگوریتم پسانشوار^۳ است که در برآش و پیش‌بینی آینده، عملکرد خوبی از خود نشان داده است. شبکه پسانشوار یک شبکه نگاشت‌کننده چندلایه است که خطاهای را به صورت بازگشته کمینه می‌کند (زنگ، زنگ، چوی و وانگ، ۲۰۱۷).

شبکه‌های عصبی امروزه در حوزه‌های مختلفی به کار گرفته شده و مدام در حال توسعه هستند. از جمله آن‌ها، حوزه پیش‌بینی بر اساس سری‌های زمانی است (ادیکاری، ۲۰۱۵). اگرچه به منظور پیش‌بینی سری‌های زمانی روش‌های مختلفی نظریه‌داری باکس - جنکینز (هیلیر و لیبرمن، ۱۳۹۱) یا مدل‌های خودرگرسیو آماری توسعه یافته‌اند اما این روش‌ها دارای محدودیت‌های ذاتی هستند (لیانگ، ۲۰۰۵). محدودیت نخست آن است که تعیین مدلی با بهترین تناسب برای مسئله نیاز به تخصص دارد، در غیر این صورت ممکن است ساختار تابعی نادرست ایجاد شود. محدودیت دیگر این مدل‌ها عدم مدل شدن برخی از انواع رفتارهای غیرخطی است که به دلیل ساختار توابع ترجیحی این روش‌ها است. از این‌رو، شبکه‌های عصبی مصنوعی برای غلبه بر این محدودیت‌ها در مدل‌سازی سری‌های زمانی غیرخطی گسترش

1. Slack-Based Measure

2. Artificial Neural Network

3. Back Propagation

یافته‌اند. با وجود این، به منظور کاهش مربعات ریسک تجربی بر اساس توابع خطای نیاز است معماری مناسبی برای شبکه عصبی ایجاد شود و برخی از شاخص‌های آن دست‌خوش تغییرات شوند (کوجادال و آشیگیل، ۲۰۱۴). توانایی شبکه‌های عصبی با الگوریتم پسانشان باعث شده است که در بسیاری از پیش‌بینی‌های غیرخطی از آن استفاده شود و پاسخ‌های ارزش‌نده‌ای ارائه کند (زنگ و همکاران، ۲۰۱۷).

رویکردهای ادغامی ANN و DEA

مدل سازی با شبکه‌های عصبی به ایجاد یک مدل «جعبه سیاه» برای مسائل و روابط پیچیده منجر می‌شود. این جعبه سیاه که اساس شبکه‌های عصبی مصنوعی را تشکیل می‌دهد، به شناسایی منطق و روابط حاکم بین داده‌ها کمک شایانی خواهد کرد (ساموئلینکو و برایسون، ۲۰۱۰). مدل‌های پیشین و حتی کنونی تحلیل پوششی داده‌ها به طور گسترده‌ای به داده‌های قلی عملکرد نیاز دارند و نمی‌توانند کارایی آینده‌نگر را برای تصمیم‌گیری ارائه کنند (شعبان‌پور و همکاران، ۲۰۱۷). از آنجا که تحلیل پوششی داده‌ها نیز رویکردی داده‌بینیان است، حضور شبکه‌های عصبی مصنوعی در کنار آن می‌تواند مؤثر باشد.

در پژوهش‌های انجام‌گرفته در حوزه ترکیب ANN و DEA بر پایه سری‌های زمانی، رویکرد غالب انتخاب بهترین برازش یا بهترین ساختار برای شبکه مصنوعی با استفاده از روش تحلیل پوششی داده‌ها است، در صورتی که در این پژوهش رویکردی متفاوت حاکم است. اساس استفاده توأمان این دو رویکرد در پژوهش جاری، تخمین و پیش‌بینی کارایی آتی با استفاده از خوراندن نتایج DEA به شبکه عصبی مصنوعی است. چنین روندی، عملاً رویکردی دو مرحله‌ای است که موجب در نظر گرفته شدن روابط و تأثیرات گام‌های زمانی پیشین خواهد شد. به دلیل استفاده از ابزار شبکه عصبی مصنوعی به منظور در نظر گرفتن این تأثیرات، امکان بسیار خوبی نظیر کشف منطق روابط غیرخطی ایجاد می‌شود که حرکت تصمیم‌گیرندگان را به سمت واقعیت دنیای پیرامون تسهیل خواهد کرد.

مدل پیشنهادی پژوهش

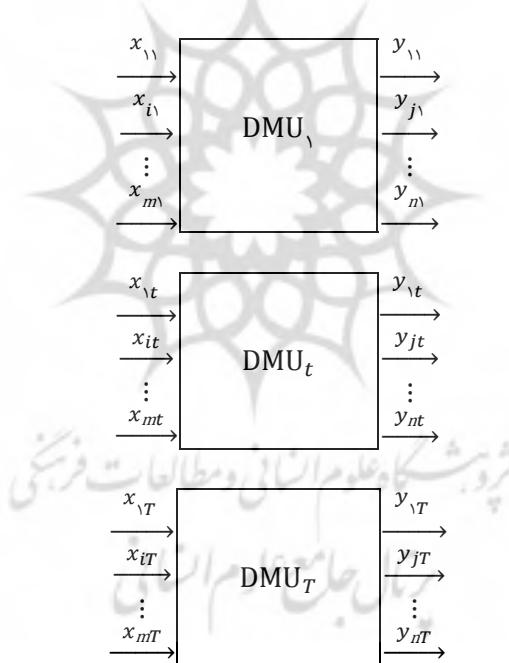
مدل مفهومی پژوهش در شکل ۱ ارائه شده است. این مدل، پنج گام اصلی را برای انجام پژوهش بر می‌شمارد که در نهایت به پیش‌بینی و تحلیل کارایی آینده واحد مورد بررسی ختم خواهد شد.



شکل ۱. مدل مفهومی روند محاسباتی پژوهش

تفاوت اساسی رویکرد بالا با تحلیل پوششی داده‌های پویا^۱ بر سر آن است که در اینجا هیچ رابطه روشنی بین DMU‌های هر گام زمانی با گام‌های بعدی تعریف نمی‌شود. به عبارتی، نیازی به این نیست که تصمیم‌گیرنده روابط بین گام‌های زمانی را تعریف کند و بخشی از ورودی‌ها یا خروجی‌های یک گام را به گام بعدی اختصاص دهد، بلکه در این حالت روابط پنهان بین گام‌های زمانی با شبکه عصبی تشخیص داده شده و بر اساس آن به محاسبه نتایج پرداخته می‌شود. مزیت دیگر این مدل آن است که در مدل‌سازی سری زمانی با ANN روابط غیرخطی حاکم بین عناصر و شاخص‌ها و کارایی‌ها محاسبه شده و این روابط مبنای کاهش خطای خواهند شد. این موضوع، خود موجب غنی‌تر شدن پژوهش جاری است، زیرا روابط ساده خطی بین کارایی‌ها و شاخص‌ها این بار با یک الگوریتم غیرخطی پردازش می‌شود.

اگر تعداد اطلاعات زمانی واحد مورد بررسی را برابر با T گام در نظر بگیریم، برای مدل‌سازی تحت مفاهیم DEA، تعداد DMU‌های مورد بررسی برابر با T خواهد بود، که اگرچه یک واحد تصمیم مورد بررسی داریم اما به تعداد اطلاعات زمانی آن برای تحلیل پوششی داده‌ها، DMU تعریف می‌کنیم. هر یک از DMU‌های تعریف شده نیز، دارای m شاخص ورودی (x_{it}) و n شاخص خروجی (y_{jt}) هستند. شکل ۲ این چیز را به خوبی نمایش می‌دهد.



شکل ۲. چینش DMU‌های زمانی و ورودی‌ها و خروجی‌های هر یک

شیوه محاسبه کارایی برای هر یک از DMU‌های زمانی، بر اساس مدل SBM بوده است، از این رو مدل برنامه‌ریزی خطی زیر ارائه می‌شود (تون، ۲۰۰۱). این مدل برای تعداد T واحد DMU تعریف شده که در آن $Y = [y_{jt}] \in \mathbb{R}^{n \times T}$ و $X = [x_{it}] \in \mathbb{R}^{m \times T}$ هستند.

$$\min \rho_o = k - \frac{1}{m} \sum_{i=1}^m \frac{S_i^-}{x_{io}} \quad (1)$$

S. to

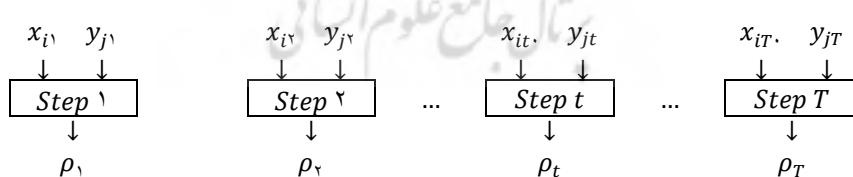
$$\begin{aligned} k + \frac{1}{n} \sum_{j=1}^n \frac{S_j^+}{y_{jo}} &= 1 \\ kx_o &= X\Lambda + S^- \\ ky_o &= Y\Lambda - S^+ \\ \sum_{t=1}^T \Lambda_t &= 1 \\ \Lambda &\geq 0, k > 0, S^- \geq 0, S^+ \geq 0 \end{aligned}$$

در مدل خطی بالا، برای هر $DMU(x_o, y_o)$ داریم:

$$\begin{cases} x_o = X\lambda + s^- \\ y_o = Y\lambda - s^+ \end{cases} \quad (2)$$

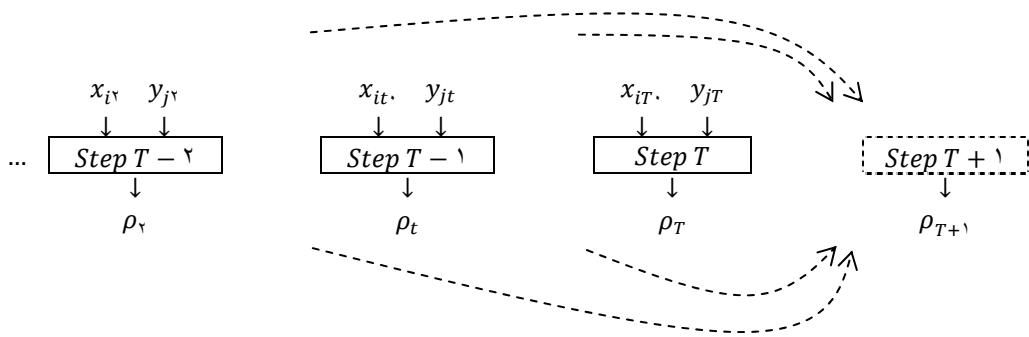
که در عبارات بالا، بردارهای $s^- \in \mathbb{R}^m$ و $s^+ \in \mathbb{R}^n$ به ترتیب نشانگر مازاد ورودی‌ها و کمبود خروجی‌ها هستند. همچنین بردارهای $\Lambda = k\lambda, S^- = ks^-, S^+ = ks^+$ نیز به منظور ارائه این مدل، تعریف شده‌اند. اکنون با استفاده از مدل بالا، می‌توان مقدار کارایی هر یک از گام‌های زمانی را بر اساس ورودی‌ها و خروجی‌های متناظر آن گام زمانی (t) محاسبه کرد. پس از حاصل شدن مقادیر کارایی $\rho_1, \rho_2, \dots, \rho_t, \dots, \rho_T$ می‌توان رویکرد پیشنهادی این پژوهش را پیاده‌سازی کرد.

با استفاده از مقادیر کارایی DMU ‌ها به عنوان مقادیر هدف برای هر گام زمانی و قرار دادن مقادیر ورودی و خروجی DMU ‌ها به عنوان ورودی‌های هر گام زمانی، یک سری زمانی با T گام ایجاد می‌شود که در پی مدل‌سازی آن برمی‌آییم. شکل ۳ این سری زمانی را نمایش می‌دهد.



شکل ۳. سری زمانی با مقادیر کارایی حاصل از مدل SBM تحلیل پوششی داده‌ها

با توجه به سری زمانی بالا می‌توان فرض تأخیرهای زمانی کارایی را وارد مدل کرد. این فرض کمک می‌کند که پیش‌بینی کارایی گام زمانی بعدی ($T + 1$) را با استفاده از ایجاد تأخیر به منظور پذیرش تأثیر ورودی‌های گام‌های قبلی ارائه کنیم. با این فرض، مدل بالا توان پیش‌بینی گام بعدی زمانی را دارا بوده و کارایی آینده را تخمین می‌زند. به طور مثال، در شکل ۴، پیش‌بینی بر اساس دو گام زمانی پیشین (تأخیر برابر با ۲ گام) به تصویر کشیده شده است.

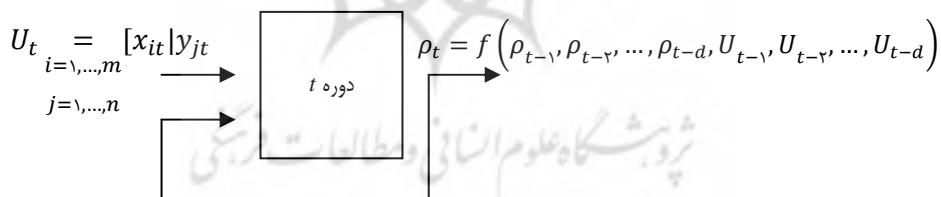


شکل ۴. در نظر گرفتن تأخیرهای زمانی در کارایی حاصل از DEA

با توجه به این توضیحات، می‌توان یک مدل سری زمانی را به منظور پیش‌بینی آتی ایجاد کرد. در این پژوهش، با توجه به ویژگی‌های مهم شبکه‌های عصبی مصنوعی، از این شبکه برای ایجاد مدل بالا استفاده می‌شود. مدل ایجادشده، مدلی غیرخطی با روابط بازگشتی بوده که به شکل زیر برای هر گام زمانی تعریف می‌شود:

$$\rho_t = f(\rho_{t-1}, \rho_{t-2}, \dots, \rho_{t-d}, U_{t-1}, U_{t-2}, \dots, U_{t-d}) \quad \text{رابطه (۳)}$$

که در آن، ρ_t کارایی دوره t بوده و U_t مجموعه بردارهای ورودی x_i و y_j برای دوره t است. مقدار d برابر با تعداد گام‌های زمانی تأخیر (Lag) برای تأثیر در مقدار مورد پیش‌بینی است. با توجه به روابط بازگشتی و تأثیرات مقادیر کارایی‌ها (به عنوان خروجی سری زمانی) در مقادیر آتی، این مدل را می‌توان در قالب شکل ۵ نمایش داد.

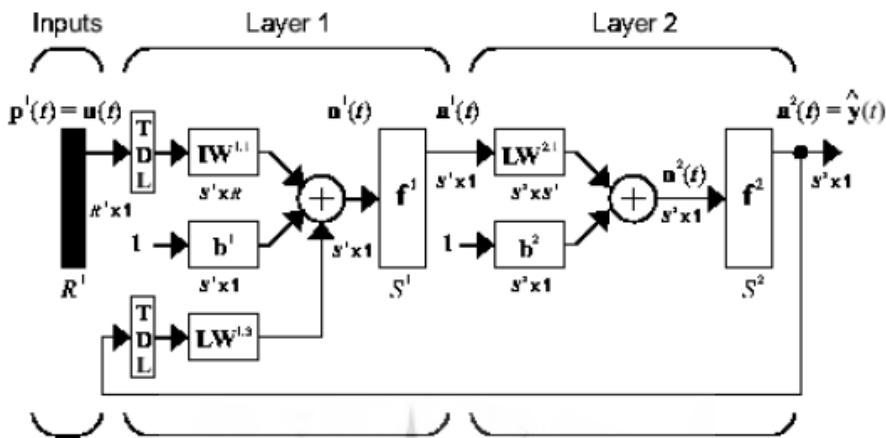


شکل ۵. مدل NARX برای هر دوره زمانی

این مدل، یک مدل غیرخطی خودرگرسیو (NARX)^۱ با روابط بازگشتی است که در این پژوهش از طریق شبکه عصبی مصنوعی با یادگیری پس انتشار، محاسبه می‌شود. به منظور پیاده‌سازی سری زمانی بالا با شبکه عصبی، از شبکه عصبی بازگشتی استفاده شده است تا بتوان علاوه بر محاسبات غیرخطی مدل، روابط بازگشتی مدل را نیز پیاده‌سازی کرد. به منظور پیاده‌سازی این شبکه، معماری‌های مختلف و روش‌های آموزش متفاوت در نظر گرفته شده و بر اساس ترکیب آن‌ها بهترین خروجی محاسبه می‌شود. به منظور تعیین تعداد نرون‌ها و تعداد لایه‌های پنهان منطق‌های مختلفی گسترش یافته‌اند، از جمله آن‌ها می‌توان به رویکرد انک و سورافان (۲۰۰۶) اشاره کرد که وجود یک یا دو لایه را برای

1. Nonlinear Autoregressive with Exogenous Inputs

پردازش اغلب اطلاعات کافی می‌داند. انتخاب تعداد مناسب نرون‌های لایه (های) پنهان از وقوع بیش‌برازش^۱ در شبکه جلوگیری خواهد کرد. در این پژوهش نیز، تعداد لایه برابر با یک و دو در نظر گرفته شده و نرون‌ها نیز در بازه ذکر شده تعیین شده‌اند. ساختار ساده یک شبکه عصبی مصنوعی پس‌خور با یک لایه پنهان در شکل ۶ به نمایش در آمده است.



شکل ۶. نمای کلی از شبکه پس‌خور با رابطه بازگشته با تأخیر

بر اساس این شکل مقادیر خروجی دوباره در کنار مقادیر ورودی با رعایت گام‌های تأخیر به شبکه خورانده می‌شوند تا رابطه بازگشته را معنادار کنند. همان‌طور که مشخص است وزن دهنده به سیناپس‌ها، ایجاد بایاس برای توازن معادلات و همچنین توابع مجموع و توابع انتقال هر لایه به تفکیک نمایش داده شده است.

در شبکه‌های عصبی متداول، تابع انتقال لایه خروجی را به صورت خطی و تابع انتقال لایه (های) پنهان را به صورت تانزانیت هیپربولیک یا سیگموئید در نظر می‌گیرند. این شبکه به منظور تصحیح خطاهای از الگوریتم پسانشان بهره می‌گیرد.

به منظور ارزیابی نتایج شبکه و انتخاب معماری مناسب، شاخص‌های مختلفی نظیر میانگین قدر مطلق خطای (MAE)، میانگین مربعات خطای (MSE)، میانگین جذر مربعات خطای (RMSE) و میانگین نسبت قدر مطلق خطای (MAPE) به کار گرفته می‌شود (ادیکاری، ۲۰۱۵) که در این پژوهش از شاخص MSE استفاده شده است. این شاخص بر مبنای نسبت زیر محاسبه می‌شود:

$$\text{MSE} = \frac{1}{N_T} \sum_{t=1}^{N_T} (\rho_t - \hat{\rho}_t)^2 \quad \text{رابطه (۴)}$$

که در آن، ρ_t و $\hat{\rho}_t$ به ترتیب مقادیر واقعی و پیش‌بینی شده کارایی است و N_T نیز کل تعداد مشاهدات را نشان می‌دهد. بر مبنای کمترین مقدار MSE، معماری متناظر آن برگزیده شده و نتایج آن تحلیل می‌شود. افزون بر این شاخص، همبستگی نتایج حاصل از خروجی شبکه عصبی نیز در این پژوهش ارزیابی شده است.

1. Over Fitting

پیاده‌سازی مدل مطالعه موردي

به منظور پیاده‌سازی مدل پیشنهادی این پژوهش، از اطلاعات یک شرکت فعال در صنعت فولاد کشور استفاده شده است. این شرکت دارای مجتمع کارخانجات ساخت و تولید با توانایی و پتانسیل ساخت انواع استراکچر، سازه‌های صنعتی و تکنولوژیک، انواع مخازن تکنولوژیک و تحت فشار و تجهیزات و ماشین‌آلات مرتبط با صنایع سنگین است و داده‌های خود که ۱۲۰ ماه متمی به اسفند ۱۳۹۶ (یعنی ۱۲۰ دوره زمانی) را شامل می‌شود، در اختیار این پژوهش قرار داده است. این داده‌ها شامل سه ورودی و یک خروجی بر اساس مدل DEA است. سه ورودی شامل هزینه سربار (x_1) و هزینه مواد اولیه (x_2) و تعداد پرسنل (x_3) بوده و تنها خروجی نیز مربوط به مقدار تنازع تولیدی (y_1) در دوره زمانی مد نظر است. در جدول ۱، مقادیر مربوط به ورودی‌ها و خروجی‌های مد نظر برای اجرای DEA به نمایش درآمده است. شایان ذکر است که با توجه تأثیرات تورمی در شاخص‌های هزینه‌ای، مقادیر آن‌ها با در نظر گرفتن ضریب تورمی اعلام شده توسط بانک مرکزی طی این ۱۲۰ ماه محاسبه شده است.

جدول ۱. مقادیر شاخص‌های ورودی و خروجی مدل DEA

				شاخص‌ها
				دوره زمانی
۲۵۶۴	۳۶۴۹	۱۲۰۵۲۹۰۱/۶۴	۱۵۲۳۰۶۳/۷۱	۱ (فوروردین ۱۳۸۷)
۲۸۵۴	۳۶۴۹	۱۳۵۴۲۹۴۳/۵۰	۲۱۷۲۶۲۶/۰۵	۲ (اردیبهشت ۱۳۸۷)
۳۱۹۶	۳۷۸۴	۱۵۵۰۰۳۲۳/۱۸	۲۲۹۹۵۹۷/۰۶	۳ (خرداد ۱۳۸۷)
:	:	:	:	:
۵۷۵۵	۷۷۷۳	۲۱۰۴۵۴۴۹/۴۱	۱۲۱۰۹۴۳۸/۵۸	۱۱۹ (بهمن ۱۳۹۶)
۵۸۴۲	۷۸۰۸	۲۱۲۴۹۱۰۶/۶۰	۱۲۲۴۸۷۲۶/۶۷	۱۲۰ (اسفند ۱۳۹۶)

روش DEA با رویکرد SBM برای هر یک از ۱۲۰ دوره جدول ۱ اجرا شده و نتایج حاصل از آن در جدول ۲ موجود است. اجرای این برنامه‌ریزی خطی و حصول نتایج آن با استفاده از نرم‌افزار MATLAB 2017 و با بهره‌گیری از تابع linprog (حل کننده برنامه‌ریزی خطی) انجام شده است. در این نرم‌افزار با استفاده از حلقه زیر، مدل برنامه‌ریزی خطی SBM برای ۱۲۰ گام زمانی محاسبه شد:

```

for i = 1:120
    f = -1/3*[1/U(1,i);1/U(2,i);1/U(3,i);0;-3;zeros(120,1)];
    Aeq = [0 0 0 1/P(1,i) 1 zeros(1,120);
           1 0 0 0 -U(1,i) U(1,:);
           0 1 0 0 -U(2,i) U(2,:);
           0 0 1 0 -U(3,i) U(3,:);
           0 0 0 1 -P(1,i) P(1,:);
           0 0 0 0 ones(1,120)];
    beq = [1; zeros(4,1); 1];
    lb = [zeros(1,3) zeros(1,1) eps zeros(1,120)];
    [w fval] = linprog(f,[],[],Aeq,beq,lb);
    FX(i,1) = fval
end

```

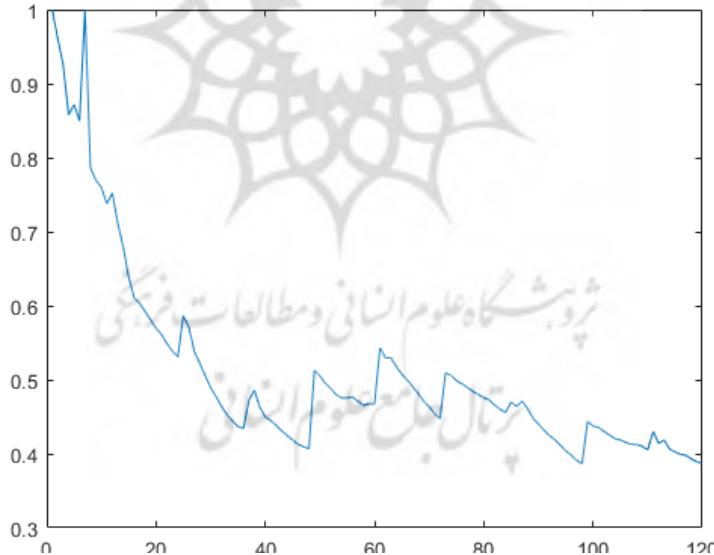
یافته‌های پژوهش

با اجرای مدل ذکر شده در این پژوهش، پاسخ بهینه مدل خطی بالا برای مقادیر کارایی هر دوره زمانی (هر ماه) به شرحی مشابه جدول ۲ استخراج شده است.

جدول ۲. میزان کارایی حاصل از روش SBM برای هر دوره زمانی

دوره زمانی	مقدار کارایی (ρ)
۱	۱/۰۰۰۰
۲	۰/۹۶۱۰
۳	۰/۹۲۵۵
⋮	⋮
۱۱۹	۰/۳۸۹۳
۱۲۰	۰/۳۸۶۳

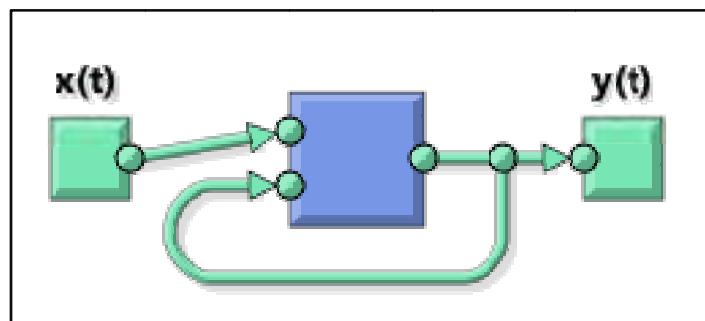
شکل ۷ نمایشی از روند کارایی طی ۱۲۰ ماه را نشان می‌دهد که حاکی از نوسانات فصلی یا دوره‌ای و نیز روند نزولی است.



شکل ۷. سری زمانی کارایی به دست‌آمده برای ۱۲۰ ماه متوالی

با توجه به مقادیر به دست‌آمده برای کارایی (ρ) هر دوره زمانی، با قرار دادن این مقادیر به عنوان خروجی شبکه عصبی مصنوعی و همچنین با قرار دادن ورودی‌ها و خروجی‌های DEA (یعنی x_{it} و y_{jt}) می‌توان این مدل سری زمانی را با شبکه عصبی بازگشتی اجرا کرد. در این پژوهش، اجرای این شبکه با نرم‌افزار MATLAB انجام شده که مدل شماتیک نرم‌افزاری آن در شکل ۸ مشهود است. در این شکل منظور از (t) همان مجموعه بردارهای x_{it} و y_{jt}

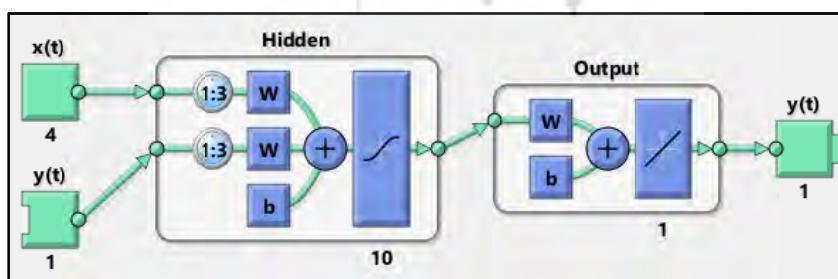
است که از این پس با (t) نمایش خواهیم داد و منظور از $y(t)$ بردارهای خروجی کارایی است که با ρ نمایش داده می‌شود.



شکل ۸. مدل شماتیک شبکه عصبی بر پایه سری زمانی NARX

به منظور آموزش شبکه عصبی متناسب، داده‌های حاصل از محاسبه کارایی ۱۲۰ ماه، به سه گروه داده‌های آموزش، اعتبارسنجی و آزمون تقسیم شدند که نسبت آن‌ها به ترتیب ۱۵، ۷۰ و ۱۵ درصد بوده است. این تقسیم‌بندی به طور تصادفی صورت گرفته و برای تمامی اجراء‌های شبکه عصبی با ساختارهای متفاوت یکسان است.

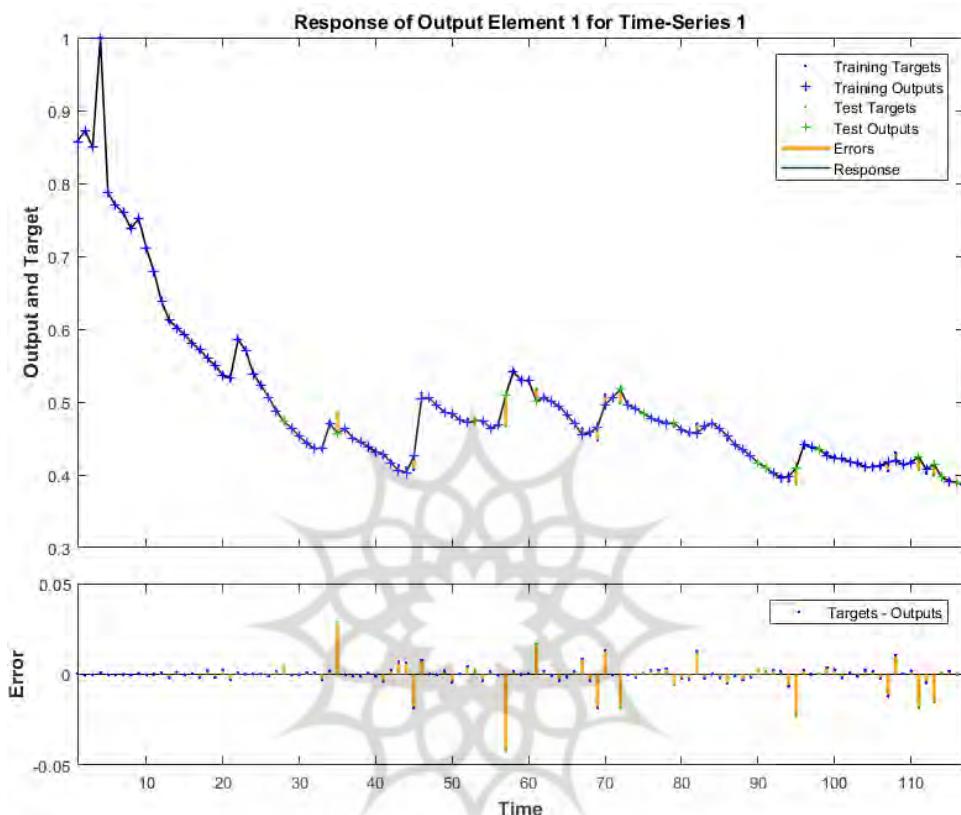
با در نظر گرفتن مدل بالا و داده‌های تعریف شده برای آن، فرایند آموزش شبکه عصبی بازگشتی با جای‌گشتهای مختلف بر اساس الگوریتم آموزش، تعداد لایه و نرون‌ها و گام‌های تأخیر انجام شد. در اینجا ساختار شبکه عصبی با یک و دو لایه پنهان با تعداد ۱۰ و ۱۵ نرون، الگوریتم‌های آموزش پس انتشار لونبرگ - مارکوارت^۱، منظم‌سازی بیزی^۲، گرادیان مزدوج مقیاس‌بندی شده^۳ و گام‌های تأخیر ۲ و ۳ دوره زمانی جای‌گشتهای مختلف را ایجاد کردند که از میان آن‌ها بهترین مقادیر MSE و R برای ساختار شبکه عصبی بازگشتی با ۱۰ نرون در لایه پنهان و الگوریتم آموزش پس انتشار بیزی مشاهده شد که به ترتیب ۰/۰۰۰۰۵۳ و ۹۹۷۹۱۲ هستند. این مقادیر نشان‌دهنده خطای پایین و همبستگی بالای خروجی شبکه است. همچنین همبستگی گزارش شده برای داده‌های آزمون نیز برابر با ۹۲۵۹۴۲ است که سطح اطمینان بالایی را فراهم می‌کند. نمای شماتیک این ساختار با لوب باز در شکل ۹ نمایان است.



شکل ۹. نمای شماتیک ساختار برگزیده

1. Levenberg-Marquardt
2. Bayesian Regularization
3. Scaled Conjugate Gradient

برازش حاصل از اجرای شبکه عصبی مصنوعی در شکل ۱۰ به نمایش در آمد که در آن، تفاوت پیش‌بینی کارایی و مقدار واقعی آن برای هر گام زمانی و به تفکیک دسته‌های داده به تصویر کشیده شده است. این تفاوت میزان خطای پیش‌بینی را نشان می‌دهد.



شکل ۱۰. برازش حاصل از شبکه عصبی و مقادیر خطا

نتیجه‌گیری و پیشنهادها

تلفیق رویکرد پیش‌بینی سری‌های زمانی و روش تحلیل پوششی داده‌ها توانایی ویژه‌ای در تخمین کارایی آتی یک واحد ایجاد می‌کند. این موضوع، نخست بر روند کارایی‌های گذشته استوار است و همچنین اثر شاخص‌های دوره‌های پیشین را به صورت غیرخطی در نظر می‌گیرد. چنین توانایی‌ای به ایجاد یک برآورد صحیح نسبت به آینده واحد یا سازمان کمک شایانی کرده و تحلیل پوششی داده‌ها را به داده‌های کنونی محصور نمی‌کند. این توانایی زمانی برجسته‌تر می‌شود که ابزار مهم و قدرتمندی نظیر شبکه‌های عصبی مصنوعی به عنوان تحلیل‌گر سیستم به کار رود و تخمین مناسبی را ایجاد کند. در این پژوهش نشان داده شد که با انتخاب معماری مطلوب این شبکه و ایجاد یک سری زمانی ورودی و خروجی دار از شاخص‌ها و کارایی‌های حاصل از تحلیل پوششی داده‌ها قدرت تخمین آینده و تأثیرپذیرفتن از شرایط پیشین به خوبی فراهم شده است. به ویژه آنکه این تأثیرپذیرفتن به صورت غیرخطی به مدل وارد شده و با شرایط واقعی انطباق بیشتری دارد.

پیاده‌سازی این رویکرد در مطالعه موردی پژوهش سبب می‌شود که تصویر روشی از آینده برای مدیران سازمان ایجاد شده و توانایی پیش‌بینی آینده به خوبی مهیا شود. با این توانایی تلاش می‌شود که کنترل ورودی‌ها و خروجی‌های به کارایی پیش‌بینی شده با سهولت و آینده‌نگری بالاتری ممکن منجر شود. از سوی دیگر روند نزولی کارایی سازمان مورد کاوی شده قابل اندازه‌گیری شده و این پژوهش توانسته است تصویر روشی را از عملکرد این سازمان طی ۱۲۰ ماه ایجاد کند که هم برای تحلیل گذشته و هم برای کنترل رخدادهای آتی مؤثر است.

به منظور گسترش این پژوهش، می‌توان تأثیرهای زمانی را بر اساس خودهمبستگی‌ها محاسبه کرد و متناسب آن بدون رعایت توالی گام‌ها ارجاع داد. این موضوع می‌تواند اثرهای فصلی یا تغییرات معمول زمانی را به خوبی پوشش دهد. از سوی دیگر با افزودن شاخص‌های خارج از محاسبه کارایی، می‌توان عوامل دیگری که بر کارایی مؤثر هستند اما به طور مستقیم در روش تحلیل پوششی داده‌ها استفاده نمی‌شوند را در ورودی‌های شبکه عصبی لحاظ کرد تا درجه اطمینان خروجی مدل بالاتر رود.

منابع

اجلی، مهدی؛ صفری، حسین (۱۳۹۰). ارزیابی عملکرد واحدهای تصمیم‌گیری با استفاده از مدل ترکیبی شبکه‌های عصبی پیش‌بینی کننده عملکرد و تحلیل پوششی داده‌ها (مورد مطالعه: شرکت ملی گاز ایران). نشریه مهندسی صنایع، ۱(۴۵)، ۱۳-۲۹.

حجازی، رضوان؛ انواری رستمی، علی اصغر؛ مقدسی، مینا (۱۳۸۷). تحلیل بهره‌وری کل بانک توسعه صادرات ایران و رشد بهره‌وری شعب آن با استفاده از تحلیل پوششی داده‌ها (DEA). فصلنامه مدیریت صنعتی، ۱(۱)، ۳۹-۵۰.

علی نژاد، علیرضا (۱۳۹۷). ارائه یک روش ترکیبی از مدل سروکوال و تحلیل پوششی داده در رتبه‌بندی کیفیت خدمات. فصلنامه مطالعات مدیریت صنعتی، ۱۶(۴۸)، ۱۵۳-۱۸۱.

علی‌رضائی، محمدرضا؛ افشاریان، محسن؛ تسلیمی، وحید (۱۳۸۶). ارائه راهکارهای منطقی بهبود عملکرد شعب بانک‌ها به کمک مدل‌های تعمیم‌یافته تحلیل پوششی داده‌ها. پژوهشنامه اقتصادی، ۷(۴)، ۲۶۳-۲۸۳.

کاظمی، مصطفی؛ منظم ابراهیم‌پور، شیلا؛ ایل بیگی، علیرضا (۱۳۹۲). بررسی کارایی نواحی مختلف شهرداری مشهد با رویکرد تحلیل پوششی داده‌ها. فصلنامه برنامه‌ریزی شهری، ۱۵(۴)، ۱۱۳-۱۳۲.

هیلیر، فردریک؛ لیبرمن، جرالد (۱۳۹۱). پیش‌بینی و مدیریت موجودی‌ها (ترجمه محمدعلی فائقی راد و عطیه حقیقت). تهران: نشر ترمه.

References

- Adhikari, R. (2015). A neural network based linear ensemble framework for time series forecasting. *Neurocomputing*, 157, 231-242.
- Ajalli, M. & Safari, H. (2011). Analysis of the Technical Efficiency of the Decision Making Units Making Use of the Synthetic Model of Performance Predictor Neural Networks,

- and Data Envelopment Analysis (Case Study: Gas National Co. of Iran). *Journal of Industrial Engineering*, 45(1), 13-29. (in Persian)
- Alinezhad, A. (2018). A combined method of data envelopment analysis and SERVQUAL model in ranking of service quality. *Industrial Management Studies*, 16(48), 153-181. (in Persian)
- Alirezaee, M. R., Afsharian, M. & Taslimi, V. (2008). Provide Rational Solutions for Improving Bank's Branch Performance by Generalized Models of DEA. *Economics Research*, 7(4), 263-283. (in Persian)
- Ashrafi, A., Seow, H., Lee, L.S., & Lee, C.G. (2013). The efficiency of the hotel industry in Singapore. *Tourism Management*, 37, 31-4.
- Athanassopoulos, A. D. & Curram, S. (1996). A comparison of data envelopment analysis and artificial neural networks as tools for assessing the efficiency of decision making units. *Journal of Operational Research Society*, 47(8), 1000-1017.
- Cecchini, L., Venanzi, S., Pierri, A. & Chiari, M. (2018). Environmental efficiency analysis and estimation of CO₂ abatement costs in dairy cattle farms in Umbria (Italy): A SBM-DEA model with undesirable output. *Journal of Cleaner Production*, 197(1), 895-907.
- Cooper, W. W., Deng, H., Gu, B., Li, S. & Thrall., R. M. (2001). Using DEA to improve the management of congestion in Chinese industries (1981–1997). *Socio-Economic Planning Sciences*, 35(4), 227-242.
- Cooper, W. W., Seiford, L. M. & Zhu, J. (2011). *Data Envelopment Analysis: History, Models and Interpretations*. Handbook on Data Envelopment Analysis, US: Springer.
- Costa, A., & Markellos, R. N., (1997). Evaluating public transport efficiency with neural network models. *Transportation research*, 5(5), 301-312.
- Enke, D., & Suraphan, T. (2005). The use of data mining and neural networks for forecasting stock market returns. *Expert Systems with Applications*, 29(4), 927-940.
- Hagan, M. T., Demuth, H. B. & Beal, M. (2002). *Neural Network Design*. Singapore: Thomson Asia Pte Ltd.
- Hejazi, R., Anvari Rostami, A. A. & Moghadasy, M. (2008). Total Productivity Analysis of Export Development Bank of Iran and Productivity Growth in Branches- A Data Envelopment Analysis Application. *Journal of Industrial Management*, 1(1), 39-50. (in Persian)
- Hillier, F. S. & Lieberman, G. J. (2013). *Inventories Management and Forecasting* (translated by Faezirad, M. A. & Haghigat, A. Trans.). Tehran, Termeh Pub. (in Persian)
- Jahanshahloo, G. R. & Khodabakhshi, M. (2004). Suitable combination of inputs for improving outputs in DEA with determining input congestion: Considering textile industry of China. *Applied Mathematics and Computation*, 151(1), 263-73.

- Kazemi, M., Monazam Ebrahimpour, S. & Ilbeigi, A. R. (2014). Evaluating the efficiency of Mashhad Municipalities by Data Envelopment Analysis. *Journal of Urban Planning*, 4(15), 113-132. (in Persian)
- Kheirkhah, A., Azadeh, A., Saberi, M., Azaron, A. & Shakouri, H. (2013). Improved estimation of electricity demand function by using of artificial neural network, principal component analysis and data envelopment analysis. *Computers & Industrial Engineering*, (64)1, 425-441.
- Kocadağlı, O. & Aşikgil, B. (2014). Nonlinear time series forecasting with Bayesian neural networks. *Expert Systems with Applications*, 41(15), 6596-6610.
- Kwon, H. B. & Lee, J. (2015). Two-stage production modeling of large U.S. banks: A DEA-neural network approach. *Expert Systems with Applications*, 42(19), 6758-6766.
- Kwon, H.B. (2017) Exploring the predictive potential of artificial neural networks in conjunction with DEA in railroad performance modeling. *International Journal of Production Economics*, 183(A), 159-170.
- Liang, F. (2005). Bayesian neural networks for nonlinear time series forecasting. *Statistics and Computing*, 15(1), 13-29.
- MA, J. (2015). A two-stage DEA model considering shared inputs and free intermediate measures. *Expert Systems with Applications*, 42(9), 4339-4347.
- Neely, A.D., Gregory, M. & Platts, K. (1995). Performance measurement system design: a literature review and research agenda. *International Journal of Operations & Production Management*, 15(4), 80-116.
- Poldrugovac, K., Tekavcic, M. & Jankovic, S. (2016). Efficiency in the hotel industry: an empirical examination of the most influential factors. *Economic Research-Ekonomska Istraživanja*, 29(1), 583-597.
- Samoilenko, S. & Osei-Bryson, K. M. (2010) Determining sources of relative inefficiency in heterogeneous samples: Methodology using Cluster Analysis, DEA and Neural Networks. *European Journal of Operational Research*, 206(2), 479-487.
- Seifert, L. M. & Zhu, J. (1998). Identifying excesses and deficits in Chinese industrial productivity (1953–1990): a weighted data envelopment analysis approach. *Omega*, 26(2), 279-96.
- Shabanpour, H., Yousefi, S. & Farzipoor Saen, R. (2017). Forecasting efficiency of green suppliers by dynamic data envelopment analysis and artificial neural networks. *Journal of Cleaner Production*, 142(2), 1098-1107.
- Silva, D. A., Alves, G. A, de Mattos Neto, P. S. G. & Ferreira, T. A. E. (2014). Measurement of Fitness Function efficiency using Data Envelopment Analysis. *Expert Systems with Applications*, 41(16), 7147-7160.

- Tone, K. (2001). A slack-based measure of efficiency in date envelopment analysis. *European Journal of Operational Research*, 130(3), 498-509.
- Tsai, C.F. & Lu, Y.H. (2009). Customer churn prediction by hybrid neural networks. *Expert Systems with Applications*, 36(10), 12547-12553.
- Zeng, Y., Zeng, Y., Choi, B., & Wang, L. (2017). Multifactor-influenced energy consumption forecasting using enhanced back-propagation neural network. *Energy*, 127, 381-396.

