



Paper Type: Original-application Paper



A Comprehensive Hybrid Ndea- Bsc Model and a New Neural Network for Predicting Organizational Performance Indicators

Mohammad Jaberi¹, Seyyed Esmail Najafi¹,* , Farhad Hoseinzadeh Lotfi¹, Mohammad Haji Molana¹

¹ Department of Industrial Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran;
najafi1515@yahoo.com; mohammad.jaberi61@gmail.com; hosseinzadeh.lotfi@yahoo.com; molana-m@gmail.com.

Citation:



Jaberi, M., Najafi, S. E., Hoseinzadeh Lotfi, F., & Haji Molana, M. (2021). A comprehensive hybrid Ndea- Bsc model and a new neural network for predicting organizational performance indicators. *Journal of decisions and operations research*, 6 (2), 271-287.

Received: 29/05/2020

Reviewed: 27/06/2020

Revised: 02/08/2020

Accept: 17/10/2020

Abstract

Purpose: Strategy is the main source of long-term growth of organizations and if the strategy is not successfully implemented, even if the appropriate strategies are adopted, this process is useless. The purpose of this paper is to propose a comprehensive hybrid model for predicting organizational performance indicators.

Methodology: In order to achieve the research goal, first, a balanced scorecard as a tool for designing performance evaluation indicators and network data envelopment analysis as a tool for performance evaluation has been used. Then, by matching the Malmquist productivity index with the mentioned hybrid model, the model of progress and regression of organizations in two consecutive periods is presented. Finally, by combining the proposed models and artificial neural networks, a solution is presented to evaluate the performance of 500 bank branches and also to identify their progress and regression.

Finding: The obtained results show good accuracy and less computational time of the proposed hybrid models.

Originality/Value: The presented study can add to the existing knowledge on performance appraisal of enterprises by providing a hybrid model using network data envelopment analysis and balanced scorecard; And the proposed methods can be promising tools for evaluating the performance of organizations, especially big data.

Keywords: Network data envelopment analysis (NDEA), Balanced score cards (BSC), Strategy goals, Malmquist productivity index, Artificial neural system, Multilayered perceptron, Efficiency.

Corresponding Author: najafi1515@yahoo.com

doi 10.22105/dmor.2020.254632.1243



Licensee. **Journal of Decisions and Operations Research**. 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>).



یک مدل جامع ترکیبی NDEA-BSC و شبکه عصبی جدید برای پیش‌بینی شاخص‌های عملکردی سازمانی

محمد جابری^۱، سید اسماعیل نجفی^{۱*} ، فرهاد حسین‌زاده لطفی^۱، محمد حاجی مولانا^۱
^۱گروه مهندسی صنایع، واحد علوم و تحقیقات دانشگاه آزاد اسلامی، تهران، ایران.

چکیده

هدف: استراتژی اصلی‌ترین منبع رشد بلندمدت سازمان‌ها می‌باشد و در صورت عدم اجرای موفق استراتژی، حتی اگر استراتژی‌های مناسبی اتخاذ شده باشد این فرآیند بیهوده است. هدف این مقاله پیشنهاد یک مدل جامع ترکیبی را برای پیش‌بینی شاخص‌های عملکردی سازمانی است.

روش‌شناسی پژوهش: به منظور رسیدن به هدف پژوهش، ابتدا از کارت امتیازی متوازن به‌عنوان ابزاری برای طراحی شاخص‌های ارزیابی عملکرد و از تحلیل پوششی داده‌های شبکه‌ای به‌عنوان ابزاری برای ارزیابی عملکرد استفاده شده است. سپس با استفاده از تطبیق شاخص بهره‌وری مالمکوئیست با مدل ترکیبی مذکور، به ارائه مدل پیشرفت و پسرفت سازمان‌ها طی دو دوره متوالی پرداخته می‌شود. سرانجام با ترکیب مدل‌های پیشنهادی و شبکه‌های عصبی مصنوعی راهکاری را برای ارزیابی عملکرد ۵۰۰ شعبه بانک و نیز تشخیص پیشرفت و پسرفت آن‌ها ارائه می‌گردد.

یافته‌ها: نتایج به‌دست‌آمده نشان‌دهنده دقت مناسب و زمان محاسباتی کمتر مدل‌های ترکیبی پیشنهادی است.

اصالت/دانش‌افزایی علمی: پژوهش حاضر با ارائه یک مدل ترکیبی با استفاده از تحلیل پوششی داده‌های شبکه‌ای و کارت امتیازی متوازن می‌تواند به دانش موجود در خصوص ارزیابی عملکرد بنگاه‌های اقتصادی بیافزاید و روش‌های پیشنهادی می‌تواند ابزارهای نویدبخشی برای ارزیابی عملکرد سازمان‌ها، به‌خصوص داده‌های بزرگ باشند.

کلیدواژه‌ها: تحلیل پوششی داده‌های شبکه‌ای، کارت امتیازی متوازن، اهداف استراتژی، شاخص بهره‌وری مالمکوئیست، شبکه عصبی مصنوعی، پرسپترون چندلایه، کارایی.

۱- مقدمه

استراتژی اصلی‌ترین منبع رشد بلندمدت سازمان‌ها می‌باشد همچنین مشخص شده عمده‌ترین موانع و مشکلات مرتبط با استراتژی در مرحله اجراء و به کارگیری استراتژی می‌باشد. این در حالی است که در صورت عدم اجرای موفق استراتژی، حتی اگر استراتژی‌های مناسبی اتخاذ شده باشد این فرآیند بیهوده است.

* نویسنده مسئول

najafi1515@yahoo.com 

10.22105/dmor.2020.254632.1243 

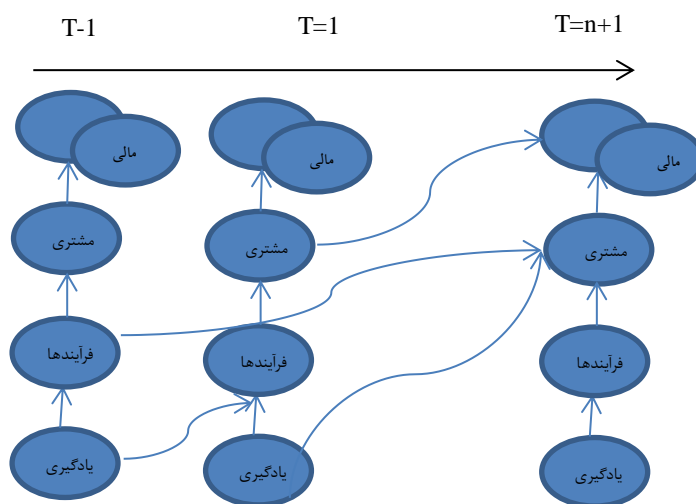


در حال حاضر محاسبه صحیح کارایی سازمان‌ها و ارزیابی عملکرد یکی از مهمترین مسائل مدیریت کلان می‌باشد. واضح است که هرچه این محاسبه کارایی دقیق‌تر و همگون با اهداف کلان سازمان صورت پذیرد، تصمیمات اتخاذ شده برای آینده سازمان در جهت پیشبرد اهداف استراتژیک دقیق‌تر و از معیارهای صحیح‌تری برخوردار می‌گردد.

یکی از مشکلاتی که در زمینه روش ارزیابی متوازن وجود دارد، این است که هدف‌های کمی مشخص شده برای شاخص‌ها که بعنوان سنگ نشانه اهداف استراتژیک دوره آتی تعیین می‌گردند براساس ضابطه خاص نبوده و سازمان در عمل نمی‌تواند به آن‌ها دست پیدا کند. اعمالی که باعث بهبود نتایج در کوتاه مدت می‌شوند ممکن است با دستیابی به اهداف بلندمدت منافات داشته باشند بدین ترتیب که شاخص‌های تعریف شده و هدف‌گذاری برای شاخص‌ها، به جای بهبودهای بلندمدت، بهبودهای کوتاه‌مدت را در نظر بگیرند. از این‌رو انتخاب روشی برای محاسبه مقدار کمی اهداف در دوره‌های آتی ضروری بنظر می‌رسد.

می‌دانیم کارت امتیازی متوازن نیز به‌عنوان یک سیستم اندازه‌گیری بر پایه روابط علت و معلولی بر اساس شاخص‌هایی در اهداف استراتژیک در چهار منظر مالی، مشتری، فرآیندهای داخلی کسب‌وکار و رشد و یادگیری می‌باشد. ضعف روش کارت امتیازی متوازن با وجود توانایی بالا در ارزیابی عملکرد بر اساس شاخص‌های کلیدی عملکرد، عدم اندازه‌گیری کمی عملکرد سازمان با استفاده از روش ریاضی می‌باشد. روش تحلیل پوششی داده‌ها یکی از بهترین روش‌های ریاضی برای محاسبه کارایی سازمان می‌باشد که از تکنیک برنامه‌ریزی خطی و انجام یکسری بهینه‌سازی جهت تعیین کارایی هر واحد استفاده می‌کند. ایراد اصلی مدل تحلیل پوششی داده‌ها با وجود توانایی بالا در ارزیابی عملکرد و ارائه مسیر بهبود، ناتوانی در تعیین متغیرهای ورودی و خروجی می‌باشد. ضعف مربوط به متغیرهای ورودی و خروجی موجود در مدل تحلیل پوششی داده‌ها از طریق شاخص‌های کلیدی عملکرد کارت امتیازی متوازن مرتفع می‌گردد و ضعف مربوط به عدم اندازه‌گیری کمی عملکرد با استفاده از روش‌های ریاضی در کارت امتیازی متوازن نیز از طریق مدل تحلیل پوششی داده‌ها مرتفع می‌گردد. با تلفیق دو ابزار مذکور نقاط ضعف هرکدام برطرف و هم‌افزایی برای اندازه‌گیری عملکرد سازمان در خلال زمان ایجاد می‌شود. ولیکن باوجود ترکیب دو ابزار یادشده که مدل ارزیابی قوی را تشکیل داده‌اند و مدل‌های مختلفی نیز ارائه گردیده است ولیکن همواره یک مشکل اساسی در مدل‌های تلفیقی وجود دارد که همانا پرداختن به مقدار *target* دوره بعدی می‌باشد یعنی پیش‌بینی دوره آتی، از این‌رو استفاده از شبکه عصبی در مدل‌سازی به‌منظور پیش‌بینی دوره آتی می‌تواند کمک بسیاری در ارزیابی و تعیین مقدار *target* دوره بعدی داشته باشد. درواقع می‌خواهیم از یک شبکه عصبی برای شبیه‌سازی مدل مسئله تلفیقی کارت امتیازی متوازن و تحلیل پوششی داده‌ها استفاده کنیم و با استفاده از این مدل شبیه‌سازی شده مقادیر کارایی واحدهای تحت ارزیابی را موردسنجش و اندازه‌گیری قرار دهیم و مقدار *target* دوره بعدی یعنی $t+1$ را پیش‌بینی کنیم.

انعطاف‌پذیری شبکه‌های عصبی در ایجاد خروجی‌های مناسب، توانایی در تجزیه و تحلیل مجموعه داده‌های بزرگ، باعث شده تا استفاده از آن در مسائل *DEA* مورد استفاده قرار گیرد. با توجه به مطالب فوق شکل زیر را در نظر بگیرید. فرض کنید کارت امتیازی متوازن طی سال‌های مختلف در سازمان پیاده شده است می‌خواهیم مقادیر پیش‌بینی دوره بعدی یعنی $t+1$ را با مدل‌سازی با استفاده از شبکه عصبی پیش‌بینی کنیم.



شکل ۱- کارت امتیازی متوازن در دوره‌های متوالی.

Figure 1- Balanced scorecard in consecutive periods.



یکی از چالش‌های بزرگ سازمان‌ها در اجرای استراتژی‌ها به‌وسیله کارت امتیازی متوازن این است که شاخص‌های موجود در اهداف استراتژیک نقشه استراتژی، با تأخیر زمانی ارتباط علت و معلولی را بین مناظر چهارگانه کارت امتیازی به وجود می‌آورد. با در نظر گرفتن تأخیر زمانی در کارت امتیازی متوازن و اضافه نمودن عامل زمان، اهداف استراتژیک در زمان‌های مختلف باهم روابط علت و معلولی خواهند داشت و بحث شبکه پویا در کارت امتیازی متوازن مطرح می‌شود.

۲- کارت امتیازی متوازن

طراحان مدل کارت امتیازی متوازن روبرت کاپلان^۱ و دیوید نورتن^۲ اساتید حسابداری از دانشگاه هاروارد بودند که با درک محدودیت‌های ارزیابی عملکرد با شاخص‌های مالی، در سال ۱۹۹۲ با چاپ مقاله‌ای در «مجله مدیریت هاروارد» کارت امتیازی متوازن را به عنوان ابزار مدیریتی نوین برای ارزیابی عملکرد معرفی کردند. در سال‌های ۱۹۹۳ و ۱۹۹۴ و ۱۹۹۶ با چاپ سه مقاله دیگر، کارت امتیازی متوازن را به ابزاری برای تدوین استراتژی‌ها و تسری آن‌ها در سازمان و کنترل مدیریت توسعه دادند (برنز و همکاران^۳، ۲۰۰۵؛ بدیعی زاده و همکاران^۴، ۲۰۱۸؛ باسو و همکاران^۵، ۲۰۱۸؛ کاستلی و همکاران^۶، ۲۰۰۱؛ چارنز و همکاران^۷، ۱۹۸۶).

کارت امتیازی متوازن شامل معیارهای مالی، مشتری، فرآیندهای داخلی کسب و کار، یادگیری و رشد می‌باشد که چهار منظر آنرا تشکیل داده و از طریق روابط علت و معلولی سازمان را برای رسیدن به هدف کلان یاری می‌رساند (چارنز و همکاران، ۱۹۸۶).

۳- تحلیل پوششی داده‌ها و شاخص بهره‌وری المکوئست

تحلیل پوششی داده‌ها در سال ۱۹۷۸ توسط چارنز و همکاران معرفی شد 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. مدل‌های *DEA* میزان توانایی هر واحد تصمیم 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.

با تلفیق تغییرات کارایی هر واحد و تغییرات تکنولوژی، شاخص بهره‌وری المکوئست تعریف می‌شود که آنرا می‌توان از توابع فاصله رابطه ۱ و یا توابع مشابه دیگری محاسبه نمود (آسوشه و همکاران^۸، ۲۰۱۰):

$$D(X_p, Y_p) = \inf \left[\theta / (\theta X_p, Y_p), PPS \right]. \quad (1)$$

رابطه ۱ در حالت‌های خیلی خاص فقط تغییرات مرز کارایی در لحظه $t+1$ را نسبت به مرز کارایی در لحظه t نشان می‌دهد و نمی‌تواند معیار مناسبی برای محاسبه تغییرات تکنولوژی باشد. همچنین تغییرات کارایی نیز در این روش نادیده گرفته می‌شود. اگر $D^k(X^k, Y^k) = 1$ آنگاه واحد k کارا فرض می‌شود این تابع فاصله مقدار ناکارایی را مشخص نمی‌کند فارل با توجه به ناکارایی خطی بودن مرز تکنولوژی شاخص بهره‌وری را به دو عامل تجزیه کرد مرز کارایی با استفاده از تکنیک‌های *DEA* برای *DMU* ها مشخص می‌شود.

فارل فرض کرد که $D^t(X^t, Y^t)$ و $D^{t+1}(X^{t+1}, Y^{t+1})$ برای کارا بودن باید برابر یک باشند بنابراین تغییرات کارایی نسبی را تعریف کرد:

^۱Robert Kaplan
^۲David Norton
^۳Brons et al.
^۴Badiezadeh et al.
^۵Basso et al.
^۶Castelli et al.
^۷Charnes et al.
^۸Asosheh et al.



$$TEC_p = \frac{D_p^{t+1}(X_p^{t+1}, Y_p^{t+1})}{D_p^t(X_p^t, Y_p^t)} \quad (۲)$$

شاخص بهره‌وری مالمکوئیست نه تنها به بررسی الگوی تغییر بهره‌وری می‌پردازد بلکه به ارائه جهت‌گیری‌های استراتژیک هر واحد تصمیم‌گیرنده در یک دوره زمانی می‌پردازد. با استفاده از این شاخص می‌توان به ارزیابی جهت‌گیری‌های استراتژیک سازمان در دوره‌های گذشته پرداخت و برای دوره‌های آینده رویه مناسب را انتخاب نمود (چن و علی^۱، ۲۰۰۴). فار و همکاران^۲ (۱۹۹۴) شاخص مالمکوئیست را بر مبنای تکنولوژی بازده متغیر نسبت به مقیاس تولید بصورت زیر تعریف کردند:

تغییرات تکنولوژی * تغییرات کارایی * تغییرات کارایی مقیاس = تغییرات بهره‌وری کل

شاخص مالمکوئیست با استفاده از توابع فاصله به صورت زیر تبیین می‌شود.


$$M_o(Y_s, X_s, Y_t, X_t) = \left[\frac{D_o^s(Y_t, X_t)}{D_o^s(Y_s, X_s)} \cdot \frac{D_o^t(Y_t, X_t)}{D_o^t(Y_s, X_s)} \right]^{\frac{1}{2}}$$

در اینجا $D_o^s(Y_t, X_t)$ نشان دهنده تابع فاصله محصول بر اساس میزان مصرف ورودی دوره t با استفاده از فناوری دوره s است. اگر مقدار $M_o > 1$ باشد نشان می‌دهد که بهره‌وری کل عوامل طی زمان t تا $t+1$ رشد مثبت دارد. بنابراین لازم است برای هر سازمان در هر زمان چهار تابع فاصله را محاسبه کرد که این کار با استفاده از روش تحلیل پوششی داده‌ها امکان‌پذیر است.

۴- شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی، ابزاری برای مدل‌سازی هوشمند ناپارامتریک مبتنی بر داده هستند که روابط غیرخطی را آموخته و بین متغیرهای ورودی و خروجی ارتباط برقرار می‌کنند (کوان^۳، ۲۰۱۷). شبکه‌های عصبی مصنوعی مانند شبکه‌های عصبی بیولوژیک پیچیده نیستند، اما دو شباهت اساسی به آن‌ها دارند. نخست شباهت ساختمان و اجزای تشکیل دهنده آن‌هاست و شباهت دیگر ارتباط بین نرون‌ها است که تعیین‌کننده شیوه کار شبکه خواهد بود (هاگان و همکاران^۴، ۱۹۹۷). 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.

شکل ۲ یک نرون عصبی را با استفاده از الگوهای ریاضی نمایش داد.



شکل ۲- مدل ریاضی یک نرون.

Figure 2- Mathematical model of a neuron.

^۱Chen and Ali
^۲Färe et al.
^۳Kwon
^۴Hagan et al.

ساختار شبکه‌های عصبی از تعداد دلخواهی واحد پردازشی (یا نرون) که در لایه‌ها قرار می‌گیرند تشکیل می‌شود که ورودی‌ها را به خروجی مرتبط می‌کند.

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. اگرچه به منظور پیش‌بینی سری‌های زمانی روش‌های مختلفی نظیر مدل‌های باکس - جنکینز یا مدل‌های خودرگرسیون آماری توسعه یافته‌اند اما این روش‌ها دارای محدودیت‌های ذاتی هستند. 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 این رو، شبکه‌های عصبی مصنوعی برای غلبه بر این محدودیت‌ها در مدل‌سازی سری‌های زمانی غیرخطی گسترش یافته‌اند.

۵- پیشینه پژوهش: رویکردهای ادغامی تحلیل پوششی داده‌ها و شبکه عصبی

در پژوهش‌های اخیر از شبکه عصبی مصنوعی به طور متداول در مسائل تحلیل پوششی داده‌ها استفاده شده است. زیرا ماهیت عملکرد شبکه‌های عصبی به دلیل قدرت یادگیری و تعمیم‌پذیری به گونه‌ای است که در برابر داده‌های پرت و اغتشاش‌های حاصل از اندازه‌گیری غیردقیق داده‌ها مقاوم‌تر عمل می‌کنند.

در سال ۲۰۰۷، مصطفی با استفاده از رویه‌ای مشابه مطالعه‌ی (وو و همکاران^۱، ۲۰۰۶) به ارزیابی عملکرد بانک‌های عربی پرداخت. در این مطالعه کارایی ۸۵ بانک برتر عربی مورد بررسی قرار گرفت. مقایسه‌ی نتایج شبکه‌های عصبی و تحلیل پوششی داده‌ها نشان داد که میان رتبه‌بندی‌های دو روش ۹۴ درصد همبستگی وجود دارد. هو^۲ و همکاران^۳ (۲۰۰۸) از شبکه عصبی هاپفیلد و استفاده از روش‌های عددی برای حل مدل‌های DEA در مقیاس کوچک استفاده نمود. سلیمی و بیرکتر^۴ (۲۰۰۸) مقاله‌ای با عنوان ترکیب تحلیل پوششی داده و شبکه عصبی برای ارزیابی تأمین‌کنندگان تحت اطلاعات ناقص را مطرح کردند. امروزنژاد و شل^۵ (۲۰۰۹) الگوریتم ترکیبی از تحلیل پوششی داده‌ها و شبکه عصبی برای ارزیابی کارایی مجموعه داده‌های بزرگ ارائه دادند. آن‌ها نشان دادند تحلیل پوششی داده‌ها برای چنین مجموعه‌هایی به منابع عظیم کامپیوتری از لحاظ زمان پردازش و میزان حافظه نیاز دارد و روش ارائه‌شده حجم محاسباتی را تا حد بسیار زیادی کم و محاسبه کارایی مجموعه داده‌های بزرگ را تسهیل می‌بخشد. سامویلنکو و اوسی برایسون^۶ (۲۰۱۰) یک متودولوژی جدید که ترکیبی از آنالیز خوشه‌بندی، DEA و شبکه عصبی بود را برای تعیین منابع ناکارایی نسبی در نمونه‌های ناهمگن ارائه نمودند.

لیوو همکاران^۷ (۲۰۱۳)، در مقاله‌ای به مقایسه تحلیل پوششی داده‌های سه مرحله‌ای و شبکه عصبی برای ارزیابی کارایی شرکت‌های نیمه هدایتی در تایوان پرداختند. طلوع و همکاران^۸ (۲۰۱۵)، از ترکیب شبکه عصبی MLP و DEA به ارزیابی کارایی مجموعه داده‌های بزرگ با مقادیر منفی پرداختند و نتایج امیدبخشی را برای استفاده از مدلشان ارائه دادند. کون^۹ و همکاران (۲۰۱۶) در پژوهشی، از مدل ترکیبی شبکه عصبی و تحلیل پوششی داده‌ها دو مرحله‌ای به عنوان دو ناپارامتریک برای ارزیابی کارایی شعب بانک‌های آمریکا استفاده کردند. شکرالله پور و همکاران^{۱۰} (۲۰۱۶)، برای پوشش دادن معضلات DEA، یک مدل شبکه عصبی مصنوعی با استفاده از DEA را برای محاسبه کارایی نسبی و معیارهای قابل اعتمادتر برای یکی از شعب بانک تجارت ایران ارائه دادند. شعبانپور و همکاران^{۱۱} (۲۰۱۷)، از مدل ترکیبی شبکه عصبی و تحلیل پوششی داده‌های پویا به عنوان دو ناپارامتریک برای پیش‌بینی کارایی تأمین‌کنندگان سبز استفاده کردند همچنین با توجه به ضرورت استفاده از شبکه‌های عصبی در مسائل کاربردی، محققان بسیاری از جمله سانتین (۲۰۰۸)، کون و

^۱ Wu et al.

^۲ Hu et al.

^۳ Hu et al.

^۴ Celebi and Bayraktar

^۵ Emrouznejad and Shale

^۶ Samoilenko and Osei-Bryson

^۷ Liu et al.

^۸ Toloo et al.

^۹ Kwon et al.

^{۱۰} Shokrollahpour et al.

^{۱۱} Shabanpour et al.




همکاران (۲۰۱۶، ۲۰۱۷)، میسوناس^۱ و همکاران (۲۰۱۶)، آگروال^۲ (۲۰۱۶)، شریفی و رضائیان^۳ (۲۰۱۶)، سینگ و پنت^۴ (۲۰۱۷)، کاولین و همکاران^۵ (۲۰۱۸)، مدل‌هایی ترکیبی از شبکه عصبی با تحلیل پوششی داده‌های ارائه کردند.



۶- مدل پیشنهادی


مدل مفهومی پژوهش در شکل ۳ نشان داده شده است این مدل پنج گام اصلی را در انجام پژوهش در نظر می‌گیرد.



شکل ۳- مدل مفهومی پژوهش.
Figure 3- Conceptual model of research.

۶-۱- مدل پیشنهادی BSC-DEA

فرض کنید n واحد قسمت ارزیابی $DMU_j ; j=1, \dots, n$ مفروض باشد که هر یک دارای شبکه‌ای به شکل ۳ شامل چهار مرحله باشد. فرض بر این است که ورودی X وارد مرحله اول (فرآیند آموزش، رشد و یادگیری) می‌شود و خروجی‌های آن شامل \bar{y}, w^1 می‌باشد که هر یک به ترتیب خروجی که از سیستم خارج می‌شود، خروجی که نقش ورودی مرحله دوم را دارد. در مرحله دوم، فرض کنید \bar{x} ورودی مستقل این مرحله باشد و خروجی‌های آن به صورت $\hat{y}, w^2, \tilde{w}^3$ باشد که به ترتیب خروجی که از سیستم خارج می‌شود، خروجی که نقش ورودی مرحله سوم را دارد و خروجی که نقش ورودی مرحله چهارم را دارد. در مرحله سوم، فرض کنید \hat{x} ورودی مستقل این مرحله باشد و خروجی‌های آن به صورت \bar{y}, w^3 باشد که به ترتیب خروجی که از سیستم خارج می‌شود و خروجی که نقش ورودی مرحله چهارم را دارد. همچنین فرض کنید \tilde{x} ورودی مستقل مرحله چهارم و \bar{y} خروجی که از سیستم خارج می‌شود باشد.



شکل ۳- ارتباط بین چهار منظر مدل BSC.
Figure 4- Relationship between the four perspectives of the BSC model.

^۱ Misiunas et al.
^۲ Agarwal
^۳ Sharifi and Rezaeian
^۴ Singh and Pant
^۵ Cavallin et al.



برای واقعی‌تر شدن نتایج، محدودیت‌های مربوط به عامل توازن قید را نیز اعمال می‌کنیم که برابر است با نسبت مجموع خروجی‌های واحد p مربوط به کارت k ام. به عبارت دیگر این کار، نشان‌دهنده اهمیت هر یک از کارت‌های BSC برای واحد p ام می‌باشد. هر چه این نسبت بزرگ‌تر باشد به این معنی است که این واحد در تعیین نمره کارایی به خروجی‌های این کارت وابسته‌تر است. به منظور ایجاد توازن مطلوب، برای این نسبت حدود بالا و پایین توسط تصمیم‌گیرنده تعیین می‌گردد. در نتیجه خواهیم داشت:

$$\max \frac{Uy_p + d\bar{y}_p + L\hat{y}_p + s\tilde{y}_p}{vx_p + m\bar{x}_p + c\hat{x}_p + h\tilde{x}_p}$$

$$s.t. \quad e_j^1 = \frac{s\tilde{y}_j + pw_j^1}{vx_j} \leq 1 \quad \forall j$$

$$e_j^2 = \frac{L\hat{y}_j + bw_j^2 + q\bar{w}_j^2}{m\bar{x}_j + pw_j^1} \leq 1 \quad \forall j$$

$$e_j^3 = \frac{d\bar{y}_j + gw_j^3}{c\hat{x}_j + bw_j^2} \leq 1 \quad \forall j$$

$$e_j^4 = \frac{Uy_j}{h\tilde{x}_j + q\bar{w}_j^2 + gw_j^3} \leq 1 \quad \forall j$$

$$LC_1 \leq \frac{s\tilde{y}_j + pw_j^1}{K_j} \leq UC_1$$

$$LC_2 \leq \frac{L\hat{y}_j + bw_j^2 + q\bar{w}_j^2}{K_j} \leq UC_2$$

$$LC_3 \leq \frac{d\bar{y}_j + gw_j^3}{K_j} \leq UC_3$$

$$LC_4 \leq \frac{Uy_j}{K_j} \leq UC_4$$

$$v, m, c, h, s, p, L, b, d, g, q, U \geq 0.$$

که در آن UC_i $i = 1, 2, 3, 4$ حدود بالا و پایین برای هر یک از کارت‌های امتیازی متوازن می‌باشد.

۲-۶- محاسبه پیشرفت و پسرفت

برای محاسبه پیشرفت و پسرفت یک واحد تصمیم‌گیرنده از شاخص مالمکوئیست استفاده می‌گردد حال فرض کنید برای همه واحدهای تصمیم‌گیرنده در دو مقطع زمانی $(t, t+1)$ ، داده وجود دارد. در این صورت برای هر واحد تصمیم‌گیرنده و مراحل آن، چهار کارایی می‌توان به دست آورد که به کمک آن‌ها بتوان شاخص بهره‌وری مالمکوئیست را محاسبه کرد.

در جدول ۱ دو تا از چهار روابط مربوط به شاخص بهره‌وری مالمکوئیست آورده شده است کارایی واحد تصمیم‌گیرنده p ام با مختصات لحظه t نسبت به مجموعه امکان تولید لحظه t و همچنین کارایی واحد تصمیم‌گیرنده p ام با مختصات لحظه t نسبت به مجموعه امکان تولید لحظه $t+1$ دو رابطه دیگر مشابه آن‌ها استخراج می‌گردند.

در رابطه مربوط به مختصات لحظه t نسبت به مجموعه امکان تولید لحظه $t+1$ بافرض $(v^*, m^*, c^*, h^*, s^*, p^*, L^*, b^*, d^*, g^*, q^*, U^*)$ به‌عنوان جواب بهینه مدل یاد شده باشد، کارایی مراحل اول الی چهارم و کارایی تجمعی از روابط زیر حاصل می‌شود:

$$e_p^{1,t+1}(t) = \frac{s^* \tilde{y}_j^t + p^* w_j^{1t}}{v^* x_j^t},$$

$$e_p^{3,t+1}(t) = \frac{d^* \bar{y}_j^t + g^* w_j^{3t}}{c^* \hat{x}_j^t + b^* w_j^{2t}},$$



$$e_p^{2,t+1}(t) = \frac{L^* \hat{y}_j^t + b^* w_j^{2t} + q^* \bar{w}_j^{2t}}{m^* \bar{x}_j^t + p^* w_j^{1t}},$$

$$e_p^{\alpha,t+1}(t) = \frac{U^* y_p^t + d^* \bar{y}_p^t + L^* \hat{y}_p^t + s^* \tilde{y}_p^t}{v^* x_p^t + m^* \bar{x}_p^t + c^* \hat{x}_p^t + h^* \tilde{x}_p^t}.$$

$$e_p^{4,t+1}(t) = \frac{U^* y_j^t}{h^* \tilde{x}_j^t + q^* \bar{w}_j^{2t} + g^* w_j^{3t}}.$$

جدول ۱- روابط مربوط به شاخص مالمکوئیست.

Tabla 1- Malmquist index relationships.

کارایی واحد تصمیم گیرنده p ام با مختصات لحظه t نسبت به مجموعه امکان تولید لحظه t	کارایی واحد تصمیم گیرنده p ام با مختصات لحظه t+1 نسبت به مجموعه امکان تولید لحظه t+1
$\theta_p^t(t) = \max U y_p^t + d \bar{y}_p^t + L \hat{y}_p^t + s \tilde{y}_p^t$ s.t. $v x_p^t + m \bar{x}_p^t + c \hat{x}_p^t + h \tilde{x}_p^t = 1,$ $s \tilde{y}_j^t + p w_j^{1t} - v x_j^t \leq 0, \quad \forall j$ $L \hat{y}_j^t + b w_j^{2t} + q \bar{w}_j^{2t} - m \bar{x}_j^t - p w_j^{1t} \leq 0 \quad \forall j$ $d \bar{y}_j^t + g w_j^{3t} - c \hat{x}_j^t - b w_j^{2t} \leq 0, \quad \forall j$ $U y_j^t - h \tilde{x}_j^t - q \bar{w}_j^{2t} - g w_j^{3t} \leq 0, \quad \forall j$ $s \tilde{y}_j^t + p w_j^{1t} - \kappa_j^t UC_1 \leq 0,$ $-(s \tilde{y}_j^t + p w_j^{1t}) + \kappa_j^t LC_1 \leq 0,$ $(L \hat{y}_j^t + b w_j^{2t} + q \bar{w}_j^{2t}) - \kappa_j^t UC_2 \leq 0,$ $-(L \hat{y}_j^t + b w_j^{2t} + q \bar{w}_j^{2t}) + \kappa_j^t LC_2 \leq 0,$ $(d \bar{y}_j^t + g w_j^{3t}) - \kappa_j^t UC_3 \leq 0,$ $-(d \bar{y}_j^t + g w_j^{3t}) + \kappa_j^t LC_3 \leq 0,$ $U y_j^t - \kappa_j^t UC_4 \leq 0,$ $-U y_j^t + \kappa_j^t LC_4 \leq 0,$ $v, m, c, h, s, p, L, b, d, g, q, U \geq 0.$	$\theta_p^{t+1}(t) = \max U y_p^t + d \bar{y}_p^t + L \hat{y}_p^t + s \tilde{y}_p^t$ s.t. $v x_p^t + m \bar{x}_p^t + c \hat{x}_p^t + h \tilde{x}_p^t = 1,$ $s \tilde{y}_j^{t+1} + p w_j^{1t+1} - v x_j^{t+1} \leq 0, \quad \forall j$ $L \hat{y}_j^{t+1} + b w_j^{2t+1} + q \bar{w}_j^{2t+1} - m \bar{x}_j^{t+1} - p w_j^{1t+1} \leq 0 \quad \forall j$ $d \bar{y}_j^{t+1} + g w_j^{3t+1} - c \hat{x}_j^{t+1} - b w_j^{2t+1} \leq 0, \quad \forall j$ $U y_j^{t+1} - h \tilde{x}_j^{t+1} - q \bar{w}_j^{2t+1} - g w_j^{3t+1} \leq 0, \quad \forall j$ $s \tilde{y}_j^{t+1} + p w_j^{1t+1} - \kappa_j^{t+1} UC_1 \leq 0,$ $-(s \tilde{y}_j^{t+1} + p w_j^{1t+1}) + \kappa_j^{t+1} LC_1 \leq 0,$ $(L \hat{y}_j^{t+1} + b w_j^{2t+1} + q \bar{w}_j^{2t+1}) - \kappa_j^{t+1} UC_2 \leq 0,$ $-(L \hat{y}_j^{t+1} + b w_j^{2t+1} + q \bar{w}_j^{2t+1}) + \kappa_j^{t+1} LC_2 \leq 0,$ $(d \bar{y}_j^{t+1} + g w_j^{3t+1}) - \kappa_j^{t+1} UC_3 \leq 0,$ $-(d \bar{y}_j^{t+1} + g w_j^{3t+1}) + \kappa_j^{t+1} LC_3 \leq 0,$ $U y_j^{t+1} - \kappa_j^{t+1} UC_4 \leq 0,$ $-U y_j^{t+1} + \kappa_j^{t+1} LC_4 \leq 0,$ $v, m, c, h, s, p, L, b, d, g, q, U \geq 0.$

بنابراین شاخص بهره‌وری مالمکوئیست مرحله i ام ($i = 1, 2, 3, 4, \alpha$) در زمان‌های t+1 نسبت به t از رابطه زیر به دست می‌آید:

$$MPI_p^i = \sqrt{\frac{\theta_p^{i,t+1}(t+1) \cdot \theta_p^{i,t+1}(t+1)}{\theta_p^{i,t}(t) \cdot \theta_p^{i,t+1}(t)}} = \frac{\theta_p^{i,t+1}(t+1)}{\theta_p^{i,t}(t)} \cdot \sqrt{\frac{\theta_p^{i,t}(t+1) \cdot \theta_p^{i,t}(t)}{\theta_p^{i,t+1}(t) \cdot \theta_p^{i,t+1}(t+1)}}.$$

در این صورت، تعریف پیشرفت و پسرفت برای هر کدام از زیر گروه‌ها و همچنین ساختار کل را بصورت جدول ۲ خواهیم داشت.

۳-۶- ترکیب شبکه عصبی با مدل (BSC-DEA-ANN) BSC-DEA

مدل پیشنهادی BSC-DEA-ANN که در آن از شبکه عصبی پرسپترون چند لایه استفاده شده است بصورت گام های زیر می‌باشد:

۱. ورودی شبکه را از ورودی‌ها و خروجی‌های هر DMU تشکیل دهید.
۲. مقدار کارایی DMU با استفاده از مدل پیشنهادی بالا به دست آورده و آن را در خروجی شبکه قرار دهید.
۳. اطلاعات مربوط به DMU ها را نرمال سازی کنید.
۴. DMU ها را به سه گروه داده‌های آموزش، داده‌های اعتبار سنجی و داده‌های تست تقسیم کنید.



- ۵. وزن‌های شبکه عصبی را با استفاده از داده‌های آموزشی تارسیدن به نتیجه و دقت مورد نظر اصلاح کنید.
- ۶. محاسبه کارایی همه DMU ها با استفاده از شبکه‌ی عصبی آموزش یافته.
- ۷. مقایسه بین نتایج حاصل از مدل ریاضی و مدل $BSC-DEA-ANN$: در صورت لزوم می‌توان از تحلیل رگرسیونی و همبستگی بین نتایج دو روش استفاده کرد.

جدول ۲- تحلیل پیشرفت و پسرفت مراحل چهارگانه مدل.

Table 2- Analysis of progress and regression of the four stages of the model.

پیشرفت و پسرفت مرحله دوم	پیشرفت و پسرفت مرحله اول
الف) اگر $MPI_p^2 > 1$ در این صورت مؤلفه دوم $DMUp$ دارای پیشرفت است. ب) اگر $MPI_p^2 < 1$ در این صورت مؤلفه دوم $DMUp$ دارای پسرفت است. ج) اگر $MPI_p^2 = 1$ در این صورت مؤلفه دوم $DMUp$ نه پیشرفت داشته و نه پسرفت.	الف) اگر $MPI_p^1 > 1$ در این صورت مؤلفه اول $DMUp$ دارای پیشرفت است. ب) اگر $MPI_p^1 < 1$ در این صورت مؤلفه اول $DMUp$ دارای پسرفت است. ج) اگر $MPI_p^1 = 1$ در این صورت مؤلفه اول $DMUp$ نه پیشرفت داشته و نه پسرفت.
پیشرفت و پسرفت مرحله پنجم	پیشرفت و پسرفت مرحله چهارم
الف) اگر $MPI_p^4 > 1$ در این صورت مؤلفه چهارم $DMUp$ دارای پیشرفت است. ب) اگر $MPI_p^4 < 1$ در این صورت مؤلفه چهارم $DMUp$ دارای پسرفت است. ج) اگر $MPI_p^4 = 1$ در این صورت مؤلفه چهارم $DMUp$ نه پیشرفت داشته و نه پسرفت.	الف) اگر $MPI_p^3 > 1$ در این صورت مؤلفه سوم $DMUp$ دارای پیشرفت است. ب) اگر $MPI_p^3 < 1$ در این صورت مؤلفه سوم $DMUp$ دارای پسرفت است. ج) اگر $MPI_p^3 = 1$ در این صورت مؤلفه سوم $DMUp$ نه پیشرفت داشته و نه پسرفت.

لازم به ذکر است که اندازه مجموعه‌های آموزش و تست، تعداد لایه‌های میانی، تعداد نرون‌ها در هر لایه میانی، تابع محرک، نرخ یادگیری و تعداد تکرارها بر اساس آزمون و خطا مشخص می‌گردد. در این مورد، نیلسون اثبات کرد که در شبکه‌های عصبی پرسپترون با یک لایه میانی با تابع محرک سیگموئید در لایه میانی و با تابع خطی در لایه خروجی قادر به تقریب تمامی توابع مورد نظر با هر درجه تقریب خواهد بود، مشروط به این‌که به اندازه کافی نرون در لایه مخفی وجود داشته باشد (منهاج^۱، ۲۰۰۵). این قضیه به تقریب ساز جهانی معروف است. همچنین برای استفاده از مدل پیشنهادی در محاسبه پیشرفت-پسرفت، از آنجا که فقط نیازمند مشخص شدن سه عبارت «پیشرفت»، «پسرفت» و «نه پیشرفت و نه پسرفت» هستیم از این روش با دیدگاه طبقه‌بندی استفاده می‌کنیم.

جدول ۳- پارامترهای تعریف شده.

Table 3- Defined parameters.

x_1 : هزینه‌های انگیزشی	\bar{x}_1 : هزینه وسایل	\bar{x} : هزینه‌های تبلیغات	\bar{x}_1 : هزینه‌های پرسنل
x_2 : رضایت کارکنان	\bar{x} : الکترونیک	\bar{x} : مطالبات معوق	\bar{x}_2 : نرخ دریافت
x_3 : ساعات آموزشی مرتبط با CRM (مدیریت ارتباط با مشتری)	\bar{x}_2 : خدمات پیشرفته	\bar{x}_3 : نسبت هزینه به درآمد	
\dot{w}_1 : مشارکت‌پذیری کارکنان	\dot{w}_1 : سرویس‌های آنلاین	\dot{w}_1 : رضایت مشتری	
\dot{w}_2 : افزایش تخصص کارکنان	\dot{w}_2 : بهبود فرایندهای عملیاتی	\dot{w}_2 : نرخ جذب مشتری	\dot{w}_2 : تعداد ایده‌های اجرایشده مشتری
\dot{w}_3 : بهبود نرم‌افزاری سیستم‌ها	\dot{w}_3 : کاهش هزینه‌های داخلی		
y : حاشیه سود، y_2 : بازده به سرمایه، y_3 : نرخ رشد دارایی.			

^۱ Menhaj



برای ارزیابی بانک‌ها با استفاده از مدل‌های مذکور، ابتدا باید شاخص‌های ورودی و خروجی بانک‌ها مشخص گردند. انتخاب عوامل ورودی و خروجی از مباحث پیشینه در ارزیابی بانک‌ها بوده است. که با مطالعات کتابخانه‌ای و میدانی، شاخص‌های ورودی و میانی و خروجی را برای شعبات بانک‌ها طی دو دوره زمانی تعیین کردیم و با استفاده از این شاخص‌ها مدل را از دیدگاه چهار منظر BSC به صورت جدول ۳ طراحی نمودیم.

در ادامه، برای اینکه نشان دهیم که مدل‌های پیشنهادی چگونه کار می‌کنند، شاخص‌های ذکر شده را ابتدا برای شش بانک و سپس در روش ترکیبی با شبکه عصبی برای ۵۰۰ بانک در دو سال متوالی (۱۳۹۵ و ۱۳۹۶) از ۴ منظر BSC به دست می‌آوریم. در جدول ۴ برای نمونه اطلاعات منظر فرآیند های داخلی را برای سال ۱۳۹۵ آورده شده است:

جدول ۴- داده‌های منظر فرآیند داخلی.
Table 4- Internal process landscape data.

سال	\bar{x}_1	\bar{x}_2	\dot{w}_1	\dot{w}_2 (%)	\bar{w} (%)
1395	1125	550	571	4	5
DMU1	1305	321	500	4/4	7
1395	1192	567	501	7/6	7/5
DMU2	1906	586	492	6/5	5/2
1395	1144	778	517	3/3	6/1
DMU3	1157	318	818	6/5	7/6
1395	1489	577	394	5/2	8/6
DMU4	1500	275	682	4/9	5/8
1395	420	580	481	4/4	4/3
DMU5	745	565	643	4/5	6/5
1395	333	570	308	6/9	8/2
DMU6	517	655	555	6/7	5/4

بعد از محاسبه، کارایی‌ها، در دو سال ۱۳۹۵ و ۱۳۹۶ مطابق روابط ریاضی که در قسمت بالا آورده شده است محاسبه می‌گردد جدول ۵ نتایج محاسبات را نشان می‌دهد.

جدول ۵- نتایج حاصل از تحلیل پوششی داده‌ها.
Table 5- Results of data envelopment analysis.

DMU	L&G	IP	C	F
1395	1396	1395	1396	1395
1	0.9899	0.9868	0.9438	0.8738
2	0.4902	0.6874	1	0.6194
3	0.5181	0.5586	0.8391	1
4	1	0.9990	1	0.9993
5	0.6848	0.6135	1	0.9523
6	0.7679	0.6805	1	1

جدول ۶ نتایج مربوط به محاسبه شاخص بهره‌وری المکوتیست کل در دو سال مذکور را نشان می‌دهد.

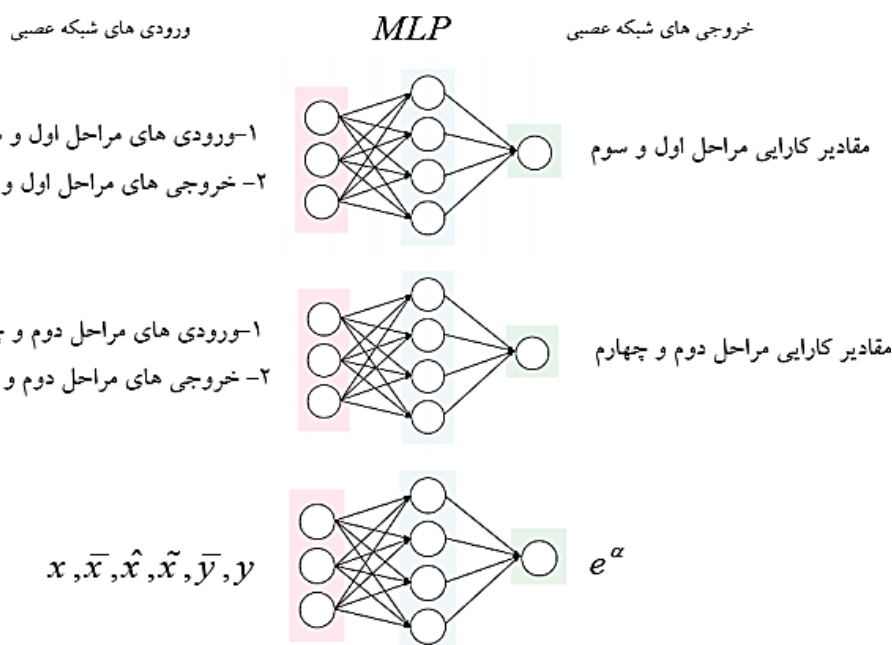
جدول ۶ - محاسبه شاخص بهره‌وری مالک‌کوئیست برای شش شعبه بانک.

Table 6- Calculation of malm quest productivity index for six bank branches.

DMU	1	2	3	4	5	6
شاخص مالم کوئیست	0.6013	0/5415	1.5241	0.6081	0.8372	0.5044

جدول فوق نشان می‌دهد که تنها $DMU3$ روند پیشرفت را داشته و سایر DMU ها پسرفت دارند.

حال می‌خواهیم به پیاده‌سازی مدل پیشنهادی $DEA-BSC-ANN$ برای داده‌های بزرگ پردازیم. به منظور نشان دادن مزایای کاربردی روش پیشنهادی، اطلاعات مجموعه بزرگ شامل ۵۰۰ شعبه بانک ایرانی جمع‌آوری گردید. حجم محاسباتی برای استفاده از روش پیشنهادی $DEA-BSC$ برای حل این مسئله، نسبتاً بالاست. ما این کار را با کدنویسی متلب برای این مسئله انجام داده‌ایم. برای ساخت شبکه عصبی ترکیبی که به محاسبه تحلیل پوششی داده‌های ۴ مرحله‌ای به همراه کارایی کل پردازد، از معماری شکل ۴ استفاده شده است:



شکل ۴ - معماری جامع شبکه عصبی ترکیبی.


Figure 4- Comprehensive neural network architecture.

برای پیاده‌سازی مدل ترکیبی پیشنهادی برای مسئله مذکور، استراتژی زیر را می‌توانیم داشته باشیم: مقادیر کارایی هر مرحله را برای داده‌های دوره t به دست می‌آوریم. (مطابق شکل ۴).

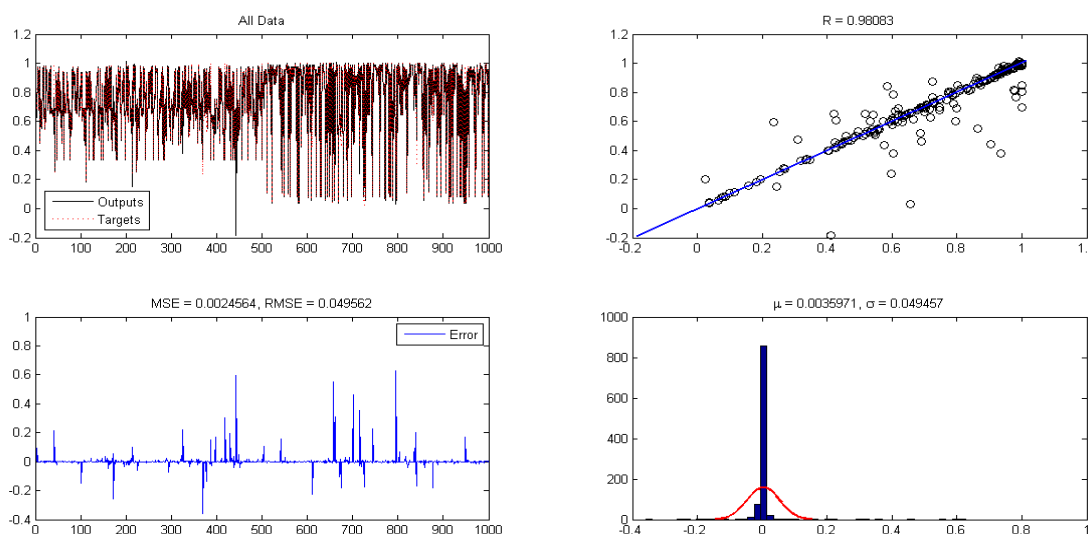
۱. ورودی‌ها و خروجی‌های مربوط به مدل فوق‌الذکر را به‌عنوان ورودی شبکه عصبی پیشنهادی و نیز مقادیر کارایی به‌دست‌آمده از گام اول را به‌عنوان خروجی شبکه عصبی در نظر می‌گیریم.
۲. معماری شبکه عصبی را بر اساس شکل ۴ و مدل MLP می‌سازیم و الگوریتم یادگیری لوبز-مارکوارت را تا رسیدن به نتیجه قابل قبول در آن اجرا می‌کنیم.
۳. با استفاده از شبکه عصبی ساخته‌شده، مقادیر کارایی را برای دوره $t+1$ پیش‌بینی و با مقادیر دقیق مقایسه می‌کنیم.

بعد از به دست آوردن مقادیر کارایی با استفاده از مدل ریاضی، از آن‌ها به‌عنوان خروجی شبکه عصبی استفاده می‌کنیم. از آنجاکه تعداد شعبات بانک‌های موردبررسی ۵۰۰ است، در نتیجه در این مرحله، ۶ ورودی به همراه ۱۰۰۰ نمونه خواهیم داشت. بعد از تعداد معین سیکل و یا وقتی که خطا از مقدار تعیین‌شده کمتر گردد، شبکه عصبی روابط غیرخطی بین ورودی‌ها و خروجی‌های مدل را آموزش می‌بیند. در این مسئله ما از شبکه عصبی پرسپترون چندلایه با دولایه پنهان استفاده می‌کنیم که در شکل ۵ نشان داده شده است و نتایج صحت مدل نیز در شکل ۶ نیز آورده شده است.





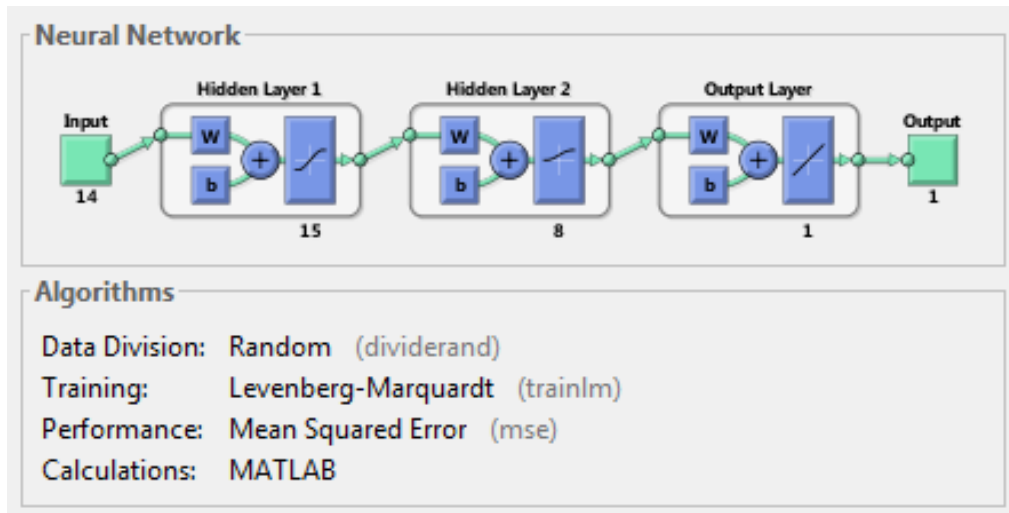
شکل ۵- توپولوژی شبکه عصبی برای کارایی مراحل اول و سوم.
Figure 5- Neural network topology for the first and third stages.



شکل ۶- نتایج شبیه سازی مدل با معماری شبکه ساخته شده برای مراحل اول و سوم.
Figure 6- Results of simulation of model with network architecture built for the first and third stages.

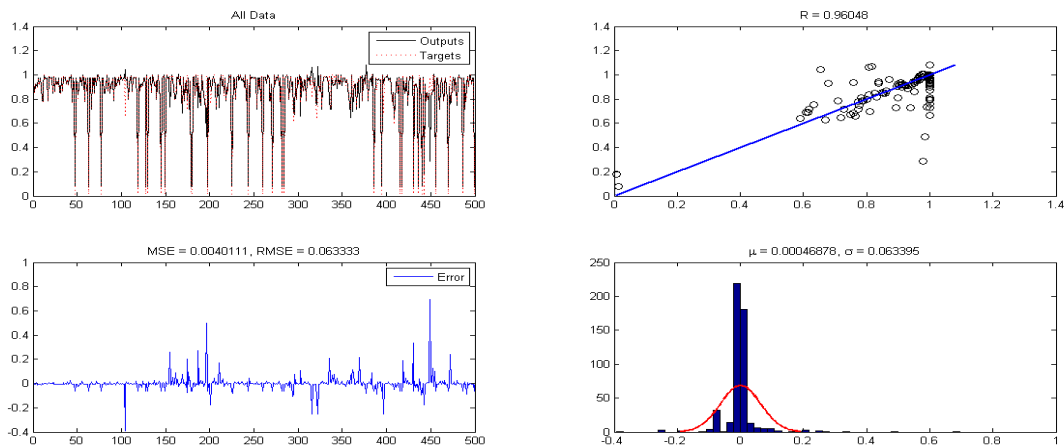
نتایج شبیه سازی نشان می دهد که شبکه عصبی پیشنهادی قابلیت اطمینان مناسبی دارد. مشابه بحث کارایی مراحل دوم و چهارم در دوره t را بدست می آوریم و نتایج آن ها نیز نشان دهنده قابلیت اطمینان مناسب به نتایج می باشد.

حال به ساخت شبکه عصبی برای به دست آوردن کارایی تجمعی (کل) برای دوره t می پردازیم. مطابق شکل ۷ ما از شبکه عصبی پرسپترون چندلایه با دولایه پنهان استفاده می کنیم.



شکل ۷- توپولوژی شبکه عصبی برای کارایی مرحله کلی.
Figure 7- Neural network topology for general stage functionality.

نتایج شبیه‌سازی نشان می‌دهد که شبکه عصبی پیشنهادی قابلیت اطمینان مناسبی دارد مشخصات مذکور در شکل ۸ برای کل داده‌ها با رگرسیون ۰٫۹۶۰۴۸ نشان داده می‌شود.




شکل ۸ - مشخصات کل داده‌ها با استفاده از شبکه عصبی پیشنهادی برای کارایی کلی.
Figure 8- Specify the total data using the proposed neural network for overall performance.

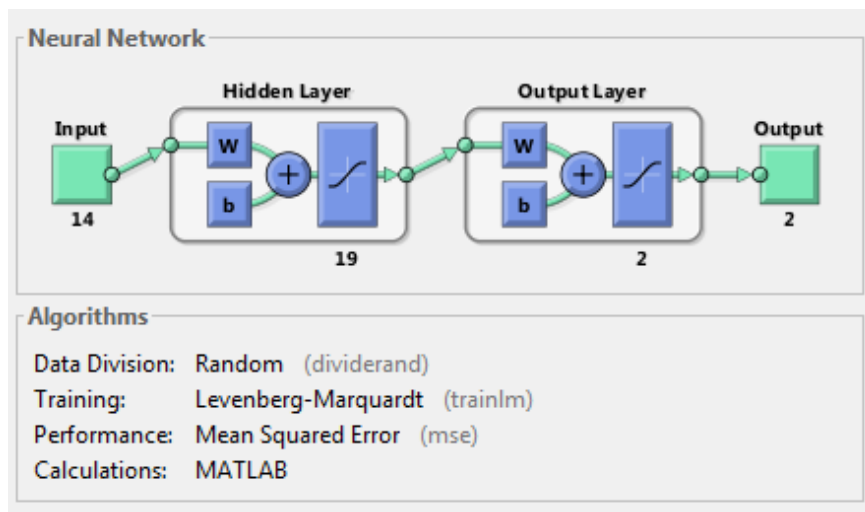
حال بنا به استراتژی حل مسئله، با استفاده از شبکه عصبی ترکیبی ساخته‌شده، مقادیر کارایی را در دوره بعد $(t+1)$ پیش‌بینی می‌کنیم. در ادامه مقادیر این پیش‌بینی را با مقادیر واقعی کارایی‌ها مقایسه می‌کنیم. حال به محاسبه پیشرفت و پسرقت DMU ‌ها در ۵۰۰ شعبه بانک می‌پردازیم. شکل ۹ محاسبه شاخص بهره‌وری مالمکوونیست کل ۵۰۰ شعبه بانک در دو سال متوالی را نشان می‌دهد.

نتایج به‌دست‌آمده نشان می‌دهد که DMU ۴۴۳ پسرقت و تعداد DMU ۵۷ پیشرفت داشته‌اند. حال برای محاسبه پیشرفت و پسرقت با استفاده از شبکه عصبی الگوریتم زیر را پیاده‌سازی می‌کنیم:

۱. ورودی شبکه عصبی برای پارامتر i ($i=1,2,14$): داده‌های هر DMU در دوره $t+1$ را بر داده‌های همان DMU در دوره t تقسیم کرده و عدد به‌دست‌آمده را به‌عنوان i امین ورودی شبکه عصبی برای این DMU در نظر می‌گیریم.
۲. خروجی شبکه عصبی: خروجی به‌دست‌آمده از شکل ۱۰ را در نظر گرفته و اگر عدد مربوطه بزرگ‌تر از یک باشد، مقدار ۲ (متناظر با پیشرفت) و در غیر این صورت مقدار ۱ (متناظر با پسرقت) قرار می‌دهیم. در حقیقت با این عمل، شبکه عصبی به دسته‌بندی DMU ‌ها در دو طبقه ۱ (متناظر با پسرقت) و ۲ (متناظر با پیشرفت) می‌پردازد.



شکل ۹- محاسبه پیشرفت و پسرفت.
Figure 9- Calculate progress and regression.




شکل ۱۰- توپولوژی شبکه عصبی برای محاسبه پیشرفت/پسرفت.
Figure 10- Neural network topology to calculate progression / regression.

هدف اصلی از ارائه روش پیشنهادی، شناسایی بهتر پیشرفت و پسرفت واحدهای تصمیم‌گیری است. همواره این تمایل وجود دارد که فرآیند شناسایی با حداکثر دقت و صرف حداقل زمان انجام شود. به عبارت دیگر وقتی ۱۴ ورودی به روش پیشنهادی داده می‌شود، انتظار می‌رود این روش، پیشرفت/پسرفت واحد تصمیم‌گیری موردنظر را در کوتاه‌ترین زمان و به‌درستی از بین مجموعه داده‌ها تشخیص دهد؛ بنابراین می‌توان گفت، دو هدف اصلی از ارائه روش، بالا بردن سرعت و دقت در شناسایی پیشرفت/پسرفت واحد تصمیم‌گیری است. بعد از پیاده‌سازی الگوریتم پیشنهادی، باید کیفیت این روش بررسی شود که با شاخص‌هایی همانند *True Positive*، *False Positive*، *True Negative* و *False Negative* صورت می‌پذیرد.

مطابق الگوریتم بالا، بررسی ساخت شبکه عصبی برای شناسایی پیشرفت و پسرفت *DMU* ها صورت پذیرفت. در این مسئله، ۱۴ ورودی به همراه ۵۰۰ نمونه خواهیم داشت. در اینجا ما از شبکه عصبی *MLP* با یک لایه پنهان استفاده می‌کنیم که در شکل ۱۰ نشان داده شده است.

شبکه عصبی را مطابق با اطلاعات داده شده، آموزش می‌دهیم. ماتریس درهم‌ریختگی برای آموزش، نشان می‌دهد که شبکه عصبی به خوبی آموزش دیده است. نتایج نشان می‌دهد در این آموزش، پدیده سرریز شدن اتفاق نیافتاده است.



شکل ۱۱ - ماتریس درهم‌ریختگی برای داده‌های اعتبار سنجی.

Figure 11- Decomposition matrix for validation data.

در این شکل DMU ۵۰ به‌عنوان داده‌های اعتبار سنجی به‌طور تصادفی انتخاب شده‌اند که در آن، DMU ۴۷ به‌درستی به‌عنوان پسرقت طبقه‌بندی شده‌اند. این عدد متناظر با ۹۴٪ از تمام DMU ۵۰ است. به‌طور مشابه، یک مورد به‌درستی به‌عنوان پیشرفت طبقه‌بندی شده است. این عدد مربوط به ۲٪ از تمام DMU های اعتبار سنجی است. همچنین، یک DMU که در دسته واقعی پیشرفت قرار دارد، نادرست به‌عنوان پسرقت دسته‌بندی شده‌اند و این مربوط به ۲٪ از تمام DMU های اعتبار سنجی می‌باشد. به‌طور مشابه، یک DMU که در دسته پسرقت هستند، به‌اشتباه به‌عنوان پیشرفت طبقه‌بندی شده‌اند و این به ۲٪ از تمام DMU های اعتبار سنجی مربوط می‌شود. از ۴۸ پیش‌بینی پسرقت، ۹۷٪ درست و ۱٪ اشتباه است. آخرین سلول نیز نشان می‌دهد که ۹۶٪ از پیش‌بینی‌ها درست هستند و ۴٪ اشتباه هستند که این نتایج رضایت‌بخش است و از آن می‌توان دریافت که پدیده سرریز شدن اتفاق نیفتاده است. به‌طور کلی، نتایج ارائه شده نشان‌دهنده کارایی روش‌های ترکیبی پیشنهادی نسبت به روش‌های غیر ترکیبی است و نشان می‌دهد که ارزیابی کارایی همه واحدهای تصمیم‌گیری و تشخیص پیشرفت و پسرقت آن‌ها در سطح خوبی انجام می‌شود. همچنین این نتایج نشان می‌دهد که در موقعیت‌های واقعی همچون بورس و بانک‌ها که با داده‌های بزرگ سرکار دارد و اطلاعات داده‌ای می‌تواند مثبت یا منفی باشد، استفاده از مدل‌های پیشنهادی می‌تواند مفید باشد.

۸- نتیجه‌گیری

در این مقاله یک مدل ترکیبی تحلیل پوششی داده‌های شبکه‌ای و کارت امتیازی متوازن ارائه داده‌ایم که در حقیقت یک مدل تحلیل پوششی داده‌های چهار مرحله‌ای است. سپس یک مدل تطبیقی از شاخص مالکونیست و مدل پیشنهادی را برای محاسبه پیشرفت و پسرقت واحدهای تصمیم‌گیری پیشنهاد دادیم. سرانجام با استفاده از شبکه عصبی در ارائه مدل ترکیبی تحلیل پوششی داده‌های شبکه‌ای و کارت امتیازی متوازن را برای ارزیابی عملکرد سازمان‌ها طراحی نمودیم. مطالعه موردی با ۵۰۰ شعبه بانک برای ارزیابی شبکه عصبی پیشنهادی مورد استفاده قرار گرفتند. به‌طور کلی نتایج پیاده‌سازی نشان داد که روش‌های پیشنهادی می‌توانند ابزارهای نویدبخشی برای ارزیابی عملکرد سازمان‌ها و به‌خصوص داده‌های بزرگ باشند.



- Agarwal, S. (2016). DEA-neural networks approach to assess the performance of public transport sector of India. *Opsearch*, 53(2), 248-258. <https://doi.org/10.1007/s12597-015-0229-2>
- Akbarian, M., Najafi, E., Tavakkoli-Moghaddam, R., & Hosseinzadeh-Lotfi, F. (2015). A network-based data envelope analysis model in a dynamic balanced score card. *Mathematical problems in engineering*, 2015. <https://doi.org/10.1155/2015/914108>
- Amado, C. A., Santos, S. P., & Marques, P. M. (2012). Integrating the Data Envelopment Analysis and the Balanced Scorecard approaches for enhanced performance assessment. *Omega*, 40(3), 390-403. <https://doi.org/10.1016/j.omega.2011.06.006>
- Asosheh, A., Nalchigar, S., & Jamporzmei, M. (2010). Information technology project evaluation: An integrated data envelopment analysis and balanced scorecard approach. *Expert systems with applications*, 37(8), 5931-5938. <https://doi.org/10.1016/j.eswa.2010.02.012>
- Athanassopoulos, A. D., & Curram, S. P. (1996). A comparison of data envelopment analysis and artificial neural networks as tools for assessing the efficiency of decision making units. *Journal of the operational research society*, 47(8), 1000-1016. <https://doi.org/10.1057/jors.1996.127>
- Azadeh, A., Ghaderi, S. F., Anvari, M., Saberi, M., & Izadbakhsh, H. (2007). An integrated artificial neural network and fuzzy clustering algorithm for performance assessment of decision making units. *Applied mathematics and computation*, 187(2), 584-599. <https://doi.org/10.1016/j.amc.2006.08.092>
- Azadeh, A., Javanmardi, L., & Saberi, M. (2010). The impact of decision-making units features on efficiency by integration of data envelopment analysis, artificial neural network, fuzzy C-means and analysis of variance. *International journal of operational research*, 7(3), 387-411. <https://doi.org/10.1504/IJOR.2010.032113>
- Badiezadeh, T., Saen, R. F., & Samavati, T. (2018). Assessing sustainability of supply chains by double frontier network DEA: A big data approach. *Computers & operations research*, 98, 284-290. <https://doi.org/10.1016/j.cor.2017.06.003>
- 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>
- Basso, A., Casarin, F., & Funari, S. (2018). How well is the museum performing? A joint use of DEA and BSC to measure the performance of museums. *Omega*, 81, 67-84. <https://doi.org/10.1016/j.omega.2017.09.010>
- Bauer, P. W., Berger, A. N., Ferrier, G. D., & Humphrey, D. B. (1998). Consistency conditions for regulatory analysis of financial institutions: a comparison of frontier efficiency methods. *Journal of economics and business*, 50(2), 85-114. [https://doi.org/10.1016/S0148-6195\(97\)00072-6](https://doi.org/10.1016/S0148-6195(97)00072-6)
- Brons, M., Nijkamp, P., Pels, E., & Rietveld, P. (2005). Efficiency of urban public transit: A meta analysis. *Transportation*, 32(1), 1-21. <https://doi.org/10.1007/s11116-004-0939-4>
- Castelli, L., Pesenti, R., & Ukovich, W. (2001). DEA-like models for efficiency evaluations of specialized and interdependent units. *European journal of operational research*, 132(2), 274-286. [https://doi.org/10.1016/S0377-2217\(00\)00151-X](https://doi.org/10.1016/S0377-2217(00)00151-X)
- Cavallin, A., Frutos, M., Vigier, H. P., & Rossit, D. G. (2018). An integrated model of data envelopment analysis and artificial neural networks for improving efficiency in the municipal solid waste management. In *Handbook of research on emergent applications of optimization algorithms* (pp. 206-231). IGI Global. DOI: 10.4018/978-1-5225-2990-3.ch009
- Celebi, D., & Bayraktar, D. (2008). An integrated neural network and data envelopment analysis for supplier evaluation under incomplete information. *Expert systems with applications*, 35(4), 1698-1710. <https://doi.org/10.1016/j.eswa.2007.08.107>
- Charnes, A., Cooper, W. W., Golany, B., Halek, R., Klopp, G., Schmitz, E., & Thomas, D. (1986). *Two phase data envelopment analysis approach to policy evaluation and management of army recruiting activities: Tradeoffs between joint services and army advertising research report CCS no. 532*. Austin, TX: Center for cybernetic studies, the university of texas.
- Chen, T. Y., & Chen, L. H. (2007). DEA performance evaluation based on BSC indicators incorporated: The case of semiconductor industry. *International journal of productivity and performance management*, 56(4), 335-357. <https://doi.org/10.1108/17410400710745333>
- Chen, Y., & Ali, A. I. (2004). DEA Malmquist productivity measure: New insights with an application to computer industry. *European journal of operational research*, 159(1), 239-249. [https://doi.org/10.1016/S0377-2217\(03\)00406-5](https://doi.org/10.1016/S0377-2217(03)00406-5)
- Chen, Y., Cook, W. D., Li, N., & Zhu, J. (2009). Additive efficiency decomposition in two-stage DEA. *European journal of operational research*, 196(3), 1170-1176. <https://doi.org/10.1016/j.ejor.2008.05.011>
- Chiang, C. Y., & Lin, B. (2009). An integration of balanced scorecards and data envelopment analysis for firm's benchmarking management. *Total quality management*, 20(11), 1153-1172. <https://doi.org/10.1080/14783360903248286>
- Delgado, F. J. (2005). Measuring efficiency with neural networks, an application to the public sector. *Economics bulletin*, 3(15), 1-10.
- Dolasinski, M. J., Roberts, C., & Zheng, T. (2019). Measuring hotel channel mix: A Dea-BSC model. *Journal of hospitality & tourism research*, 43(2), 188-209. <https://doi.org/10.1177/1096348018789741>
- Duygun, M., Prior, D., Shaban, M., & Tortosa-Ausina, E. (2016). Disentangling the European airlines efficiency puzzle: A network data envelopment analysis approach. *Omega*, 60, 2-14. <https://doi.org/10.1016/j.omega.2015.06.004>
- Eilat, H., Golany, B., & Shtub, A. (2006). Constructing and evaluating balanced portfolios of R&D projects with interactions: A DEA based methodology. *European journal of operational research*, 172(3), 1018-1039. <https://doi.org/10.1016/j.ejor.2004.12.001>
- Eilat, H., Golany, B., & Shtub, A. (2008). R&D project evaluation: An integrated DEA and balanced scorecard approach. *Omega*, 36(5), 895-912. <https://doi.org/10.1016/j.omega.2006.05.002>
- Emrouznejad, A., & Shale, E. (2009). A combined neural network and DEA for measuring efficiency of large scale datasets. *Computers & industrial engineering*, 56(1), 249-254. <https://doi.org/10.1016/j.cie.2008.05.012>



- Färe, R., Grosskopf, S., Lindgren, B., & Roos, P. (1994). Productivity developments in Swedish hospitals: a Malmquist output index approach. In *Data envelopment analysis: Theory, methodology, and applications* (pp. 253-272). Dordrecht: Springer.
- Farell, P. (1957). DEA in production center: An input-output mode. *Journal of econometrics*, 3, 23-49.
- Hagan, M. T., Demuth, H. B., & Beale, M. (1997). *Neural network design*. PWS Publishing Co.
- Hu, S. C., Chung, Y. K., & Chen, Y. S. (2008). Using Hopfield neural networks to solve DEA problems. *2008 IEEE Conference on Cybernetics and Intelligent Systems* (pp. 606-611). IEEE.
- Kwon, H. B. (2014). Performance modeling of mobile phone providers: A DEA-ANN combined approach. *Benchmarking: an international journal*, 21(6), 1120-1144.
- 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, 159-170.
- Kwon, H. B., & Lee, J. (2015). Two-stage production modeling of large US banks: A DEA-neural network approach. *Expert systems with applications*, 42(19), 6758-6766.
- Kwon, H. B., & Lee, J. (2015). Two-stage production modeling of large US banks: A DEA-neural network approach. *Expert systems with applications*, 42(19), 6758-6766.
- Kwon, H. B., Lee, J., & Roh, J. J. (2016). Best performance modeling using complementary DEA-ANN approach: Application to Japanese electronics manufacturing firms. *Benchmarking: an international journal*, 23(3), 704-721.
- Kwon, H. B., Marvel, J. H., & Roh, J. J. (2017). Three-stage performance modeling using DEA-BPNN for better practice benchmarking. *Expert systems with applications*, 71, 429-441.
- Minhaj, M. B. (2005). *Fundamentals of neural networks*. Amirkabir University of Technology Press.
- 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.
- Shabanpour, H., Yousefi, S., & Saen, R. F. (2017). Forecasting efficiency of green suppliers by dynamic data envelopment analysis and artificial neural networks. *Journal of cleaner production*, 142, 1098-1107. <https://doi.org/10.1016/j.jclepro.2016.08.147>
- Shokrollahpour, E., Lotfi, F. H., & Zandieh, M. (2016). An integrated data envelopment analysis-artificial neural network approach for benchmarking of bank branches. *Journal of industrial engineering international*, 12(2), 137-143.
- Singh, N., & Pant, M. (2017, December). Evaluating the efficiency of higher secondary education state boards in India: A DEA-ANN approach. *International conference on intelligent systems design and applications* (pp. 942-951). Springer, Cham. https://doi.org/10.1007/978-3-319-76348-4_90
- Toloo, M., Zandi, A., & Emrouznejad, A. (2015). Evaluation efficiency of large-scale data set with negative data: an artificial neural network approach. *The journal of supercomputing*, 71(7), 2397-2411.
- Wu, D. D., Yang, Z., & Liang, L. (2006). Using DEA-neural network approach to evaluate branch efficiency of a large Canadian bank. *Expert systems with applications*, 31(1), 108-115.