E-ISSN: 2676-6159 | P-ISSN: 2538-5079

Journal of Decisions and Operations Research

www.journal-dmor.ir

J. Decis. Oper. Res. Vol. 7, No. 4 (2022) 610–627.

Paper Type: Original-Application Paper

Provide an Optimal Model for Determining and Ranking Inefficiency Factors in the Banking Industry by Combining Data Envelopment Analysis and Neural Network

Gholamreza Panahandeh Khojin[1], Abbass Toloie Eshlaghy[1,*], Mohammad Ali Afshar Kazemi[2]

[1] *Department of Industrial Management, Faculty of Economics and Management, Science and Research Branch, Islamic Azad University, Tehran, Iran; panahandeh1354@yahoo.com; toloie@srbiau.ac.ir.*

[2] *Department of Industrial Management, Faculty of Economics and Management, Central Tehran Branch, Islamic Azad University, Tehran, Iran; dr.mafshar@gmail.com.*

Citation:

Panahandeh Khojin, Gh., Toloie Eshlaghy, A., & Afshar Kazemi, M. A. (2022). Provide an optimal model for determining and ranking inefficiency factors in the banking industry by combining data envelopment analysis and neural network. *Journal of decisions and operations research, 7*(4), 610-627.

Received: 06/09/2020 Reviewed: 03/10/2020 Revised: 14/02/2021 Accepted: 20/02/2021

Abstract

Purpose: Data envelopment analysis is a method for comparing and evaluating the relative efficiency of decision-making units, each of which has several similar inputs and outputs. Every organization has an urgent need for an efficiency evaluation system in order to know the level of desirability and quality of its activities, especially in complex and dynamic environments. The purpose of this study is to combine two methods of data envelopment analysis and neural network in order to provide an optimal model for ranking inefficiency factors in the banking industry of Iran.

Methodology: The current research is a cross-sectional descriptive study that was conducted on 32 bank branch managers. First, through the study of theoretical foundations and interviews with banking experts, performance evaluation indicators in the banking industry were identified and finalized. Further, in order to evaluate the efficiency of the units in the studied statistical population, the technique of data envelopment analysis was used, especially the modified goal programming model of data envelopment analysis, and out of the 32 bank managements studied, 3 effective managements and 29 ineffective managements were recognized. Then, branches under inefficient managements were evaluated and using the information of inefficient branches, a neural network matrix was prepared to detect inefficiency factors and the results were analyzed with different neural network models. The model with the lowest mean squared error was selected as the optimal model in order to determine the inefficiency factors.

Findings: The results of combining data envelopment analysis technique, especially the modified goal programming model of data envelopment analysis with neural networks showed that self-organizing mapping neural network with hyperbolic tangent transfer function and 0.9 momentum training rule has the best performance compared to other methods in identification of inefficiency factors. After analyzing the sensitivity of the mentioned method, the indicators of the provinces' liquidity share, personnel distribution and operational costs were selected as the most important factors of inefficiency.

Originality/Value: The integration of data envelopment analysis models with neural networks to evaluate the efficiency of decision-making units along with the identification of inefficiency factors can help managers of organizations in improving the inefficiency factors of decision-making units.

Keywords: Data envelopment analysis, Modified goal programming data envelopment analysis, Neural network, Self-organized neural network, Inefficiency factors.

Corresponding Author: toloie@srbiau.ac.ir

https://doi.org/20.1001.1.25385097.1401.7.4.9.0

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).

Journal of Decisions and Operations Research

تصمیم‌گیری و تحقیق در عملیات

دوره ۷، شماره (۴)، (۱۴۰۱)، ۶۲۷-۶۱۰

www.journal-dmor.ir

نوع مقاله: پژوهشی-کاربردی

ارایه مدل بهینه جهت تعیین و رتبه بندی عوامل ناکارایی در صنعت بانکداری با تلفیق تحلیل پوششی داده‌ها و شبکه عصبی

غلامرضا پناهنده خوجین[۱]، عباس طلوعی اشلقی[۱،*]، محمد علی افشار کاظمی[۲]

[۱]گروه مدیریت صنعتی، دانشکده اقتصاد و مدیریت، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

[۲]گروه مدیریت صنعتی، دانشکده اقتصاد و مدیریت، واحد تهران مرکز، دانشگاه آزاد اسلامی، تهران، ایران.

چکیده

هدف: تحلیل پوششی داده‌ها روشی برای مقایسه و ارزیابی کارایی نسبی واحدهای تصمیم‌گیرنده است که هر یک دارای چندین ورودی و خروجی مشابه هستند. هر سازمان به‌منظور آگاهی از میزان مطلوبیت و مرغوبیت فعالیت‌های خود به ویژه در محیط‌های پیچیده و پویا، نیاز مبرم به سیستم ارزیابی کارایی دارد. هدف از این مطالعه تلفیق دو روش تحلیل پوششی داده‌ها و شبکه عصبی به منظور ارائه یک مدل بهینه برای رتبه‌بندی عوامل ناکارایی در صنعت بانکداری ایران می‌باشد.

روش‌شناسی پژوهش: پژوهش حاضر یک مطالعه توصیفی مقطعی می‌باشد که بر روی ۳۲ مدیریت شعب بانک انجام گردید. ابتدا از طریق مطالعه مبانی نظری و مصاحبه با خبرگان بانکی شاخص‌های ارزیابی کارایی در صنعت بانکداری شناسایی و نهایی گردید. در ادامه به‌منظور ارزیابی کارایی واحدها در جامعه آماری مورد مطالعه از تکنیک تحلیل پوششی داده‌ها به ویژه مدل برنامه‌ریزی آرمانی اصلاح شده تحلیل پوششی داده‌ها استفاده شد که از ۳۲ مدیریت بانک مورد مطالعه، ۳ مدیریت کارا و ۲۹ مدیریت ناکارا تشخیص داده شدند. سپس شعب زیرمجموعه مدیریت‌های ناکارا مورد ارزیابی قرار گرفته و با استفاده از اطلاعات شعب ناکارا ماتریس شبکه عصبی برای تشخیص عوامل ناکارایی تهیه و با مدل‌های مختلف شبکه عصبی به تحلیل نتایج پرداخته شد. مدلی که کم‌ترین میانگین مجذور خطا را داشت به عنوان مدل بهینه به‌منظور تعیین عوامل ناکارایی انتخاب شد.

یافته‌ها: نتایج تلفیق تکنیک تحلیل پوششی داده‌ها به ویژه مدل برنامه‌ریزی آرمانی اصلاح شده تحلیل پوششی داده‌ها با شبکه‌های عصبی نشان داد که شبکه عصبی نگاشت خودسازمان‌ده با تابع انتقال تانژانت هیپربولیک و با قاعده آموزش ممنتم ۰/۹ بهترین عملکرد را نسبت به دیگر روش‌ها در شناسایی عوامل ناکارایی داشت. پس از تحلیل حساسیت روش مذکور شاخص‌های سهم نقدینگی استان‌ها، توزیع پرسنل و هزینه‌های عملیاتی به عنوان مهم‌ترین عوامل ناکارایی انتخاب شدند.

اصالت/ارزش افزوده علمی: تلفیق مدل‌های تحلیل پوششی داده‌ها با شبکه‌های عصبی برای ارزیابی کارایی واحدهای تصمیم‌گیرنده به همراه شناسایی عوامل ناکارایی، می‌تواند مدیران سازمان‌ها را در بهبود عوامل ناکارایی واحدهای تصمیم‌گیرنده یاری کند.

کلیدواژه‌ها: تحلیل پوششی داده‌ها، برنامه‌ریزی آرمانی اصلاح‌شده تحلیل پوششی داده‌ها، شبکه عصبی، شبکه عصبی خودسازمان‌ده، عوامل ناکارایی.

۱- مقدمه

بانک‌ها به کمک سیاست‌های اعتباری و مالی خود قادرند وسایل رشد و توسعه اقتصادی را در کشور فراهم کرده یا با اعطای تسهیلات بازرگانی، صنعتی و تولیدی، توسعه اقتصادی کشور را فراهم نمایند. به دلیل نقش بسیار مهم و اساسی بانک‌ها در اکثر فعالیت‌های اقتصادی،

* نویسنده مسئول

toloie@srbiau.ac.ir

https://doi.org/20.1001.1.25385097.1401.7.4.9.0

بررسی عملکرد هر یک از بانک‌های موجود در کشور اهمیت ویژه‌ای یافته است (مهر آرا و مهران فر[1]، ۲۰۱۵). در این فضای رقابتی، سنجش کارایی بانک از اهمیت بالایی برای مدیران بانک و سهامداران برخوردار است، زیرا مدیران برای باقی ماندن در عرصه رقابت با سایر بانک‌ها نیازمند رسیدن به بالاترین سطح کارایی هستند (رنجبر و همکاران[2]، ۲۰۱۶).

هدف اصلی هر سازمان مالی بهبود عملکرد بوده و ارزیابی عملکرد یکی از بهترین راه‌ها برای بهبود عملیات در سازمان‌ها است. امروزه شاخص‌های گوناگونی به‌عنوان معیار ارزیابی عملکرد سازمان‌ها مطرح شده‌اند که کارایی یکی از مهم‌ترین این معیارها هستند (آذر و همکاران[3]، ۲۰۱۴). طبق تعریف، کارایی[4] به مفهوم اجرای درست‌کارها در سازمان است؛ یعنی تصمیم‌هایی که باهدف کاهش هزینه‌ها، افزایش مقدار تولید و بهبود کیفیت محصول گرفته می‌شوند. در اقتصاد مفهوم کارایی، همان تخصیص بهینه منابع است، اما روی‌هم‌رفته، می‌توان گفت که کارایی، معرف نسبت ستاده‌ها به نهاده‌ها در مقایسه با یک استاندارد مشخص است (اردبیلی میانجی و بریم نژاد[5]، ۲۰۱۷).

در اندازه‌گیری کارایی واحدها روش‌های مختلفی به کار گرفته می‌شود. به‌طورکلی دو گروه از روش‌های عمده برای اندازه‌گیری کارایی وجود دارد. این دو گروه عبارت‌اند از: روش‌های پارامتری و روش‌های نا پارامتری. تحلیل پوششی داده‌ها[6]، یك روش ناپارامتری برپایه برنامه‌ریزی ریاضی است که برای ارزیابی کارایی واحدهای تصمیم‌گیرنده است که چندین ورودی و چندین خروجی دارند. فارل[7] (۱۹۵۷) با استفاده از روشی همانند اندازه‌گیری کارایی در مباحث مهندسی، به اندازه‌گیری کارایی برای واحد تولیدی اقدام کرد. موردی که فارل برای اندازه‌گیری کارایی مدنظر قرار داد، شامل یك ورودی و یك خروجی بود. چارنز و همکاران[8] (۱۹۷۸) دیدگاه فارل را توسعه دادند و الگویی را ارایه کردند که تحلیل پوششی داده‌ها نام گرفت. تحلیل پوششی داده‌ها به‌عنوان یک ابزار مناسب برای برآورد کارایی شرکت‌هایی که از تکنولوژی‌های تولید با چندین ورودی و چندین خروجی استفاده می‌نمایند، مورداستفاده قرار می‌گیرد (ساهو و همکاران[9]، ۲۰۱۴).

شبکه عصبی مصنوعی[10] از طرز کار شبکه عصبی واقعی اقتباس‌شده است. عصب که نقش انتقال اطلاعات و پیام‌ها را در بدن ایفا می‌کند اجتماعی از نرون‌ها است. نرون[11] یا گره کوچک‌ترین واحد پردازش اطلاعات هست که اساس عملکرد شبکه‌های عصبی را تشکیل می‌دهد (منهاج[12]، ۲۰۰۵). هر یک از نرون‌ها، ورودی‌ها را دریافت نموده و پس از پردازش روی آن‌ها، یک سیگنال خروجی تولید می‌نمایند. لذا هر نرون در شبکه به‌عنوان مرکز پردازش و توزیع اطلاعات عمل کرده، ورودی و خروجی مخصوص به خود را دارد (سادوروسکی[13]، ۲۰۰۶).

تحلیل پوششی داده‌ها و شبکه عصبی به‌عنوان دو ابزار کارآمد معمولا در مسایل بانکی برای مقاطع مختلف مورداستفاده قرارگرفته‌اند. تحلیل پوششی داده‌ها معمولا برای محاسبه کارایی شعب بانک‌ها و شبکه عصبی به‌منظور پیش‌بینی و طبقه‌بندی در حوزه ریسک و اعتبارات بانک‌ها در مطالعات مختلف استفاده شدند (علیحیدری بیوکی و خادمی زارع[14]، ۲۰۱۴).

عزیزی[15] (۲۰۱۵) به ارزیابی کارایی ۲۵ شعبه بانک کشاورزی استان مازندران در سال ۱۳۹۳ با سه رویکرد جذب منابع، تخصیص مصارف و سودآوری پرداخت و با توجه به نمره کارایی به‌دست‌آمده شعب بانک را رتبه‌بندی نمود. نیلچی و همکاران[16] (۲۰۱۷) با استفاده از یک رویکرد فازی به ارزیابی پنج بخش بانک پرداخت و به این نتیجه رسید که بانک کارایی نسبتا قابل‌قبول در زمینه جذب منابع و مدیریت دارد، اما کارایی بخش‌های خدمات، تخصیص منابع و سودآوری با مشکل جدی مواجه است. جهانگیری[17] (۲۰۱۹) بیان نمود که در مجموع ۳۹۴ تحقیق به کاربرد تحلیل پوششی داده‌ها در نظام بانکی ایران پرداختند و بانک‌های ملت و صادرات بیشترین استفاده

[1] Mehrara and Mehranfar
[2] Ranjbar et al.
[3] Azar et al.
[4] Efficiency
[5] Ardabili Mianhi and Barimnejhad
[6] Data Envelopment Analysis (DEA)
[7] Farrell
[8] Charnes et al.
[9] Sahoo et al.
[10] Artifical Neural Network (ANN)
[11] Node
[12] Minhaj
[13] Sadorsky
[14] Aliheidari Bioki and Khademi Zare
[15] Azizi
[16] Nilchi et al.
[17] Jahangiri

از تحلیل پوششی داده‌ها را داشته‌اند. عرب مزار و همکاران[1] (۲۰۱۸) در تحقیقی با استفاده از تحلیل پوششی داده‌های شبکه‌ای به ارزیابی ۱۸ بانک طی سال‌های ۱۳۸۹ تا ۱۳۹۳ پرداختند. احدزاده نمین و همکاران[2] (۲۰۱۹) در تحقیقی با استفاده از رویکرد محدودیت وزنی در تحلیل پوششی داده‌ها به ارزیابی شعب درجه ۱ برای یک بانک تجاری در سال ۱۳۹۵ پرداختند. مقدس و واعظ قاسمی[3] (۲۰۲۱) به ارایه یک مدل جدید کارایی هزینه در تحلیل پوششی داده‌های شبکه‌ای پرداخته و با استفاده از آن به ارزیابی کارایی در حوزه بانکداری پرداخته‌اند.

رجب‌زاده قطری و همکاران[4] (۲۰۰۹) با استفاده از سیستم خبره، شبکه‌های عصبی و شبکه عصبی فازی به رتبه‌بندی اعتباری مشتریان بانک‌ها پرداختند. الهی و همکاران[5] (۲۰۱٤) از مدل ترکیبی شبکه‌های عصبی با بهره‌گیری از یادگیری جمعی به‌منظور ارزیابی ریسک اعتباری بانک‌ها استفاده نمودند که بهترین عملکرد و کم‌ترین هزینه در پیش‌بینی متقاضیان اعتباری از بانک حاصل شد. دادمحمدی و احمدی[6] (۲۰۱٤) با استفاده از شبکه عصبی با اتصالات جانبی به طبقه‌بندی اعتباری مشتریان بانک پرداختند و مدل آن‌ها توانست رفتار مشتریان را با دقت بسیار بالایی در دو گروه خوش‌حساب و بدحساب پیش‌بینی کند. قاسم نیا عربی و صفایی قادیکلایی[7] (۲۰۱۸) به مقایسه عملکرد مدل‌های کلاسیک و هوش مصنوعی در پیش‌بینی وضعیت اعتباری مشتریان بانک‌ها پرداختند و نتایج به‌دست‌آمده از روش شبکه عصبی را با روش رگرسیون لجستیک مقایسه نمودند که حجم مطالبات معوق در شبکه عصبی نسبت به رگرسیون کاهش چشمگیری می‌یابد. علاوه بر این محرابیان و همکاران[8] (۲۰۱۱) با ترکیب تحلیل پوششی داده‌ها و شبکه عصبی به ارزیابی کارایی ٤۰ شعبه بانک اقتصاد نوین پرداختند. میرغفوری و همکاران[9] (۲۰۱٤) با تلفیق تحلیل پوششی داده‌ها و شبکه عصبی به ارایه یک مدل جهت پیش‌بینی مناسب برای ارزیابی عملکرد پرداختند و به‌وسیله مدل ارایه‌شده شعب بانک تجارت در یزد را مورد ارزیابی قراردادند. حسین زاده لطفی و جهانبخش[10] (۲۰۱۵) با استفاده از یک مدل تحلیل پوششی داده‌های شبکه‌ای به ارزیابی ۲٤ شعبه یک بانک ایرانی پرداخته‌اند. حیدری و همکاران[11] (۲۰۱۸) یک مدل ترکیبی شبکه عصبی و تحلیل پوششی داده‌ها را برای ارزیابی عملکرد واحدهای تصمیم‌گیری ارایه دادند و عملکرد شعب بانک را با روش ارایه‌شده محاسبه نمودند. جابری و همکاران[12] (۲۰۲۱) به ارایه یک مدل جامع ترکیبی *NDEA-BSC* برای پیش‌بینی شاخص‌های عملکرد سازمانی پرداخته و راهکاری را برای ارزیابی عملکرد ۵۰۰ شعبه بانک و نیز تشخیص پیشرفت و پسرفت آن‌ها ارایه نمودند. بامطالعه تحقیقات انجام‌شده در صنعت بانکداری مشخص گردید که در تحقیقات قبلی بیشتر به مباحث ارزیابی کارایی پرداخته‌شده و در خصوص تعیین عوامل ناکارایی که به‌عنوان دلایل تاثیرگذار بر عدم کارایی واحدهای تصمیم‌گیرنده هست، تحقیقی انجام‌نشده است. اهمیت این موضوع برای تصمیم‌گیرندگان بانک به‌قدری مهم است که همواره مورد پرسش قرارگرفته و به‌عنوان یک خلا مطالعاتی در این حوزه هست. درواقع تعیین عوامل اصلی ناکارایی بانک به‌عنوان هدف اصلی این تحقیق بوده و برای رسیدن به این هدف در این تحقیق به ارایه یک مدل بهینه برای تعیین و رتبه‌بندی عوامل ناکارایی در صنعت بانکداری ایران پرداخته می‌شود. مدل مورداستفاده تلفیقی از دو تکنیک تحلیل پوششی داده‌ها و شبکه عصبی است.

۲- روش پژوهش

در این تحقیق به دنبال تعیین و رتبه‌بندی عوامل ناکارایی در یک بانک تجاری در کشور ایران با استفاده از تکنیک تلفیقی تحلیل پوششی داده‌ها و شبکه عصبی هستیم. در فلوچارت **شکل ۱**، مراحل انجام تحقیق آورده شده است.

تجزیه‌وتحلیل داده‌ها در دو مرحله انجام خواهد شد، در مرحله اول از مدل‌های تحقیق در عملیات به‌ویژه تحلیل پوششی داده‌ها استفاده می‌شود که نرم‌افزار مورداستفاده *Lingo* می‌باشد. در مرحله بعد پس از مشخص شدن واحدهای تصمیم‌گیرنده ناکارا، برای تعیین علل ناکارایی از مدل‌های شبکه عصبی مصنوعی و از نرم‌افزار *Neuro Solution* استفاده خواهد شد.

پناهنده خوجین و همکاران / تصمیم‌گیری و تحقیق در عملیات، دوره ۷، شماره ۴، زمستان ۱۴۰۱، صفحه: ۶۲۷-۶۱۰

[1] Arabmazar et al.
[2] Ahadzadeh Nami et al.
[3] Moghaddas and Vaez Ghasemi
[4] Rajabzadeh Ghatari et al.
[5] Elahi et al.
[6] Dadmohammadi and Ahmadi
[7] Ghasem Nia Arabi and Safaei Ghadi Kolaei
[8] Mehrabian et al.
[9] Mir Ghafouri et al.
[10] Hosseinzadeh Lotfi and Jahanbakhsh
[11] Heidary et al.
[12] Jaberi et al.

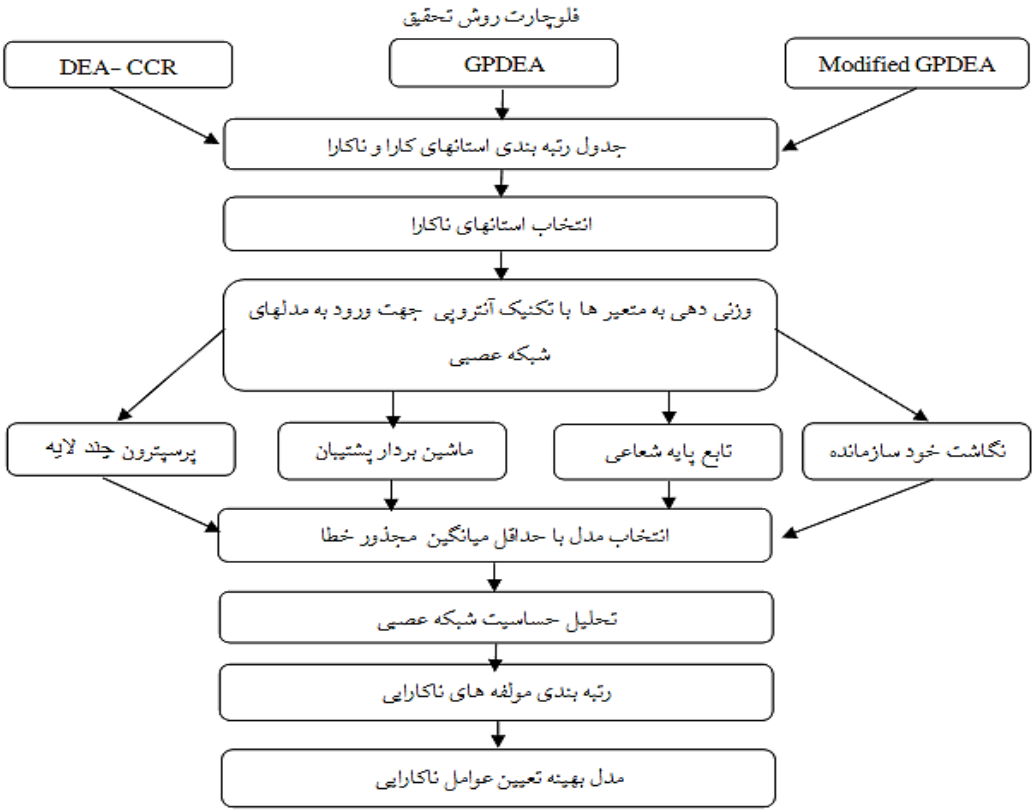

شکل ۱- مراحل انجام تحقیق.

Figure 1- Steps of conducting research.

۱-۲- مدل برنامه‌ریزی خطی چندهدفه برای تحلیل پوششی داده‌ها

لی و ریوز[1] (۱۹۹۹) با استفاده از یک مدل چند هدفه به بهبود قدرت تفکیک‌پذیری در تحلیل پوششی داده‌ها کلاسیک پرداختند. مدل موردنظر یک مدل سه هدفه می‌باشد که تابع هدف اول آن (d_0) یا همان نمره کارایی سنتی می‌باشد؛ اما دو تابع هدف دیگر، d_j و M سبب محدود شدن کارایی سنتی به‌منظور تفکیک‌پذیری بیشتر مدل ارزیابی می‌شود. ارجحیت اهداف در این مدل سه هدفه یکسان می‌باشد. ازآنجاکه توابع d_j و M در مقایسه با تابع هدف نخست به تهیه تعداد واحد کارای کمتری گرایش دارند، به این مطلب می‌توان اشاره کرد که با کاربرد این دو تابع در مدل تحلیل پوششی داده‌های چندهدفه، در مقایسه با مدل تحلیل پوششی داده‌ها کلاسیک، قدرت تفکیک‌پذیری بیشتری مهیا می‌شود. مدل پیشنهادی تحلیل پوششی داده‌های چندهدفه ارایه‌شده توسط لی و ریوز به‌صورت زیر است (لی و ریوز، ۱۹۹۹):

$$
\begin{aligned}
&\min d_0, \\
&\min M, \\
&\min \sum_{j=1}^{n} d_j, \\
&\sum_{i=1}^{m} v_i x_{i0}=1, \\
&\sum_{i=1}^{m} u_r y_{rj} - \sum_{i=1}^{m} v_i x_{ij} + d_j = 0, \quad j=1,\dots,n, \\
&\text{"}M-\text{"}\ \text{"}d\text{"}_\text{"}j\text{"}\ \text{"} \geq 0, \quad j=1,\dots,n, \\
&u_r \geq 0, \ r=1,\dots,s, \\
&v_i \geq 0, \ i=1,\dots,m, \\
&d_j \geq 0, \ j=1,\dots,n.
\end{aligned}
\qquad (۱)
$$

این مدل یک برنامه‌ریزی چند هدفه هست که می‌توان با روش‌های مختلفی آن را حل نمود. یکی از این روش‌ها برنامه‌ریزی آرمانی است که در ادامه توضیح داده می‌شود.

[1] Li and Reeves

۲-۲- مدل برنامه‌ریزی آرمانی تحلیل پوششی داده‌ها

بال و همکاران[1] (۲۰۱۰) برای حل هم‌زمان سه تابع هدف **مدل (۱)** و به‌منظور ارتقای قدرت تفکیک‌پذیری و توزیع مناسب وزن‌ها در تحلیل پوششی داده‌ها، از برنامه‌ریزی آرمانی استفاده نمودند و آن را مدل برنامه‌ریزی آرمانی تحلیل پوششی داده‌ها[2] برمبنای *BCC* نام‌گذاری کردند که به شرح زیر است:

$$
\begin{gathered}
min\, a=\left\{d_1^-+d_1^++d_2^++\sum_j d_{3j}^++\sum_j d_j\right\},\\
\sum_{i=1}^m v_i x_{i0}+d_1^--d_1^+=1,\\
\sum_{i=1}^m u_r y_{rj}+u_0+d_2^--d_2^+=1,\\
\sum_{i=1}^m u_r y_{rj}-\sum_{i=1}^m v_i x_{ij}+u_0+d_j=, j=1,\dots,n,\\
M-d_j+d_{3j}^--d_{3j}^+=0, j=1,\dots,n,\\
u_r\geq 0, r=1,\dots,s,\\
v_i\geq 0, i=1,\dots,m,\\
d_j,d_{3j}^-,d_{3j}^+\geq 0, j=1,\dots,n,\\
d_1^-,d_1^+,d_2^-,d_2^+\geq 0,\\
u_0 \text{ is free.}
\end{gathered}
\tag{۲}
$$

بال و همکاران (۲۰۱۰) مسئله برنامه‌ریزی چند هدفه در **مدل (۱)** را تبدیل به **مدل تک هدفه (۲)** نمودند. برنامه‌ریزی آرمانی به‌طور هم‌زمان همه اهداف را در یک تابع هدف مرکب شامل انحرافات به حداقل می‌رساند که انحراف تفاضل بین هدف در دسترس با سطح آرمان برای هدف موردنظر است.

۲-۳- مدل برنامه‌ریزی آرمانی اصلاح‌شده تحلیل پوششی داده‌ها بر مبنای BCC

در اینجا یک ورژن اصلاح‌شده از مدل *GPDEA-BCC* معرفی خواهد شد. ازآنجایی‌که فضای موجه مدل *BCC* و مدل *GPDEA-BCC* مشابه هستند، بنابراین اصلاح مدل *GPDEA-BCC* مشابه مدل *BCC* به شرح زیر است (دانشور و همکاران[3]، ۲۰۱۵).

ابتدا مدل زیر حل می‌شود:

$$
\begin{gathered}
max\, u_0,\\
\sum_{i=1}^m v_i x_{i0}=1,\\
\sum_{i=1}^m u_r y_{rj}+u_0=1,\\
\sum_{i=1}^m u_r y_{rj}-\sum_{i=1}^m v_i x_{ij}+u_0\leq 0, j=1,\dots,n,\\
u_r\geq 0, r=1,\dots,s,\\
v_i\geq 0, i=1,\dots,m,\\
u_0 \text{ is free.}
\end{gathered}
\tag{۳}
$$

اگر مقدار بهینه برای مدل فوق u_0^+ باشد، در این صورت برای همه واحدهای تصمیم‌گیرنده کارا $u_0^+=1$ است. در ادامه مدل زیر حل خواهد شد:

$$
\begin{gathered}
min\, u_0,\\
\sum_{i=1}^m v_i x_{i0}=1,
\end{gathered}
\tag{۴}
$$

---

[1] Bal et al.

[2] Goal Programming Data Envelopment Analysis (GPDEA-BCC)

[3] Daneshvar et al.

$$\sum_{i=1}^{m} u_r y_{rj}+u_0=1,$$
$$\sum_{i=1}^{m} u_r y_{rj}-\sum_{i=1}^{m} v_i x_{ij}+u_0\le 0,\ j=1,\dots,n,$$
$$u_r\ge 0,\ r=1,\dots,s,$$
$$v_i\ge 0,\ i=1,\dots,m,$$
$$u_0 \text{ is free.}$$

اگر مقدار بهینه برای مدل فوق برابر u_0^- باشد. در این صورت مقدار ε به‌صورت زیر محاسبه می‌شود:

$$\varepsilon=\max\{u_0^-/u_0^-\neq 0,\ \text{for efficient DMUs}\}. \qquad (۵)$$

با جایگذاری ε به‌عنوان یک کران بالا برای متغیرهای آزاد u_0 در مدل *GPDEA-BCC* یک ورژن اصلاح‌شده از این مدل به‌صورت زیر به دست می‌آید که به آن مدل برنامه‌ریزی آرمانی اصلاح‌شده تحلیل پوششی داده‌ها بر مبنای *BCC* (*MODIFI GPDEA-BCC*) گفته می‌شود (دانشور و همکاران، ۲۰۱۵):

$$\min a=\left\{d_1^-+d_1^++d_2^++\sum_j d_{3j}^++\sum_j d_j\right\},$$
$$\sum_{i=1}^{m} v_i x_{i0}+d_1^--d_1^+=1,$$
$$\sum_{i=1}^{m} u_r y_{rj}+u_0+d_2^--d_2^+=1,$$
$$\sum_{i=1}^{m} u_r y_{rj}-\sum_{i=1}^{m} v_i x_{ij}+u_0+d_j=0,\ j=1,\dots,n, \qquad (۶)$$
$$M-d_j+d_{3j}^--d_{3j}^+=0,\ j=1,\dots,n,$$
$$u_r\ge 0,\ r=1,\dots,s,$$
$$v_i\ge 0,\ i=1,\dots,m,$$
$$d_j,d_{3j}^-,d_{3j}^+\ge 0,\ j=1,\dots,n,$$
$$d_1^-,d_1^+,d_2^-,d_2^+\ \ge 0,$$
$$u_0\le\varepsilon.$$

متغیرهای انحرافی d_1^- ,d_1^+, d_2^-, d_2^+, d_{3j}^-, d_{3j}^+ در **مدل (۲)** تعریف‌شده است. با محدود کردن u_0 در مدل *GPDEA-BCC* اصلاح‌شده **مدل (٦)**، نتایج مفید به دست می‌آید. درواقع این مدل با کاهش تعداد واحدهای تصمیم‌گیرنده کارا، موجب بهبود قدرت تفکیک‌پذیری واحدهای تصمیم‌گیرنده می‌شود.

۴-۲- شبکه عصبی مصنوعی

شبکه عصبی مصنوعی از شمار زیادی عناصر پردازشی ویژه به‌هم‌پیوسته به نام نرون تشکیل‌شده است. در شبکه‌های عصبی مصنوعی، اولین لایه که داده‌های ورودی به آن وارد می‌گردد، لایه ورودی نامیده می‌شود. لایه‌های میانی تحت عنوان لایه‌های مخفی و آخرین لایه که جواب‌های خروجی از مدل را فراهم می‌نماید، لایه خروجی نام دارد. ازجمله مشهورترین توابع مورداستفاده برای آستانه گذاری در شبکه‌های عصبی مصنوعی می‌توان به توابعی نظیر سیگموئید، آرکتانژانت و آرکسینوس اشاره کرد (ساجی‌کوما و زانداویسوارا[1]، ۱۹۹۹). به‌صورت کلی، شبکه با استفاده از قواعد و داده‌ها، آموزش داده و با استفاده از قابلیت یادگیری شبکه، الگوریتم‌های متنوعی پیشنهاد می‌گردد که همگی سعی در نزدیک کردن خروجی تولیدشده توسط شبکه به خروجی ایده‌آل و مورد انتظار را دارند (ویسولوسکی و سوچیز[2]، ۲۰۱۲).

در این تحقیق از انواع مدل‌های شبکه‌های عصبی استفاده‌شده و مدلی که حداقل میانگین مجذور خطا را داشته باشد به‌عنوان مدل بهینه برای تعیین عوامل ناکارایی معرفی خواهد شد. در طراحی شبکه بایستی موارد زیر مدنظر قرار گیرد:

[1] Sajikumar and Thandaveswara

[2] Wesolowski and Suchacz

تعداد لایه‌های پنهان: تعداد لایه‌های پنهان تا حد امکان باید کم باشد. ثابت‌شده است که هر تابع می‌تواند حداکثر با سه لایه پنهان تقریب زده شود. ابتدا شبکه با یک‌لایه پنهان آموزش داده می‌شود که در صورت عملکرد نامناسب، تعداد لایه‌های پنهان افزایش خواهد یافت.

تعداد نرون‌های لایه پنهان: اندازه یک‌لایه‌ی مخفی عموما به‌طور تجربی به دست می‌آید. برای یك شبکه عصبی با اندازه معقول تعداد نرون‌های مخفی با یك نسبت بالنسبه کوچکی از تعداد ورودی‌ها انتخاب می‌گردد. اگر شبکه به جواب مطلوب همگرا نگردد، تعداد نرون‌های لایه مخفی را افزایش می‌دهند و اگر شبکه همگرا گردید و از قدرت تعمیم خوبی هم برخوردار بود در صورت امکان تعداد نرون‌های مخفی کمتری را مورد آزمایش قرار می‌دهند (منهاج، ۲۰۰۵).

توابع محرك: نرون‌ها می‌توانند از توابع محرك متفاوتی جهت تولید خروجی استفاده کنند که از رایج‌ترین آن‌ها می‌توان به توابع لگاریتم سیگموئیدی، تانژانت سیگموئیدی و تابع محرك خطی اشاره کرد (فقیه[1]، ۲۰۱۰).

روش‌های آموزش در شبکه‌های پرسپترون چندلایه: جهت آموزش شبکه‌های عصبی چهار الگوریتم آموزشی مرسوم که بر اساس ساختار معروف پرسپترون چندلایه می‌باشند وجود دارد. این روش‌ها عبارت‌اند از: پس انتشار خطا[2] بیشترین شیب، گرادیان مزدوج[3]، شبه نیوتن[4] و مارکوارت- لونبرگ[5] که در بین چهار الگوریتم آموزشی الگوریتم مارکوارت- لونبرگ از سال ۱۹۹۳ تا به امروز به‌عنوان سریع‌ترین روش آموزش شبکه‌های عصبی شناخته‌شده است (صابونیان و بهنژاد[6]، ۲۰۱۸). در این پژوهش از این الگوریتم‌ها استفاده خواهد شد.

تعداد تکرار یا سیکل: زمانی که پارامترهای شبکه پس از یك دوره کامل ارایه الگوها به دست آمدند در اصطلاح به این نوع تکرار، اپوچ[7] یا یك سیکل می‌گویند تعداد تکرارهای شبکه برابر تعداد داده‌های یادگیری هست (منهاج، ۲۰۰۵) که در این بررسی برای هر شبکه ۱۰۰۰ دور در نظر گرفته‌شده است.

ارزیابی مدل‌های شبکه عصبی: به‌منظور مقایسه عملکرد الگوریتم‌های شبکه عصبی از دو روش رایج استفاده می‌شود. روش اول مبتنی بر بررسی ضریب تبیین هست که رابطه زیر شیوه محاسبه آن را نشان می‌دهد (کاتسوفی و همکاران[8]، ۲۰۱۷):

$$R^2=1-\left[\frac{\sum_{i=1}^{N}\left(P_{ANN,i}-P_{exp,i}\right)^2}{\sum_{i=1}^{N}\left(\bar{P}_{ANN,i}-P_{ANN,i}\right)^2}\right]. \qquad (۷)$$

P_{ANN} مقدار پیش‌بینی برای پارامترهای خروجی از شبکه، P_{exp} مقادیر داده‌های تجربی حاصل از آزمایش است. روش دوم بررسی میانگین مجذور خطا است که دقت و اعتبار دسته‌های آموزشی و آزمونی را اندازه‌گیری می‌نماید و از طریق رابطه زیر محاسبه می‌شود:

$$MSE=\frac{\sum_{i=1}^{N}\left(P_{ANN,t}-P_{exp,t}\right)^2}{N}. \qquad (۸)$$

همچنین برای ارزیابی مدل‌های شبکه‌های عصبی از مدل‌های ضریب همبستگی[9] (R) و میانگین خطای مطلق[10] و به‌عنوان یک معیار کمی برای سنجش دقت مدل‌های شبکه‌های عصبی استفاده می‌شود (فقیه، ۲۰۱۰).

در ادامه پس ارزیابی مدل‌ها و انتخاب بهترین مدل شبکه عصبی، برای رتبه‌بندی عوامل ناکارایی از تحلیل حساسیت استفاده شد. درواقع با تحلیل حساسیت بر روی شبکه عصبی بهینه با کمترین میانگین مجذور خطا یک نمره برای هر متغیر ورودی در شبکه عصبی به‌دست‌آمده که با استفاده از آن به رتبه‌بندی عوامل ناکارایی می پرداریم.

[1] Faghih
[2] Back propagation
[3] Conjugate gradient
[4] Quasi-Newton
[5] Levenberg-Marquardt
[6] Sabonian and Behnajady
[7] Epoch
[8] Katsoufi et al.
[9] Correlation coefficients
[10] Mean Absoulate Error (MAE)

پناهنده خوجین و همکاران / تصمیم‌گیری و تحقیق در عملیات، دوره ۷، شماره ۴، زمستان ۱۴۰۱، صفحه: ۶۲۷-۶۱۰

۳- یافته‌های پژوهش

در این تحقیق کار در دو مرحله انجام می‌شود. در مرحله اول از مدل‌های موجود در تحلیل پوششی داده‌ها استفاده می‌کنیم و به ارزیابی کارایی واحدهای تصمیم‌گیرنده در جامعه آماری تحقیق می‌پردازیم. در مرحله بعد با استفاده از خروجی مرحله اول که همان نمره کارایی واحدهای تصمیم‌گیرنده ناکارا هست و روش‌های موجود در شبکه عصبی به همراه آنتروپی شانون و با کمک آنالیز حساسیت، به تعیین و رتبه‌بندی عوامل ناکارایی در جامعه آماری موردمطالعه می‌پردازیم.

۳-۱- ارزیابی کارایی با استفاده از مدل‌های تحلیل پوششی داده‌ها

در این مرحله به ارزیابی کارایی واحدهای تصمیم‌گیرنده در جامعه آماری موردمطالعه می‌پردازیم.

۳-۱-۱- معرفی واحدهای تصمیم‌گیرنده

واحدهای تصمیم‌گیرنده در این تحقیق شامل ۳۲ واحد مدیریت به ازای هر استان یک مدیریت و تهران بزرگ دو مدیریت شرق و غرب در نظر گرفته شد. محدوده زمانی در نظر گرفته‌شده برای پژوهش حاضر، اطلاعات صورت‌های مالی حسابرسی شده در سال ۱۳۹۶ هست. اسامی مدیریت شعب استان‌ها در **جدول ۱** آورده شده است.

جدول ۱- اسامی مدیریت شعب بانک موردمطالعه به‌عنوان واحدهای تصمیم‌گیرنده.

Table 1- The names of the branches of the bank under study as decision-making units.

ردیف	مدیریت	ردیف	مدیریت	ردیف	مدیریت	ردیف	مدیریت
1	تهران شرق	9	کرمان	17	زنجان	25	سمنان
2	خراسان رضوی	10	اصفهان	18	همدان	26	اردبیل
3	آذربایجان شرقی	11	کردستان	19	یزد	27	قم
4	آذربایجان غربی	12	کرمانشاه	20	مرکزی	28	گلستان
5	فارس	13	گیلان	21	البرز	29	خراسان جنوبی
6	خوزستان	14	هرمزگان	22	لرستان	30	تهران غرب
7	مازندران	15	کهکیلویه و بویر احمد	23	بوشهر	31	قزوین
8	سیستان و بلوچستان	16	چهارمحال و بختیاری	24	ایلام	32	خراسان شمالی

۳-۱-۲- متغیرهای ورودی و خروجی

در این تحقیق با توجه به اینکه از مدل‌های تحلیل پوششی داده‌ها به‌منظور ارزیابی کارایی واحدهای تصمیم‌گیرنده استفاده می‌شود؛ نیاز به انتخاب معیارهای مناسبی است که در مدل قرار گیرند تا سنجش دقیقی از کارایی واحدها انجام شود. برای این کار مطالعات فراوانی صورت گرفته و درنهایت با توجه به مطالعات مقالات و پایان‌نامه‌ها و همچنین پژوهش‌های گذشته و مطالعات میدانی و کسب نظر از خبرگان این صنعت، سوابق چندین ساله محقق در صنعت مالی و بانکی کشور نهایتا تعداد ۱۰ متغیر به‌عنوان شاخص‌های عملکردی بانک برای سنجش کارایی واحدهای تصمیم‌گیرنده انتخاب شد. همچنین نیاز است معیارهای موردنظر به دو گروه متغیرهای ورودی و خروجی تقسیم شوند. این متغیرها به شرح ورودی و خروجی در **جدول ۲** آورده شده است.

جدول ۲- شاخص‌های ورودی و خروجی برای ارزیابی کارایی واحدهای تصمیم‌گیرنده.

Table 2- Input and output indicators to evaluate the efficiency of decision-making units.

ورودی ۱	ورودی ۲	ورودی ۳	ورودی ۴	ورودی ۵	خروجی ۱	خروجی ۲	خروجی ۳	خروجی ۴	خروجی ۵
تعداد نیروی انسانی	تعداد شعبه	هزینه عملیاتی	هزینه غیرعملیاتی	سهم نقدینگی	درآمد مشاع	درآمد غیر مشاع	منابع جذب‌شده	تسهیلات پرداختی	مطالبات معوق

تعریف و نحوه اندازه‌گیری متغیرهای **جدول ۲** به شرح زیر می‌باشند:

۱. تعداد نیروی انسانی: تعداد افرادی که به‌صورت تمام‌وقت در بخش‌های متفاوت بانک (به‌عنوان واحد تصمیم‌گیرنده) مشغول به کار هستند.
۲. تعداد شعب: شعب زیرمجموعه هر مدیریت استان که دارای کد فعالیت از بانک مرکزی هست.
۳. هزینه عملیاتی: کلیه هزینه‌های مستقیم پرداختی از بابت تجهیز پول، مثل هزینه سود پرداختی.
٤. هزینه‌های غیرعملیاتی: کلیه هزینه‌های غیرمستقیم تجهیز پول مانند هزینه اجاره، حقوق و ... .
٥. سهم نقدینگی: حجم کل نقدینگی موجود در حوزه فعالیت هر واحد تصمیم‌گیرنده.
٦. درآمد مشاع: کلیه درآمدهای حاصل از پرداخت تسهیلات عقود اسلامی.
۷. درآمد غیر مشاع: شامل کلیه درآمدهای کارمزدی از قبیل بانکداری الکترونیک، ضمانت‌نامه و ... .
۸. منابع جذب‌شده: کلیه سپرده‌های دیداری و غیر دیداری مردم نزد بانک.
۹. تسهیلات پرداختی: منابع تخصیص‌یافته به مشتریان در قالب عقود اسلامی.
۱۰. مطالبات معوق: کلیه مطالباتی که سررسید وصول آن‌ها گذشته باشد.

۳-۱-۳- گردآوری اطلاعات

به‌منظور گردآوری اطلاعات درباره متغیرهای ورودی و خروجی، از مستندات صورت‌های مالی و گزارش‌های مالی سال ۱۳۹٦ در بانک موردمطالعه استفاده شد، همچنین برای جمع‌آوری اطلاعات تکمیلی در ارتباط با برخی از معیارها به بانک‌های اطلاعاتی هریک از مدیریت شعب استان‌ها مراجعه گردید. در ادامه اطلاعات ورودی‌ها و خروجی‌های به‌دست‌آمده از صورت‌های مالی و کارگزینی، جمع‌آوری گردید. آمار توصیفی مربوط به ورودی‌ها و خروجی‌های تحقیق در **جدول ۳** آورده شده است.

جدول ۳- آمار توصیفی ورودی و خروجی‌ها مربوط به واحدهای تصمیم‌گیرنده.
Table 3- Descriptive statistics of inputs and outputs related to decision-making units.

شاخص آماری	تعداد نیروی انسانی	تعداد شعبه	هزینه عملیاتی	هزینه غیرعملیاتی	سهم نقدینگی
میانگین	189	22	0.18399	154,635,657,256	802,277,406
انحراف معیار	94.48119	12.2337	0.006485	87,884,230,347	2,180,654,087
شاخص آماری	درآمد مشاع	درآمد غیر مشاع	منابع	مصارف	مطالبات معوق
میانگین	203,588,853,298	37,810,912,289	26,139,224	1,855,997	37,941
انحراف معیار	114521312737.01	31195251172	28282814.5	1186086	38,421.858

٤-۱-۳- تشریح مدل جهت سنجش کارایی واحدها

هدف از این زیر بخش استفاده از مدل‌های تحلیل پوششی داده‌ها به‌منظور ارزیابی کارایی واحدهای تصمیم‌گیرنده است. مدل‌های مورداستفاده در این تحقیق از نوع خروجی محور و بازده به مقیاس متغیر می‌باشند. این مدل‌ها باهدف حداکثر کردن خروجی و ثابت در نظر گرفتن ورودی‌ها مدل‌سازی شده‌اند. در مدل‌های تحلیل پوششی داده‌ها اگر تعداد واحدهای تصمیم‌گیرنده در مقایسه با مجموع تعداد ورودی‌ها و خروجی‌ها اختلاف چندانی نداشته باشد، پس از حل مسئله خواهیم دید که اکثر واحدها کارا خواهند بود؛ لذا برای تفکیک دقیق واحدهای تصمیم‌گیرنده در این تحقیق، مدلی استفاده می‌شود که مشکل مذکور را حل نموده و قدرت تفکیک‌پذیری واحدهای کارا از ناکارا را بالا ببرد. بدین منظور در این تحقیق از مدل برنامه‌ریزی آرمانی اصلاح‌شده تحلیل پوششی داده‌ها در **مدل (٦)** استفاده می‌نمایم. در این تحقیق بعد از نرمال‌سازی داده‌ها، با در نظر گرفتن ۵ شاخص ورودی و ۵ شاخص خروجی و ۳۲ واحد تصمیم‌گیرنده که شامل ۳۰ مدیریت شعب در استان‌ها و تهران بزرگ شامل ۲ مدیریت شعب غرب و شرق هر یک به‌عنوان واحدهای تصمیم‌گیرنده مستقل، مدل برنامه‌ریزی خطی ساخته و کارایی واحدهای تصمیم‌گیرنده ابتدا با مدل *BCC* خروجی محور تحلیل پوششی داده‌ها، با استفاده از نرم‌افزار *LINGO* مورد ارزیابی قرار گرفت. در اینجا به‌منظور تفکیک‌پذیری واحدهای تصمیم‌گیرنده کارا از ناکارا از مدل دانشور و همکاران (۲۰۱۵) یعنی *MODIFI GPDEA-BCC* معرفی‌شده در بخش قبل، استفاده می‌نمایم. همچنین برای رتبه‌بندی واحدهای کارا از روش اندرسون – پیترسون[1] (*AP*) استفاده می‌گردد. نتایج خروجی مدل برنامه‌ریزی آرمانی تحلیل پوششی داده‌ها (*GPDEA-BCC*)، مدل برنامه‌ریزی آرمانی

[1] Andeson-Peterson

اصلاح‌شده تحلیل پوششی داده‌ها (*MODIFI GPDEA-BCC*) و همچنین رتبه‌بندی واحدهای تصمیم‌گیرنده کارا برمبنای مدل اندرسون-پیترسون بر اساس خروجی مدل برنامه‌ریزی آرمانی اصلاح‌شده تحلیل پوششی داده‌ها (*MODIFI GPDEA-BCC-AP*) در **جدول ٤** آورده شده است.

جدول ۴- مقادیر کارایی با استفاده از مدل‌های مختلف DEA.

Table 4- Performance values using different DEA models.

ردیف	نام استان	مدل BCC	GPDEA- BCC	MODIFI GPDEA-BCC	MODIFI GPDEA-BCC-AP
1	خراسان جنوبی	1	1	1	2.976017
2	ایلام	1	1	1	2.222222
3	خراسان شمالی	1	1	1	1.698272
4	اصفهان	1	0.2288101	0.9701786	0.9701786
5	اردبیل	1	1	0.8012619	0.8012619
6	سمنان	1	1	0.7873547	0.7873547
7	کهکیلویه و بویر احمد	1	1	0.7759720	0.7759720
8	کردستان	1	1	0.7259961	0.7259961
9	قزوین	1	1	0.7162321	0.7162321
10	زنجان	1	1	0.6083473	0.6083473
11	چهارمحال و بختیاری	1	1	0.5916076	0.5916076
12	گلستان	1	1	0.5857645	0.5857645
13	تهران غرب	1	0.1319416	0.5638531	0.5638531
14	یزد	1	1	0.5533701	0.5533701
15	هرمزگان	1	1	0.5302572	0.5302572
16	تهران شرق	1	0.1230710	0.5032886	0.5032886
17	سیستان و بلوچستان	1	1	0.4632330	0.4632330
18	لرستان	1	1	0.4602528	0.4602528
19	بوشهر	1	1	0.4588970	0.4588970
20	قم	1	0.8607619	0.3614696	0.3614696
21	مرکزی	1	0.9083810	0.3538591	0.3538591
22	همدان	1	0.8293913	0.3391727	0.3391727
23	کرمان	1	0.7630400	0.2989608	0.2989608
24	آذربایجان غربی	1	0.7336923	0.2903150	0.2903150
25	کرمانشاه	1	0.6577931	0.2618009	0.2618009
26	گیلان	1	0.5830968	0.2367744	0.2367744
27	مازندران	1	0.5961250	0.2337919	0.2337919
28	البرز	1	0.4769000	0.1933744	0.1933744
29	خراسان رضوی	1	0.4239111	0.1599356	0.1599356
30	فارس	1	0.3171228	0.1322882	0.1322882
31	خوزستان	1	0.3116552	0.1315243	0.1315243
32	آذربایجان شرقی	1	0.2963279	0.1255047	0.1255047

پس از رتبه‌بندی واحدهای تصمیم‌گیرنده مطابق مدل *MODIFI GPDEA-BCC-AP* مشخص گردید که از بین ۳۲ واحد تصمیم‌گیرنده، مدیریت شعب استان خراسان جنوبی، ایلام، خراسان شمالی، اصفهان و اردبیل به ترتیب بیشترین کارایی (۲٫۹۷ و ۲٫۲۲ و ۱٫۶۹ و ۰٫۹۷ و ۰٫۸) را از میان واحدهای تصمیم‌گیرنده داشته و همچنین مدیریت شعب البرز، خراسان رضوی، فارس، خوزستان و آذربایجان شرقی به ترتیب کمترین کارایی (۰٫۱۹۳ و ۰٫۱۵۹ و ۰٫۱۳۲ و ۰٫۱۳۱ و ۰٫۱۲۵) را در بین سایر مدیریت‌های شعب بانک دارند.

با در نظر گرفتن خروجی مدل *BCC* کلاسیک که در آن کلیه واحدهای تصمیم‌گیرنده کارا شده بودند ($DMU_S = 1$) و در مدل برنامه‌ریزی آرمانی تحلیل پوششی داده‌ها تعداد ۱٦ واحد از ۳۲ واحد تصمیم‌گیرنده ناکارا و الباقی کارا و همچنین در مدل برنامه‌ریزی

آرمانی اصلاح‌شده تحلیل پوششی داده‌ها ۳ واحد از ۳۲ واحد تصمیم‌گیرنده کارا و واحد ناکارا شده بودند؛ بنابراین مشخص گردید که قدرت تفکیک‌پذیری واحدهای تصمیم‌گیرنده کارا از ناکارا توسط مدل *MODIFI GPDEA-BCC* بیشتر هست.

با مقایسه نمره ارزیابی کارایی به‌دست‌آمده با استفاده از روش‌های *GPDEA-BCC* و *MODIFI GPDEA-BCC* یک تفاوت معناداری بین نمره کارایی برای این دو روش وجود دارد و پراکندگی درروش اول بیشتر هست. دلیلی که در اینجا برای این تفاوت می‌توان اشاره نمود این است که روش *MODIFI GPDEA-BCC* از یک رویکرد محدودیت وزنی استفاده می‌کند و وزن‌های غیرمعمول که باعث پراکندگی نمره کارایی می‌شوند را حذف می‌نماید. این عمل (محدودیت وزنی) باعث می‌شود روش *MODIFI GPDEA-BCC* نمره کارایی منطقی‌تری برای ارزیابی کارایی مدیریت‌ها ارایه نماید که این موضوع همچنین به‌وسیله مدیران ارشد بانک نیز تایید گردید.

در ادامه برای بررسی عوامل ناکارایی واحدهای تصمیم‌گیرنده در بانک از مدل *MODIFI GPDEA-BCC* استفاده شد. روش کار بدین‌صورت هست که ابتدا مدیریت شعب ناکارا بر مبنای مدل *MODIFI GPDEA-BCC* مشخص گردید، با توجه به اینکه هر یک از مدیریت شعب استان‌ها تعدادی از شعب را در آن استان تحت مدیریت خود دارند، لذا در گام بعدی کارایی شعب زیرمجموعه هر یک از مدیریت‌های ناکارا با مدل *MODIFI GPDEA-BCC* موردبررسی قرار گرفت که شامل ۶۸۰ شعبه می‌باشد.

با توجه به نتایج به‌دست‌آمده، از ۶۸۰ شعبه موردبررسی ۷۰ شعبه کارا و ۶۱۰ شعب ناکارا می‌باشند که متغیرهای ورودی و خروجی شعب ناکارا به‌عنوان ماتریس ورودی برای شبکه عصبی مصنوعی و مقادیر کارایی هریک از شعب ناکارا به‌عنوان ماتریس خروجی شبکه عصبی مصنوعی در نظر گرفته شد. در ادامه توسط مدل‌های شبکه عصبی علل ناکارایی این شعب با توجه به متغیرهای موردبررسی شناسایی شدند که جز مرحله دوم تحقیق می‌باشد.

۲-۳- استفاده از مدل‌های شبکه عصبی به‌منظور رتبه‌بندی عوامل ناکارایی در بانک

بعد از ارزیابی کارایی و مشخص شدن شعب ناکارا با استفاده از داده‌های این شعب و خروجی مدل ارزیابی کارایی، ماتریس ورودی و خروجی شبکه عصبی تشکیل خواهد شد. شاخص‌های ورودی ماتریس شبکه عصبی به‌عنوان ۱۰ نرون لایه ورودی شبکه در نظر گرفته می شوند که عبارت‌اند از:

۱. تعداد شعب،
۲. توزیع نیروی انسانی،
۳. هزینه‌های عملیاتی،
۴. هزینه‌های غیرعملیاتی،
۵. سهم نقدینگی استان‌ها،
۶. منابع،
۷. مصارف،
۸. درآمد مشاع،
۹. درآمد غیر مشاع،
۱۰. مطالبات معوق.

نرون خروجی را کارایی هر یک از شعب تشکیل می‌دهد. ماتریس ورودی در ابعاد ۶۱۰*۱۰ و ماتریس خروجی در ابعاد ۶۱۰*۱ می‌باشد. برای تصمیم‌گیری در مورد زمان متوقف ساختن آموزش، داده‌ها به‌صورت تصادفی به سه مجموعه تقسیم شد، ۷۰% داده‌های موردنظر برای آموزش شبکه، ۱۵% برای صحت سنجی شبکه و ۱۵% بقیه نیز برای آزمایش شبکه تخصیص داده شد. در این قسمت داده‌های نرمال‌سازی شده ناشی از عملکرد شعب و خروجی مدل برنامه‌ریزی آرمانی اصلاح‌شده تحلیل پوششی داده‌ها توسط شبکه‌های عصبی

پناهنده خوجین و همکاران / تصمیم‌گیری و تحقیق در عملیات، دوره ۷، شماره ۴، زمستان ۱۴۰۱، صفحه: ۶۲۷-۶۱۰

مصنوعی پرسپترون چندلایه[1]، توابع شعاعی پایه[2]، نگاشت خود سازمانده[3] و بردار ماشین پشتیبان[4] با نرم‌افزار *Neuro Solutions* و با الگوریتم‌های آموزشی ممنتم[5]، گرادیان نزولی و لونبرگ-مارکوارت با تابع انتقال سیگموئید[6] و هایپربولیک[7] با یک‌لایه مخفی و با نرون‌های متفاوت آموزش و آزمایش شد و پس از اعمال الگوهای مختلف و آموزش شبکه بهترین الگو از میان الگوها انتخاب گردید. معیار انتخاب، شبکه‌ای است که بهترین آموزش را دیده، کمترین میانگین مجذور خطا[8] را داشته و نتایج قابل قبولی ارایه داده باشد. البته در انتخاب شبکه باید به وقوع پدیده بیش پردازش نیز دقت داشته باشیم زیرا در آزمون‌هایی که میانگین مجذور خطا به مقدار زیادی به صفر نزدیک شود، شبکه تعمیم دهی قابل قبولی نخواهد داشت. در ابتدا ماتریس داده‌ها، توسط شبکه عصبی پرسپترون چندلایه (*MLP*) با مقدار *epochs =1000*، با توابع انتقال تانژانت هایپربولیک و سیگموئید و با قانون آموزشی ممنتم که برای تعیین مناسب‌ترین مقدار ممنتم مدل‌های مختلف شبکه عصبی، که در آن‌ها مقدار ممنتم (۰/۱ و ۰/۲ و ۰/۳ و ۰/٤ و ۰/٥ و ۰/٦ و ۰/۷ و ۰/۸ و ۰/۹) در نظر گرفته‌شده و همچنین با گرادیان نزولی و لونبرگ-مارکوارت مورد آموزش و آزمایش قرار گرفت که نتایج این تحلیل در ادامه آورده شده است. ابتدا به انتخاب بهترین ساختار در پرسپترون چندلایه می‌پردازیم که مقادیر به‌دست‌آمده برای آن در **جدول ۵** آورده شده است.

جدول ۵- آزمون سعی و خطا برای انتخاب بهترین ساختار برای پرسپترون چندلایه (MLP).

Table 5- Trial and error test for selecting the best structure for multilayer perceptron (MLP).

ساختار	نوع شبکه	تابع انتقال	قانون آموزش	قانون ممنتم	MSE	سطح اطمینان	MAE	R
R1	MLP	TAN	ممنتم	0/1	0/05898064	0/94101936	0/21611646	0/02770837
R2		TAN		0/2	0/05339212	0/94660788	0/20369696	0/19266709
R3		TAN		0/3	0/05864217	0/94135783	0/21089419	0/07013188
R4		TAN		0/4	0/05864778	0/94135222	0/2134036	0/04783467
R5		TAN		0/5	0/05653542	0/94346458	0/20888978	0/05557381
R6		TAN		0/6	0/05975778	0/94024222	0/21723459	0/0412824
R7		TAN		0/7	0/05509063	0/94490937	0/20519971	0/10768065
R8		TAN		0/8	0/0540692	0/9459308	0/20579165	0/19603594
R9		TAN		0/9	0/05436917	0/94563083	0/20635183	0/18307582
R10		TAN	گرادیان نزولی		0/05426152	0/94573848	0/19898907	0/05865082
R11		TAN	لونبرگ و مارکوارت		0/05983225	0/94016775	0/21588254	0/21769425
R12		SIG	ممنتم	0/1	0/10763498	0/89236502	0/29621821	0/24621184
R13		SIG		0/2	0/10521763	0/89478237	0/29291932	0/23773248
R14		SIG		0/3	0/06908685	0/93091315	0/23443458	0/12560953
R15		SIG		0/4	0/05671338	0/94328662	0/21195275	0/28790024
R16		SIG		0/5	0/05529169	0/94470831	0/20862339	0/28568791
R17		SIG		0/6	0/05556568	0/94443432	0/20953205	0/30927478
R18		SIG		0/7	0/05252572	0/94747428	0/20220129	0/30936113
R19		SIG		0/8	0/05013746	0/94986254	0/19551225	0/31657281
R20		SIG		0/9	0/0512896	0/9487104	0/19799749	0/28144703
R21		SIG	گرادیان نزولی		0/05554756	0/94445244	0/20694829	0/11225767
R22		SIG	لونبرگ و مارکوارت		0/05579077	0/94420923	0/20716094	0/12361321

[1] Multi Layer Perseptron (MLF)
[2] Redial Basic Function (RBF)
[3] Self-Organized Mapping (SOM)
[4] Support Vectore Machine (SVM)
[5] Momentum
[6] Sigmoid
[7] Hyperbolic
[8] Mean Square Error (MSE)

بهترین ساختار برای شبکه عصبی زمانی است که میانگین مجذور خطا یعنی *MSE* آن کمترین مقدار یا سطح اطمینان آن بالاترین مقدار باشد که با توجه به **جدول ۵** این ساختار مربوط *R19* با تابع انتقال سیگموید با قانون آموزش ممنتم ۰/۸ و با مقدار *MSE=0.05013746* و با سطح اطمینان ۰/۹۴۹ و همچنین با ضریب همبستگی *R=0.316* و میانگین قدر مطلق خطا *MAE=0.195* است. در ادامه از شبکه عصبی تابع شعاعی پایه (*RBF*) با مقدار *epochs =1000*، با توابع انتقال تانژانت هایپربولیک و سیگموئید و با قانون آموزشی ممنتم (۰/۱ و ۰/۲ و ۰/۳ و ۰/٤ و ۰/٥ و ۰/٦ و ۰/۷ و ۰/۸ و ۰/۹)، گرادیان نزولی و لونبرگ-مارکوارت مورد آموزش و آزمایش قرار گرفت که مقادیر به‌دست‌آمده برای آن در **جدول ٦** آورده شده است.

جدول ۶- آزمون سعی و خطا برای انتخاب بهترین ساختار برای تابع شعاعی پایه (RBF).

Table 6- Trial and error test for selecting the best structure for the base radial function (RBF).

ساختار	نوع شبکه	تابع انتقال	قانون آموزش	قانون ممنتم	MSE	سطح اطمینان	MAE	R
R1		TAN		0/1	0/05103992	0/94896008	0/19289423	0/65621849
R2		TAN		0/2	0/04975929	0/95024071	0/19051806	0/67164915
R3		TAN		0/3	0/05114501	0/94885499	0/19158282	0/69399163
R4		TAN		0/4	0/05282657	0/94717343	0/1959904	0/64781587
R5		TAN		0/5	0/04981975	0/95018025	0/18503894	0/59040339
R6		TAN	ممنتم	0/6	0/04988413	0/95011587	0/19205285	0/63152129
R7		TAN		0/7	0/04606461	0/95393539	0/17350181	0/60315292
R8		TAN		0/8	0/05173994	0/94826006	0/19306389	0/65944432
R9		TAN		0/9	0/04822755	0/95177245	0/18488749	0/6918987
R10	RBF	TAN	گرادیان نزولی		0/04932989	0/95067011	0/19146322	0/2854172
R11		TAN	لونبرگ و مارکوارت		0/06198176	0/93801824	0/22275523	-0/02269674
R12		SIG		0/1	0/07210863	0/92789137	0/23646793	-0/36268997
R13		SIG		0/2	0/07239408	0/92760592	0/23714014	-0/58032805
R14		SIG		0/3	0/07121503	0/92878497	0/23486944	0/61744596
R15		SIG		0/4	0/07178101	0/92821899	0/23572593	0/4294937
R16		SIG		0/5	0/07221882	0/92778118	0/23649635	-0/27755122
R17		SIG		0/6	0/07245275	0/92754725	0/23736815	-0/49057708
R18		SIG		0/7	0/07140352	0/92859648	0/23507144	0/71502792
R19		SIG		0/8	0/07166192	0/92833808	0/23578396	-0/23498109
R20		SIG		0/9	0/07542666	0/92457334	0/23663064	0/30010793
R21		SIG	گرادیان نزولی		0/0565357	0/9434643	0/20471809	0/12964692
R22		SIG	لونبرگ و مارکوارت		0/05883791	0/94116209	0/2107312	0/12324689

با توجه به **جدول ٦** با بهترین ساختار برای تابع شعاعی پایه مربوط به *R7* با تابع انتقال تانژانت هایپربولیک با آموزش ممنتم ۰/۷ هست که در آن میانگین مجذور خطا برابر *MSE=0/04606461* و سطح اطمینان ۰/۹۵۳ و همچنین با ضریب همبستگی *R= 0.603* و میانگین قدر مطلق خطا *MAE=0.173* می‌باشد. تحلیل مشابهی برای شبکه عصبی نگاشت خود سازمانده (*SOM*) با مقدار *epochs =1000* و با توابع انتقال تانژانت هایپربولیک و سیگموئید و با قانون آموزشی ممنتم (۰/۱ و ۰/۲ و ۰/۳ و ۰/٤ و ۰/٥ و ۰/٦ و ۰/۷ و ۰/۸ و ۰/۹)، گرادیان نزولی و لونبرگ- مارکوارت مورد آموزش و آزمایش قرار گرفت که نتایج آن در **جدول ۷** آورده شده است.

پناهنده خوجین و همکاران / تصمیم‌گیری و تحقیق در عملیات، دوره ۷، شماره ۴، زمستان ۱۴۰۱، صفحه: ۶۲۷-۶۱۰

جدول ۷- آزمون سعی و خطا برای انتخاب بهترین ساختار برای نگاشت خودسازمان‌ده (SOM).

Table 7- Trial and error test for selecting the best structure for self-organized mapping (SOM).

ساختار	نوع شبکه	تابع انتقال	قانون آموزش	قانون ممنتم	MSE	سطح اطمینان	MAE	R
R1		TAN	ممنتم	0/1	0/04988499	0/95011501	0/19153563	0/66872289
R2		TAN		0/2	0/0541135	0/9458865	0/19739561	0/53327399
R3		TAN		0/3	0/05701132	0/94298868	0/20736864	0/61377133
R4		TAN		0/4	0/05716537	0/94283463	0/20604346	0/53597891
R5		TAN		0/5	0/04632877	0/95367123	0/18352027	0/65956974
R6		TAN		0/6	0/04966516	0/95033484	0/18730967	0/6150144
R7		TAN		0/7	0/05820201	0/94179799	0/20779785	0/49991821
R8		TAN		0/8	0/05990614	0/94009386	0/21190861	0/44872713
R9		TAN		0/9	0/042174	0/957825	0/171199	0/6545324
R10		TAN	گرادیان نزولی		0/06648157	0/93351843	0/22579415	-0/12361582
R11	SOM	TAN	لونبرگ و مارکوارت		0/07668474	0/92331526	0/24998578	-0/01442779
R12		SIG		0/1	0/06969521	0/93030479	0/23166388	0/53769977
R13		SIG		0/2	0/05913526	0/94086474	0/21174512	0/69502742
R14		SIG		0/3	0/05471101	0/94528899	0/20184134	0/68655737
R15		SIG		0/4	0/05215286	0/94784714	0/19586524	0/68384872
R16		SIG		0/5	0/05595112	0/94404888	0/20422138	0/68292028
R17		SIG		0/6	0/05113751	0/94886249	0/1940422	0/68982057
R18		SIG		0/7	0/05079663	0/94920337	0/19347536	0/69065406
R19		SIG		0/8	0/05139115	0/94860885	0/19468756	0/6798062
R20		SIG		0/9	0/05205918	0/94794082	0/19717829	0/65634878
R21		SIG	گرادیان نزولی		0/06421607	0/93578393	0/22387416	-0/26326805
R22		SIG	لونبرگ و مارکوارت		0/05779913	0/94220087	0/21261056	-0/03062235

با توجه به **جدول ۷** بهترین ساختار برای شبکه عصبی نگاشت خودسازمان‌ده (*SOM*) مربوط به ساختار *R*9 هست که در آن تابع انتقال، تانژانت هایپربولیک و قاعده آموزش ممنتم ۰/۹ می‌باشد و همچنین میانگین مجذور خطا برابر *MSE=0/04217463*، سطح اطمینان ۰/۹۵۷، ضریب همبستگی *R= 0.654* و میانگین قدر مطلق خطا *MAE=0.171* می‌باشد. درنهایت برای شبکه عصبی بردار ماشین پشتیبان (*SVM*) با مقدار *epochs =1000* مورد آموزش و آزمایش قرار گرفت که نتایج آن در **جدول ۸** آورده شده است.

جدول ۸- آزمون سعی و خطا برای انتخاب بهترین ساختار برای بردار ماشین پشتیبان (SVM).

Table 8- Trial and error test for selecting the best structure for support machine (SVM) vector.

ساختار	نوع شبکه	MSE	سطح اطمینان	MAE	R
R1	SVM	0/06129273	0/93870727	0/20711299	0/08935262

با توجه به **جدول ۸** برای روش ماشین بردار پشتیبان (*SVM*) مقدار میانگین مجذور خطا برابر *MSE=0.06129273*، سطح اطمینان برابر ۰/۹۳۸، ضریب همبستگی۰/۰۸۹۳ =*R* و میانگین قدر مطلق خطا *MAE=0, 207* می‌باشد. با توجه به نتایج به‌دست‌آمده از انواع شبکه‌ها، بهترین ساختار شبکه به‌عنوان شبکه عصبی بهینه انتخاب می‌شود. این شبکه باید کمترین میانگین مجذور خطا یعنی *MSE* را داشته، یا سطح اطمینان آن بیشترین باشد. با توجه به نتایج این جدول‌ها شبکه عصبی نگاشت خودسازمان‌ده با تابع انتقال تانژانت هیپربولیك و باقاعده آموزشی ممنتم ۰/۹ در تدوین مدل‌ها، عملکرد بهتری نسبت به تابع سیگموئید داشت. شبکه عصبی نگاشت خودسازمان‌ده با تابع انتقال تانژانت هیپربولیک و با مقادیر میانگین مجذور خطا برابر *MSE= 0/04217463*، سطح اطمینان ۰/۹۵۷، ضریب همبستگی *R= 0.654* و میانگین قدر مطلق خطا *MAE=0,171* به‌عنوان بهینه‌ترین شبکه عصبی مصنوعی جهت تعیین و رتبه‌بندی عوامل ناکارایی در بانک موردمطالعه انتخاب می‌شود که در **جدول ۹** ارایه شده است.

جدول ۹- بهینه‌ترین شبکه عصبی مصنوعی جهت تعیین و رتبه‌بندی عوامل ناکارایی با نگاشت خودسازمان‌ده (SOM).

Table 9- The most optimal artificial neural network for determining and ranking dysfunction factors with self-organized mapping (SOM).

ساختار	نوع شبکه	تابع انتقال	قانون آموزش	قانون ممنتم	MSE	سطح اطمینان	MAE	R
R9	SOM	TAN	ممنتم	0/9	0/04217463	0/957825	0/171199	0/6545324

اکنون به‌منظور تعیین و رتبه‌بندی عوامل ناکارایی به تحلیل حساسیت برای شبکه عصبی انتخاب‌شده می‌پردازیم. تحلیل حساسیت، درواقع روشی است که در آن با ایجاد تغییرات در ورودی‌ها میزان تغییر در خروجی‌ها تحلیل می‌شود. تحلیل حساسیت نشان‌دهنده آن است که کدام ورودی بیشترین تاثیر را بر روی خروجی خواهد داشت. در ادامه با این دیدگاه به تحلیل حساسیت برای شبکه عصبی نگاشت خودسازمان‌ده با تابع انتقال تانژانت هیپربولیک و باقاعده آموزش ممنتم ۰/۹ می‌پردازیم. تا بتوانیم با توجه به نتایج آن به رتبه‌بندی عوامل ناکارایی در بانک بپردازیم. نتایج تحلیل حساسیت در **شکل ۲** زیر آورده شده است.

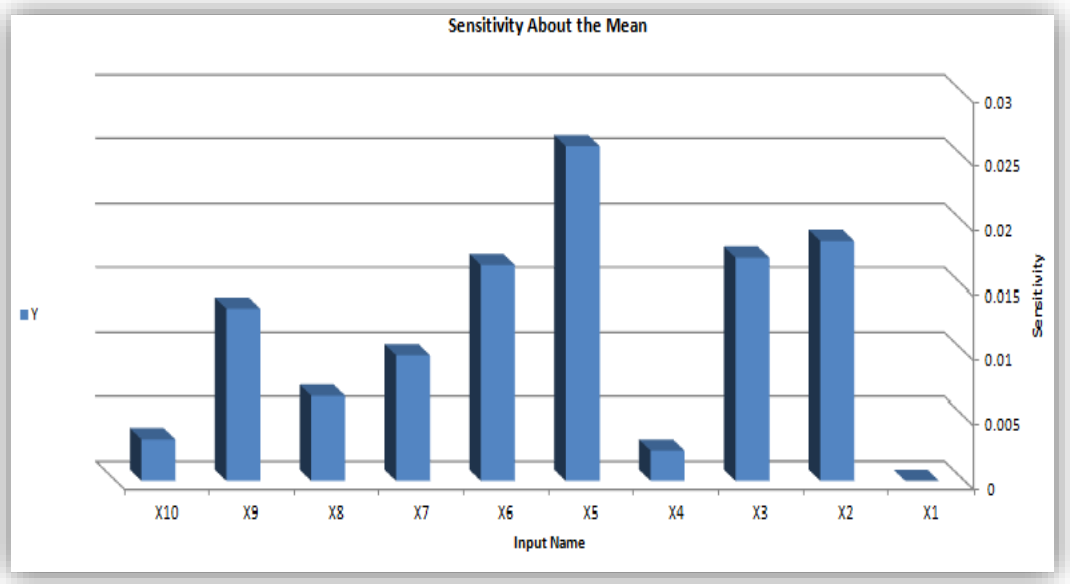

شکل ۲- تحلیل حساسیت شاخص‌های ورودی با استفاده از شبکه عصبی نگاشت خودسازمان‌ده.

Figure 2- Sensitivity analysis of input indicators using self-organized mapping neural network.

علاوه بر این در **جدول ۱۰**، نتایج تحلیل حساسیت به‌منظور رتبه‌بندی عوامل ناکارایی آورده شده است.

جدول ۱۰- نتایج تحلیل حساسیت ورودی‌های شبکه عصبی نگاشت خودسازمان‌ده به‌منظور رتبه‌بندی عوامل ناکارایی در بانک.

Table 10- Results of sensitivity analysis of neural network inputs for self-organized mapping to rank inefficiency factors in the bank.

نام متغیر ورودی	نماد متغیرهای ورودی	مقدار تحلیل حساسیت	رتبه تاثیرگذاری
سهم نقدینگی	X5	0/02592	1
توزیع پرسنل	X2	0/01860	2
هزینه‌های عملیاتی	X3	0/01729	3
درآمد مشاع	X6	0/01672	4
مصارف (تسهیلات)	X9	0/01340	5
درآمد غیر مشاع	X7	0/00975	6
منابع (سپرده‌ها)	X8	0/00658	7
مطالبات معوق	X10	0/00326	8
هزینه‌های غیرعملیاتی	X4	0/00238	9
تعداد شعب	X1	0/00000	10

با توجه به **جدول ۱۰** سهم نقدینگی استان، توزیع پرسنل و هزینه‌های عملیاتی به ترتیب با مقادیر تحلیل حساسیت ۰/۰۲۵۹۲ و ۰/۰۱۸۶ و ۰/۰۱۷۲۹ بیشترین نمره در تحلیل حساسیت را کسب نموده‌اند که با توجه به این نتایج متغیرهای فوق بالاترین تاثیر را در ناکارآمدی

بانک دارند. در مقابل تعداد شعب، هزینه‌های غیرعملیاتی و مطالبات معوق به ترتیب با مقادیر تحلیل حساسیت صفر و ۰/۰۰۲۳۸ و ۰/۰۰۳۲۶ کمترین نمره را در تحلیل حساسیت کسب نموده‌اند که با توجه به این نتایج متغیرهای یادشده کمترین تاثیر را در ناکارآمدی بانک دارند.

۴- بحث و نتیجه‌گیری

مدیران سازمان‌ها و ادارات جهت برنامه‌ریزی و کنترل سازمان خود، نیاز به اندازه‌گیری و ارزیابی عملکرد واحدهای زیرمجموعه سازمان خود دارند تا بتوانند واحدها را مقایسه کرده و از نقاط ضعف و قوت واحدها آگاه شوند و پیشنهادهای لازم را جهت افزایش عملکرد واحدها ارایه دهند. تحلیل پوششی داده‌ها روشی برای مقایسه و ارزیابی کارایی نسبی واحدهای تصمیم‌گیرنده است که هر یک دارای چندین ورودی و خروجی مشابه هستند، مانند مدارس، دانشگاه‌ها، بانک‌ها، بیمارستان‌ها و غیره (کلین، ۲۰۰۱). موضوع این تحقیق ارزیابی کارایی و رتبه‌بندی عوامل ناکارایی در یک بانک تجاری برای سال ۱۳۹۶ هست. ازآن‌جاکه روش‌های موجود ارزیابی و سنجش کارایی واحدها اغلب تجربی و فاقد پشتوانه علمی محکمی بوده و به‌علاوه به دلیل استاندارد نبودن این روش‌ها، نتایج آن‌ها در سازمان‌های مختلف با یکدیگر قابل‌مقایسه نیستند، در این مطالعه برای ارزیابی کارایی بانک‌ها، از روش علمی تحلیل پوششی داده‌ها با شبکه عصبی که از روش‌های متداول ارزیابی کارایی در زمینه‌های مختلف برای واحدهای تولیدی و خدماتی می‌باشد، استفاده‌شده است. مسئله یعنی تفاوت بین وضع موجود و مطلوب؛ به‌عبارت‌دیگر، مسئله یعنی فاصله بین شرایط فعلی و شرایط بهینه. مسئله وقتی حل می‌شود که بتوان وضعیت موجود را به وضعیت مطلوب تبدیل کرد (هامبر[1]، ۱۹۸۰). با توجه به کاربرد وسیع روش‌های تحلیل پوششی داده‌ها و شبکه عصبی در ارزیابی کارایی واحدهای صنعتی و خدماتی، هدف این تحقیق ارایه یک مدل بهینه برای ارزیابی کارایی و رتبه‌بندی عوامل ناکارایی در بانک بود. نتایج تحقیق نشان داد که شبکه عصبی نگاشت خودسازمان‌ده (*SOM*) با تابع انتقال تانژانت هیپربولیک و باقاعده آموزش ممنتم ۰/۹ بهترین عملکرد را نسبت به دیگر روش‌ها دارد. درنهایت با توجه به این روش به رتبه‌بندی عوامل ناکارایی در بانک پرداخته شد. از نتایج به‌دست‌آمده به‌وسیله مدل شبکه عصبی نگاشت خودسازمان‌ده مشخص گردید که شاخص‌های، سهم نقدینگی استان‌ها، توزیع نیروی انسانی و هزینه عملیاتی بالاترین تاثیر را در ناکارآمدی بانک داشتند. با توجه به نتایج به‌دست‌آمده، پیشنهادهای زیر جهت بهبود کارایی ارایه می‌گردد:

از مجموع ۱۰۰% نقدینگی کل کشور بالغ‌بر ۵۵% نقدینگی در استان تهران و الباقی در بقیه استان‌ها توزیع‌شده است. میانگین نقدینگی در مدیریت‌های شعب بانک موردمطالعه بدون لحاظ نمودن مدیریت غرب و شرق تهران ۷% از کل نقدینگی موجود در آن استان‌ها بوده ولی سهم نقدینگی مدیریت غرب و شرق تهران از کل نقدینگی استان تهران ۲/۶% هست که در کل نزدیک به ۵% نقدینگی کل کشور در بانک موردمطالعه متمرکزشده است، لذا عدم توزیع مناسب نقدینگی در کشور و همچنین عدم تناسب کافی بین منابع موجود در استان تهران با شبکه شعب مستقر در آن استان، باعث از دست رفتن سهم بازار و در نتیجه ناکارایی شعب بانک شده است. پیشنهاد می گردد بین حجم نقدینگی استان‌ها و توزیع شبکه شعب تعادل برقرار گردد. با بررسی‌های به‌عمل‌آمده از سوابق نیروی انسانی مشاهده گردید توزیع نیروی انسانی در مدیریت شعب استان‌ها برابر چارت سازمانی نبوده و استانداردهای موجود در زمینه توزیع نیرو و تقسیم‌کار رعایت نگردیده و تعدادی از مدیریت شعب استان‌ها با کمبود نیرو مواجه بوده و تعدادی نیز با انباشت نیرو مواجه هستند که در هر دو حالت مدیریت نیروی انسانی در آن استان دچار چالش و در برخی مواقع باعث غفلت از عملکرد واقعی سازمان شده است. پیشنهاد می گردد نسبت بین صف و ستاد رعایت شده و در توزیع نیروی انسانی از استانداردهای موجود در این حوزه استفاده شود. هزینه‌های عملیاتی بانک سومین عامل ناکارایی در بانک موردمطالعه هست بامطالعه ترکیب منابع مشخص گردید که ۹۸% سپرده‌های بانک به‌صورت گران‌قیمت بوده و بانک از بابت تجهیز منابع هزینه گزافی را پرداخت می‌نماید در مقابل ۲% از منابع بانک به‌صورت ارزان‌قیمت و در قالب سپرده‌های جاری و پس‌انداز قرض‌الحسنه هست. پیشنهاد می‌گردد بخش بازاریابی بانک با طراحی محصولات اعتباری نسبت به کاهش بهای تمام‌شده پول اقدام نماید.

[1] Huber

منابع

Ahadzadeh Namin, M., Khamseh, E., & Mohamadi, F. (2019). Evaluate the performance of bank branches using the control approach in analyzing the data common weight. *Financial engineering and securities management*, *10*(40), 1-28. (**In Persian**). https://civilica.com/doc/958478

Aliheidari Bioki, T., & Khademi Zare, H. (2014). Adaptive DEA for clustering of credit clients. *Journal of applied research on industrial engineering*, *1*(1), 35-49. http://www.journal-aprie.com/article_43017.html

Arabmazar, A., Varahrami, V., & Hasani, H. (2018). Survey performance of Iran's banks with network data envelopment analysis method. *Quarterly journal of quantitative economics*, *15*(2), 1-21. (**In Persian**). DOI: 10.22055/jqe.2017.21388.1596

Ardabili Miyanaj, P., & Borimnezhad, V. (2017). Evaluation of agricultural bank branches performance using data envelopment analysis: case study of alborz province. *Journal of agriclutural economices research*, *8*(32), 19-38. (**In Persian**). 20.1001.1.20086407.1395.8.32.2.8

Azar, A, Zarei Mahmoudabadi, M., Moqbel Ba'arz, A., & Khadivar, A. (2014). Evaluating the productivity of a bank's branches using network data envelopment analysis approach (case study: a bank in Gilan province). *Journal of monetary and banking research*, *7*(20), 285-305. (**In Persian**). https://jmbr.mbri.ac.ir/article-1-144-fa.pdf

Azizi, J. (2015). Evaluation of the efficiency of the agricultural bank branches by using data envelopment analysis and the determination of a consolidated index: the case study in mazandaran province. *Agricultural economics*, *9*(1), 63-76. (**In Persian**). http://ensani.ir/file/download/article/20150706141047-9437-202.pdf

Bal, H., Örkcü, H. H., & Çelebioğlu, S. (2010). Improving the discrimination power and weights dispersion in the data envelopment analysis. *Computers & operations research*, *37*(1), 99-107. https://doi.org/10.1016/j.cor.2009.03.028

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

Dadmohammadi, D., & Ahmadi, A. (2014). Credit rating of bank customers using neural network with lateral connections. *Monetary and banking management development quarterly*, *2*(3), 1-28. (**In Persian**). https://journal.ansarbank.ir/article_9005.html

Daneshvar, S., Shahi, N., & Najafzadeh, F. (2015). Modified goal programming approach for improving the discrimination power and weights dispersion. *Journal of new researches in mathematics*, *1*(3), 5-18. https://www.sid.ir/paper/257260/en

Elahi, Sh., Ghods Elahi, A., & Naji, H. R. (2014). Presenting a hybrid model of neural networks using collective learning in order to assess credit risk. *Iran information and communication technology quarterly*, *20*(6). (**In Persian**). http://jour.aicti.ir/Article/6581/FullText

Faghih, H. (2010). Evaluating artificial neural network and its optimization using genetic algorithm in estimation of monthly precipitation data (case study: Kurdistan region). *JWSS*, *14*(51), 27-42. (**In Persian**). https://www.sid.ir/paper/14867/fa

Farrell, M. J. (1957). The measurement of productive efficiency. *Journal of the royal statistical society: series A(general)*, *120*(3), 253-281.

Ghasem Nia Arabi, N., & Safaei Ghadi Kolaei, A. (2018). Comparing the performance of classical models and artificial intelligence in predicting the credit status of bank customers. *Scientific-research journal of business management explorations*, *10*(20), 51-69. (**In Persian**). https://sid.ir/fileserver/jf/4003313972003

Heidary, S., Zanburi, E., & Parvin, H. (2018). A hybrid model based on neural network and data envelopment analysis model for evaluation of unit performance. *Iranian journal of optimization*, *10*(2), 101-112. (**In Persian**). https://journals.iau.ir/article_537750_7a9f12b441f6b39322346234381df15e.pdf

Hosseinzadeh Lotfi, F., & Jahanbakhsh, M. (2015). Assess the efficiency and effectiveness simultaneously in a three-stage process, by using a unified model. *International journal of research in industrial engineering*, *4*(1(4)), 15-23. https://doi.org/10.22105/riej.2017.49165

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. (**In Persian**). DOI: 10.22105/dmor.2020.254632.1243

Jahangiri, A. (2019). Application of data envelopment analysis technique in Iran banking system. *Journal of decisions and operations research*, *3*(4), 368-401. (**In Persian**). https://doi.org/10.22105/dmor.2019.82229

Katsoufi, S., Lazou, A. E., Giannakourou, M. C., & Krokida, M. K. (2017). Mass transfer kinetics and quality attributes of osmo-dehydrated candied pumpkins using nutritious sweeteners. *Journal of food science and technology*, *54*(10), 3338-3348. https://doi.org/10.1007/s13197-017-2786-2

Li, X. B., & Reeves, G. R. (1999). A multiple criteria approach to data envelopment analysis. *European journal of operational research*, *115*(3), 507-517. https://doi.org/10.1016/S0377-2217(98)00130-1

Mehrabian, S., Saati-Mohtadi, S., & Hadi, A. (2011). Evaluating the efficiency of new economy bank branches with a combination of neural network method and data envelopment analysis. *Operations research in its applications*, *8*(4). (**In Persian**). https://jamlu.liau.ac.ir/article-1-329-fa.html

Mehrara, M., & Mehran Far, M. (2015). Bank and macroeconomic variables efficiency in risk management. *Economic modeling*, *7*(21), 21-37. (**In Persian**). https://eco.firuzkuh.iau.ir/article_555431_en.html?lang=fa

Minhaj, M. B. (2005). *Basics of neural networks*. Amir Kabir University, Tehran. (**In Persian**). http://publication.aut.ac.ir/fa/book/show/711

Mir Ghafouri, S. H., Morovatti Sharifabadi, A., & Zamani, F. (2014). Providing an integrated model of data envelopment analysis and artificial neural networks to evaluate and predict the performance of case study bank branches (Tejarat

Bank Yazd branches). *The third national accounting and management conference*, Tehran, Iran. Civilica. (**In Persian**). https://civilica.com/doc/342996/

Moghaddas, Z., & Vaez Ghasemi, M. (2021). Cost efficiency evaluation for a two-stage series network in data envelopment analysis. *Innovation management and operational strategies*, *1*(1), 48-56. (**In Persian**). DOI: 10.22105/imos.2021.262727.1018

Nilchi, M., Fadaeinejad, M., Razavi-Hajiagha, S., & Badri, A. (2017). Providing new multi-component data envelopment analysis to evaluate efficiency of bank branches. *Industrial management studies*, *15*(46), 73-96. (**In Persian**). DOI: 10.22054/jims.2017.7989

Rajabzadeh Ghatari, A., Mirzaei, A. B., & Ahmadi, P. (2009). Designing a combined intelligent system for credit rating of bank customers using combined fuzzy reasoning models. *Quarterly journal of business research*, *53*, 159-201. (**In Persian**). https://sid.ir/fileserver/jf/51213885306

Ranjbar, M., BakyHaskouei, M., & Farahanifard, S. (2016). The study of effective factors on Iranian banking system technical performance by applying panel data approach. *Journal of econometric modeling*, *1*(3), 23-42. (**In Persian**). DOI: 10.22075/JEM.2017.1509

Sabonian, M., & Behnajady, M. A. (2018). Application of artificial neural networks in the modeling of photocatalytic reduction of Cr (VI) by titanium dioxide nanoparticles: optimization of artificial neural network structure. *Iranian journal of health and environment*, *11*(2), 183-196. (**In Persian**). http://ijhe.tums.ac.ir/article-1-5979-fa.html

Sadorsky, P. (2006). Modeling and forecasting petroleum futures volatility. *Energy economics*, *28*(4), 467-488. https://doi.org/10.1016/j.eneco.2006.04.005

Sahoo, B. K., Mehdiloozad, M., & Tone, K. (2014). Cost, revenue and profit efficiency measurement in DEA: a directional distance function approach. *European journal of operational research*, *237*(3), 921-931. https://doi.org/10.1016/j.ejor.2014.02.017

Wesolowski, M., & Suchacz, B. (2012). Artificial neural networks: theoretical background and pharmaceutical applications: a review. *Journal of AOAC international*, *95*(3), 652-668. https://doi.org/10.5740/jaoacint.SGE_Wesolowski_ANN