Financial Research Journal

Print ISSN: 1024-8153

Online ISSN: 2423-5377

Designing a Model for Credit Risk Assessment of Customers for Guarantees Issued by the Export Guarantee Fund of Iran via Artificial Neural Network Model

Farshid Ahmadi Sartakhti

PhD Candidate, Department of Economics, Science and Research Branch, Islamic Azad University, Tehran, Iran. E-mail: farshid.ahmadi.sartakhti@gmail.com

Kambiz Hojabr Kiani *

*Corresponding Author, Prof., Department of Economics, Science and Research Branch, Islamic Azad University, Tehran, Iran. E-mail: khkiani@yahoo.com

Seyed Shamsoddin Hoseini

Assistant Prof., Department of Economics, Science and Research Branch, Islamic Azad University, Tehran, Iran. E-mail: s.s.hoseini@gmail.com

Abbas Memarnejad

Assistant Prof., Department of Economics, Science and Research Branch, Islamic Azad University, Tehran, Iran. E-mail: ab_memar@yahoo.com

Abstract

Objective

One of the most important risks faced by financial institutions is credit risk, which is formed by the possibility of the receiver's default in repaying the loan or repaying the loan on time. One of the pivotal financial institutions in Iran's economy is the Export Guarantee Fund of Iran. Being the exclusive official export credit insurance entity in Iran, it operates under complete government ownership, shouldering all obligations associated with the fund's coverage. Over the past decade, the Export Guarantee Fund of Iran, the sole provider of export guarantees in the Iranian economy, has undertaken the risk amounting to approximately $15.8 billion through the issuance of diverse guarantees and insurance policies. The most significant volume of claims pertains to credit guarantees. Based on available statistics and official records within the Iranian entity, it can be observed that between the Iranian calendar years of 1387 and 1397, this fund issued guarantees totaling $6.7 billion, with the largest claim, exceeding $317 million, originating from the credit guarantees provided for the benefit of creditors. Recognizing the significance of this matter, the development of an optimal model for evaluating the credit guarantees provided by customers of the Export Guarantee Fund of Iran holds the potential to mitigate credit risk and subsequently decrease the fund's incurred losses. Even a one percent reduction in the fund's losses could result in substantial savings, amounting to at least 1,330 billion Rials. This figure is poised to grow even further as the

fund increases the issuance of credit guarantees. Consequently, the primary objective of this research is to identify the most effective method for distinguishing between creditworthy and high-risk customers, ultimately diminishing the default rate of loans extended by the Export Guarantee Fund of Iran.

Methods

In this study, an artificial neural network model was employed to create a risk assessment framework for applicants seeking financial facilities and guarantees from this fund. This model exhibits exceptional predictive capabilities, especially in estimating the likelihood of default for the granted facilities. To achieve this objective, a dataset comprising 2,170 credit files granted by this fund was utilized. A total of 69 intra-organizational and extra-organizational variables were initially considered, and their respective information was gathered. Subsequently, six key variables were employed in the ultimate neural network model, encompassing the credit recipient's province, the guarantee beneficiary (creditor bank), personnel count, current ratio, real interest rate, and economic growth rate.

Results

Based on the neural network model, the best models were extracted with three methods: Bayesian, Levenberg, and Conjugate Gradient, and with one to 30 neurons in the hidden layer. The best model with all independent variables (i.e., 69 independent variables) was predicted with 96.2% accuracy, which is more than the Probit econometric model.

Conclusion

The findings of this research offer the capability to distinguish between customers with favorable and unfavorable credit profiles. Furthermore, the credit rating of customers can be used as a basis for adjusting the collateral requirements for each customer group, thereby aligning the collateral amount with the creditworthiness of the respective groups. This means that if the customer is one of the customers with good credit and a good credit rating, less collateral can be obtained from them, and if the customer has higher credit risk, more collateral can be used as a guarantee of the repayment obligation. In this case, while measuring the credit risk and separating customers, it is possible to manage the risk and the credit portfolio of the Export Guarantee Fund of Iran optimally.

Keywords: Credit risk, Export guarantee fund of Iran, Artificial neural networks.

Citation: Ahmadi Sartakhti, Farshid; Hojabr Kiani, Kambiz; Hoseini, Seyed Shamsoddin & Memarnejad, Abbas (2023). Designing a Model for Credit Risk Assessment of Customers for Guarantees Issued by the Export Guarantee Fund of Iran via Artificial Neural Network Model. *Financial Research Journal*, 25(4), 641- 660. https://doi.org/10.22059/FRJ.2023.361963.1007488 (*in Persian*)

Financial Research Journal, 2023, Vol. 25, No.4, pp. 641-660
Published by University of Tehran, Faculty of Management
https://doi.org/10.22059/FRJ.2023.361963.1007488
Article Type: Research Paper
© Authors
Received: July 12, 2023
Received in revised form: September 10, 2023
Accepted: October 15, 2023
Published online: January 20, 2024

تحقیقات مالی
شاپا چاپی: ۱۰۲۴-۸۱۵۳
شاپا الکترونیکی: ۲۴۲۳-۵۳۷۷

طراحی مدلی برای ارزیابی ریسک اعتباری مشتریان ضمانت‌نامه‌های صادر شده توسط صندوق ضمانت صادرات ایران با کمک مدل شبکه عصبی مصنوعی

فرشید احمدی سرتختی
دانشجوی دکتری، گروه اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. رایانامه: farshid.ahmadi.sartakhti@gmail.com

کامبیز هژبر کیانی *
* نویسنده مسئول، استاد، گروه اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. رایانامه: khkiani@yahoo.com

سید شمس‌الدین حسینی
استادیار، گروه اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. رایانامه: s.s.hoseini@gmail.com

عباس معمارنژاد
استادیار، گروه اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. رایانامه: ab_memar@yahoo.com

چکیده

هدف: یکی از ریسک‌های مهم پیش روی مؤسسه‌های مالی، ریسک اعتباری است که از احتمال قصور تسهیلات‌گیرنده در بازپرداخت تسهیلاتی یا بازپرداخت به‌موقع تسهیلات شکل می‌گیرد. یکی از نهادهای مالی بسیار مهم در اقتصاد ایران، صندوق ضمانت صادرات ایران است که به‌عنوان تنها مؤسسه بیمه اعتبار صادراتی رسمی ایران، کاملاً دولتی است و تمامی تعهدهای مربوط به پوشش‌های صندوق بر عهده دولت است. صندوق ضمانت صادرات ایران، به‌عنوان تنها صادرکننده ضمانت‌نامه‌های صادراتی در اقتصاد ایران، طی دهه اخیر حدود ۱۵/۸میلیارد دلار از طریق صدور انواع ضمانت‌نامه و بیمه‌نامه، ریسک پذیرفته است که بیشترین مبلغ خسارت آن، به ضمانت‌نامه‌های اعتباری صادره مربوط می‌شود. بر اساس آمار و مستندات موجود در صندوق ضمانت صادرات ایران، طی دوره ۱۳۸۷ تا ۱۳۹۷، این صندوق ۶/۷ میلیارد دلار ضمانت‌نامه صادر کرده است که بیشترین مبلغ خسارت (بیش از ۳۱۷ میلیون دلار)، مربوط به ضمانت‌نامه‌های اعتباری صادرشده به نفع اعتباردهندگان است. نظر به اهمیت این موضوع با دستیابی به یک الگوی بهینه برای اعتبارسنجی مشتریان ضمانت‌نامه‌های اعتباری صندوق ضمانت صادرات ایران، می‌توان ریسک اعتباری و به‌تبع آن، خسارات پرداختی صندوق را کاهش داد؛ به‌گونه‌ای که حتی اگر تنها ۱ درصد خسارت‌های صندوق کاهش یابد، حداقل سالانه بیش از ۱۳۳۰ میلیارد ریال از مجموع خسارات وارده به صندوق کاهش خواهد یافت. بدیهی است که با افزایش صدور ضمانت‌نامه‌های اعتباری صندوق، این رقم افزایش بیشتری نیز خواهد یافت. بر این اساس، هدف اصلی پژوهش، انتخاب بهترین روش برای تفکیک اشخاص خوش‌حساب از بدحساب، برای کاهش نکول اعتبارات اعطاشده صندوق ضمانت صادرات ایران است.

روش: در این پژوهش تلاش شده است تا به‌کمک مدل شبکه عصبی مصنوعی، مدلی برای ارزیابی ریسک متقاضیان تسهیلات و ضمانت‌نامه‌ها از این صندوق طراحی شود که بیشترین قدرت پیش‌بینی احتمال نکول تسهیلات اعطایی را داشته باشد. برای این منظور، بر اساس داده‌های ۲۱۷۰ پرونده اعتبار اعطایی این صندوق، ۶۹ متغیر درون‌سازمانی و برون‌سازمانی انتخاب و اطلاعات آن جمع‌آوری شد و از میان آن‌ها ۶ متغیر در مدل نهایی شبکه عصبی استفاده شد که عبارت‌اند از: استان محل فعالیت اعتبار گیرنده، ذی‌نفع ضمانت‌نامه (بانک اعتباردهنده)، تعداد کارمند، نسبت جاری، نرخ سود واقعی و نرخ رشد اقتصادی.

یافته‌ها: بر اساس مدل شبکه عصبی و با سه شیوه بیزین، لونبرگ و گرادیان مزدوج و با ۱ تا ۳۰ نرون در لایه پنهان، بهترین مدل‌ها استخراج شدند. بهترین مدل با کلیه متغیرهای مستقل (یعنی ۶۹ متغیر مستقل)، پیش‌بینی‌ای با ۹۶/۲ درصد دقت داشته است که از مدل اقتصادسنجی پروبیت بیشتر است.

نتیجه‌گیری: بر اساس نتایج حاصل از این پژوهش، می‌توان ضمن تفکیک مشتریان خوش‌حساب از بدحساب و بر اساس رتبه اعتباری مشتریان، میزان وثایق اخذشده از مشتریان را متناسب با وضعیت اعتباری گروه‌های اعتباری تنظیم کرد؛ بدین معنا که چنانچه مشتری جزء مشتریان خوش‌حساب و با رتبه اعتباری خوب باشد، می‌توان وثایق کمتری از ایشان گرفت و اگر مشتری ریسک اعتباری بالاتری داشته باشد، متناسب با آن، وثایق بیشتری را به‌عنوان تضمین تعهد بازپرداخت درخواست کرد. در این صورت، ضمن اندازه‌گیری ریسک اعتباری و تفکیک مشتریان، می‌توان به مدیریت بهینه ریسک و پرتفوی اعتباری صندوق ضمانت صادرات ایران اقدام کرد.

کلیدواژه‌ها: ریسک اعتباری، صندوق ضمانت صادرات، مدل شبکهٔ عصبی مصنوعی.

استناد: احمدی سرتختی، فرشید؛ هژبر کیانی، کامبیز؛ حسینی، سید شمس الدین و معمارنژاد، عباس (۱۴۰۲). طراحی مدلی برای ارزیابی ریسک اعتباری مشتریان ضمانت‌نامه‌های صادر شده توسط صندوق ضمانت صادرات ایران با کمک مدل شبکهٔ عصبی مصنوعی. *تحقیقات مالی*، ۲۵(۴)، ۶۴۱- ۶۶۰.

تحقیقات مالی، ۱۴۰۲، دوره ۲۵، شماره ۴، صص. ۶۴۱-۶۶۰
ناشر: دانشکدهٔ مدیریت دانشگاه تهران
نوع مقاله: علمی پژوهشی
© نویسندگان
تاریخ دریافت: ۱۴۰۲/۰۴/۲۱
تاریخ ویرایش: ۱۴۰۲/۰۶/۱۹
تاریخ پذیرش: ۱۴۰۲/۰۷/۲۳
تاریخ انتشار: ۱۴۰۲/۱۰/۳۰
doi: https://doi.org/10.22059/FRJ.2023.361963.1007488

مقدمه

نهادهای مالی مانند بانک‌ها، مؤسسه‌هایی هستند که نقش واسطه‌های مالی را اجرا می‌کنند. این نهادها باعث می‌شوند که سرمایه‌ها با سرعت بیشتر و با هزینه‌ای کمتر در گردش باشند؛ زیرا این نهادها عمدتاً امور مالی و سرمایه‌گذاری را اجرایی و پشتیبانی می‌کنند. بنابراین نهاد مالی یکی از ارکان مهمی است که در بازارهای مالی نقش ایفا می کند و در اکوسیستم اقتصادی اهمیت ویژه‌ای دارد. برخی از فعالیت‌ها، مانند ارائهٔ تسهیلات به بخش خصوصی با ریسک همراه است. بر اساس ماهیت ذاتی و عملکردی، نهادهای مالی باید ریسک‌پذیر باشند تا حاشیهٔ سود خود را حفظ و نقش خود را در اقتصاد ایفا کنند؛ اما اگر بیش از حد ریسک‌پذیر باشند و تسهیلاتی با احتمال نکول بالا به بخش خصوصی اعطا کنند، دچار مشکل می‌شوند.

ریسک‌هایی که نهادهای مالی با آن مواجهند، متنوع است و باید شناسایی، درک، اندازه‌گیری و مدیریت شوند. یکی از ریسک‌های مهمی که نهادهایی مانند بانک‌ها و مؤسسه‌های اعتباری، در تخصیص تسهیلات به بخش خصوصی با آن مواجهند، ریسک اعتباری است. ریسک اعتباری به احتمال نکول یا احتمال تأخیر در بازپرداخت تسهیلات، توسط بخش خصوصی یا افراد وام‌گیرنده اطلاق می‌شود که بر سود مؤسسه‌های مالی نیز اثر منفی دارد (شوال‌پور و اشعری، ۱۳۹۲). طبق قوانین کمیتهٔ بازل، یکی از وظایف بانک‌ها (و در حالت کلی‌تر مؤسسه‌های مالی) این است که سیستم‌های امتیازدهی داخلی خود را سازمان‌دهی کنند و ارتقا دهند. بر همین اساس امروزه اهمیت صنعت رتبه‌بندی اعتباری افزایش یافته و توسعهٔ سیستم‌های مربوط به آن‌ها، یکی از دغدغه‌های بسیار مهم است.

یکی از نهادهای مالی بسیار مهم در اقتصاد ایران، صندوق ضمانت صادرات ایران[1] است که به‌عنوان تنها مؤسسهٔ بیمهٔ اعتبار صادراتی رسمی ایران، کاملاً دولتی است و تمامی تعهدهای مربوط به پوشش‌های صندوق بر عهدهٔ دولت است. صندوق ضمانت صادرات ایران با دو هدف تأسیس شده است: ۱. پوشش مطالبات صادرکنندگان از خریداران خارجی در برابر ریسک‌های سیاسی و تجاری با صدور انواع بیمه‌نامه‌های کوتاه‌مدت، میان‌مدت و بلندمدت؛ ۲. امکان تأمین مالی فعالیت‌های صادراتی صادرکنندگان از طریق صدور انواع ضمانت‌نامه‌های اعتباری به نفع بانک‌ها و مؤسسه‌های اعتباری داخلی[2].

انواع خدمات صندوق ضمانت صادرات ایران عبارت‌اند از: اعتبارسنجی خریداران خارجی، بیمهٔ خاص صادرات، بیمهٔ کل گردش صادرات، بیمهٔ بلااثر شدن قرارداد صادراتی، بیمهٔ پوشش ضمانت‌نامه‌های بانکی بازپرداخت، بیمهٔ صدور

1. Export Guarantee Fund of Iran

۲. یکی از عواملی که همواره اسباب نگرانی صادرکنندگان را فراهم می‌آورد، وجود ریسک‌های سیاسی و تجاری در روند صادرات آن‌هاست؛ زیرا تحقق هر یک از این ریسک‌ها، موجب عدم وصول وجه کالا و خدمات صادره از سوی آن‌ها می‌شود. عدم وصول به‌موقع مطالبات از خریداران خارجی، اغلب صادرکننده را در تنگنای مالی قرار می‌دهد و در نتیجه باعث ناتوانی در ایفای تعهدات مالی وی به اعتباردهندگان داخلی و گاهی نیز، به ورشکستگی کامل منجر می‌شود. به‌منظور تشویق صادرکنندگان به توسعهٔ فعالیت‌های صادراتی خود و کاهش نگرانی آن‌ها در این زمینه و ارائهٔ پوشش‌های لازم به آن‌ها در مقابل ریسک‌های سیاسی و تجاری، دولت‌ها به ایجاد شرکت‌های بیمهٔ اعتبار صادراتی اقدام می‌کنند.

خدمات فنی و مهندسی، بیمهٔ سرمایه‌گذاری، ضمانت‌نامه اعتبار ریالی، ضمانت‌نامه اعتبار ارزی و ضمانت‌نامه اعتبار تولیدی. این صندوق با سرمایهٔ ۱۳ هزار میلیارد ریالی طی دو دههٔ اخیر، تقریباً ۲۵ میلیارد دلار از طریق صدور انواع ضمانت‌نامه و بیمه‌نامه، ریسک پذیرفته است. مبالغ صدور ضمانت‌نامه و همچنین مبالغ خسارت پرداختی بابت آن، بیش از دو محصول دیگر بیمه‌ای صندوق مذکور بوده است. ضمانت‌نامه‌های اعتباری به‌صورت ریالی و یا ارزی صادر شده و در واقع جایگزین انواع وثایق برای اعطای اعتبار توسط اعتباردهندگان است. این ضمانت‌نامه، ریسک‌گیرنده اعتبار را به نفع اعتباردهنده (سیستم بانکی) تحت پوشش قرار می‌دهد (صندوق ضمانت صادرات ایران، ۱۴۰۰).

موضوع ریسک و چگونگی مدیریت، کنترل و کاهش آن، همواره یکی از دغدغه‌های جدی وزرای اقتصادی دولت (اعضای مجمع صندوق ضمانت صادرات ایران) و همچنین و مسئولین این نهاد حمایتی بوده است. بر اساس آمار و مستندات موجود در صندوق ضمانت صادرات ایران، طی دورهٔ ۱۳۸۷ تا ۱۳۹۷، این صندوق، ۶/۷ میلیارد دلار ضمانت‌نامه صادر کرده است که بیشترین مبلغ خسارت (بیش از ۳۱۷ میلیون دلار) به ضمانت‌نامه‌های اعتباری صادره به‌نفع اعتباردهندگان مربوط است. نظر به اهمیت این موضوع با دستیابی به یک الگوی بهینه برای اعتبارسنجی مشتریان ضمانت‌نامه‌های اعتباری صندوق ضمانت صادرات، می‌توان ریسک اعتباری و به تبع آن خسارات پرداختی صندوق را کاهش داد؛ به‌گونه‌ای که حتی اگر تنها ۱درصد خسارت‌های صندوق کاهش یابد، دست‌کم سالانه بیش از ۱۳۳۰ میلیارد ریال از مجموع خسارات وارده به صندوق کاهش خواهد یافت. بدیهی است با افزایش صدور ضمانت‌نامه‌های اعتباری صندوق، این رقم افزایش بیشتری نیز خواهد یافت. بر این اساس، سؤال اصلی پژوهش آن است که چگونه اشخاص خوش‌حساب و بدحساب را از هم تفکیک کرده و نکول اعتبارات اعطایی از سوی صندوق ضمانت صادرات ایران را پیش‌بینی کنیم؟ به‌منظور پاسخ به سؤال مذکور، در مطالعهٔ حاضر تلاش می‌شود که با کمک رویکرد شبکهٔ عصبی مصنوعی، این مهم برآورده شود تا بتوان زیان‌های ناشی از عدم تعیین دقیق ریسک اعتباری مشتریان صندوق ضمانت صادرات ایران و هزینه‌های بازیافت خسارت‌های پرداختی توسط این صندوق را کاهش داد.

سایر بخش‌های مقاله به شرح زیر تدوین شده است. در بخش دوم، پیشینهٔ نظری مربوط به ریسک اعتباری و مطالعات تجربی قبلی مرور می‌شود. در بخش سوم، مدل شبکهٔ عصبی مصنوعی و در بخش چهارم نتایج آن تشریح می‌شود. سرانجام در قسمت پنجم، نتیجه‌گیری و توصیه‌های سیاستی ارائه خواهد شد.

پیشینهٔ نظری و مطالعات تجربی

در این بخش ابتدا به مرور مبانی نظری در زمینهٔ دلایل شکل‌گیری ریسک اعتباری و بحث در خصوص عوامل مؤثر بر آن پرداخته شده است؛ سپس مطالعات تجربی انجام‌شدهٔ داخلی و خارجی مرور خواهد شد.

ریسک اعتباری ریسکی است که از احتمال قصور تسهیلات‌گیرنده در بازپرداخت تسهیلاتی یا بازپرداخت به‌موقع تسهیلات شکل می‌گیرد. به بیان دیگر، ریسک اعتباری به‌دلیل تغییر تمکن مالی دریافت‌کنندهٔ تسهیلات ایجاد می‌شود و از این واقعیت نشئت می‌گیرد که دریافت‌کننده تسهیلات، نتواند (به‌دلیل توان مالی) یا نخواهد (به‌دلیل تمایل) تعهدهای

قرارداد را انجام دهد. عوامل مختلفی در شکل‌گیری ریسک اعتباری و نکول تسهیلات مؤثرند که می‌توان آن‌ها را در سه گروه شرایط محیطی خارج از بنگاه، عوامل درون بنگاهی و شرایط مؤسسه‌های مالی دسته‌بندی کرد (خرمی، تقوی فرد و خاتمی فیروزآبادی، ۱۳۹۹ و مهرآرا و بهلولوند، ۱۳۹۵).

الف) عوامل محیطی خارج از سازمان: عوامل اقتصاد کلان و شرایط اقتصاد داخلی و بین‌المللی که بر عملکرد بنگاه‌ها و دوره‌های رونق و رکود آن‌ها مؤثرند، مانند نرخ رشد اقتصادی، تورم، بحران مالی جهانی و تحریم‌های خارجی بر احتمال نکول تسهیلات دریافتی تأثیر می‌گذارند. در زمان رونق اقتصادی با توجه به سطح تولید و درآمد افراد، توان بازپرداخت دیون بالا و بنابراین ریسک اعتباری پایین است؛ اما در زمان رکود اقتصادی به‌دلیل کاهش تولید و درآمد، توان بازپرداخت دیون کاهش می‌یابد و در این بین، بانک‌ها که وظیفهٔ تأمین و تجهیز منابع مالی و اعطای تسهیلات را دارند با مشکل مواجه می‌شوند و سطح خدمات آن‌ها نیز کاهش می‌یابد (مهرارا و بهلولوند، ۱۳۹۵). نتایج بینیسی و هاتچیسان[1] (۲۰۱۸) نشان می‌دهد که وضعیت چشم‌انداز اقتصاد کلان، در تعیین دقیق ارزش اطلاعات تغییرات رتبه‌بندی اعتباری نقش مهمی دارد. دندرامیس، تزاوالیس و آدراکتاس[2] (۲۰۱۷) در مقاله‌ای با عنوان «مدل‌سازی ریسک اعتباری در شرایط تنش رکود و مالی»، دریافتند که شرایط اقتصاد داخلی کشور، یکی از متغیرهای مهم در مدل‌سازی میزان ریسک اعتباری در شرایط رکود و رونق است. نادعلی‌زاده، هژبر کیانی، حسینی و پیکارجو (۱۴۰۰) دریافتند که تکانه‌های قیمت نفت بر نسبت مطالبات غیرجاری به کل تسهیلات اعطایی، به‌عنوان شاخصی برای اندازه‌گیری ریسک اعتباری، تأثیر مثبت دارد.

ب) عوامل درون‌سازمانی: شرایط درون‌بنگاهی که از نوع مدیریت، حجم نقدینگی و اندازهٔ بنگاه تأثیر می‌پذیرد، بر احتمال نکول تسهیلاتی دریافتی مؤثر است. یکی از این عوامل، دورهٔ گردش عملیات است که با افزایش دورهٔ گردش، توانمندی وام‌گیرنده برای تسویهٔ تعهدات خود کمتر و ریسک اعتباری بیشتر خواهد شد. یکی دیگر از متغیرهای مهم، تعداد کارکنان مشغول در یک بنگاه اقتصادی است که اندازهٔ آن بنگاه و احتمال برخورداری بنگاه از صرفه‌جویی‌های ناشی از مقیاس را نشان می‌دهد. انتظار می‌رود با افزایش تعداد کارکنان هر بنگاه، ریسک اعتباری آن کاهش یابد. متغیر مهم بعدی نسبت جاری است که این نسبت، دارایی‌های جاری به بدهی‌های جاری را می‌سنجد. مقادیر بزرگ‌تر این نسبت، از فزونی دارایی‌های جاری بر بدهی‌های جاری حکایت دارد و بدیهی است با افزایش این نسبت، توانمندی شرکت برای ایفای تعهدات خود (بدهی‌های جاری) بیشتر شده و ریسک اعتباری کمتر می‌شود.

ج) علاوه بر شرایط محیط‌های خارجی و داخلی، فعالیت بنگاه‌های دریافت‌کنندهٔ اعتبار، ساختار و عملکرد مؤسسه‌های مالی در اعطای تسهیلات بر حجم ریسک اعتباری آن‌ها مؤثر است. بر اساس فرضیهٔ مخاطرهٔ اخلاقی، بانک‌هایی که سرمایه محدودی دارند از ریسک اعتباری بالایی برخوردارند. در چارچوب این فرضیه، سرمایهٔ محدودتر باعث نگرانی کمتر آن‌ها از ورشکستگی می‌شود و بنابراین به مخاطرهٔ اخلاقی می‌انجامد. از این رو سهم وام‌های با ریسک بالا در ترکیب وام‌های بانکی افزایش خواهد یافت که نتیجهٔ آن، افزایش میزان تسهیلات غیرجاری است. یکی دیگر از اثرهای اخلاقی، بروز تضاد منافع است؛ به‌گونه‌ای که گاهی یک بانک به یک بنگاه وامی با شرایط بسیار آسان اعطا می‌کند تا از

1. Binici & Hutchison
2. Dendramis, Tzavalis & Adraktas

تعرفه‌ها و کارمزدهای ناشی از به‌دست‌آوردن بعضی از خدمات آن بنگاه برخوردار شود. در این صورت، تخصیص ناکارای اعتبارات و افزایش ریسک اعتباری به‌وجود می‌آید (کردبچه و پردل نوش‌آبادی، ۱۳۹۰).

برای سنجش ریسک اعتباری، معمولاً شرکت‌ها یا دریافت‌کننده‌های اعتبار مالی را بر اساس ریسکی که در قرارداد متوجه بانک است، رتبه‌بندی می‌کنند و برای اندازه‌گیری ریسک اعتباری، به هر رتبهٔ اعتباری، یک احتمال نُکول نسبت می‌دهند. احتمال نکول به احتمال عدم پرداخت تمام یا بخشی از اعتبار دریافتی از سوی دریافت‌کنندهٔ اعتبار اطلاق می‌شود که ممکن است به‌صورت ارادی یا ناخواسته رخ دهد.

شکاف اطلاعاتی موجود میان اعتباردهنده و اعتبارگیرنده که از آن به عدم تقارن اطلاعات[1] یاد می‌شود، اساس علمی شکل‌گیری نظام سنجش اعتبار را تشکیل می‌دهد. عدم تقارن اطلاعات میان اعتباردهنده و گیرندهٔ اعتبار، موجب کاهش عملکرد اعتباردهندگان و همچنین افزایش چشمگیر مطالبات معوق خواهد شد. این عدم تقارن اطلاعات، در مواقعی به کژگزینی و کژمنشی منجر می‌شود که می‌تواند، موجب ورشکستگی بانک‌ها و مؤسسه‌های مالی و اعتباری شود. چنین موضوعاتی باعث می‌شود تا برخی از اشخاص حقیقی یا حقوقی قادر باشند با دریافت تسهیلات از مؤسسه‌های مالی، به سوءاستفاده از این موضوع اقدام کنند (پورعبادالهان کویچ، نوبهار و رحیمی، ۱۳۹۹). راه‌حل پرکاربرد در سطح جهانی انتشار اطلاعات مالی و به‌خصوص دیون مالی اشخاص حقیقی و حقوقی و به بیان دیگر توسعهٔ سیستم‌های اطلاعات اعتباری و تسهیم اطلاعات است که به اعتباردهندگان امکان می‌دهد تا با استفاده از سوابق مالی متقاضیان اعتبار، به ارزیابی آن‌ها و احتمال نکول وام بپردازند (جلیلی، ۱۳۸۹ و نظرپور و اولاد، ۱۳۹۷).

پیشینه تجربی پژوهش

نیلساز، راسخ، عصاره و سینایی (۱۳۸۶) به رتبه‌بندی اعتباری فروش اقساطی متقاضیان وام با کمک رویکرد شبکه‌های عصبی پرداختند. آن‌ها از روش‌های آماری مختلفی از جمله آنالیز ممیزی، رگرسیون لجستیک و شبکه‌های عصبی برای رتبه‌بندی اعتباری استفاده کردند؛ بدین ترتیب که یک مدل شبکهٔ عصبی برای طبقه‌بندی متقاضیان دریافت وام فروش اقساطی ارائه دادند و عملکرد این مدل را با دو مدل آماری آنالیز ممیزی و رگرسیون لجستیک مقایسه کردند. نتایج حاصل از این مقایسه نشان می‌دهد که مدل شبکهٔ عصبی در مقایسه با سایر مدل‌های مورد مطالعه از کارایی و دقت بالاتری برخوردار است.

قدسی‌پور، سالاری و دلاوری (۱۳۹۱) با به‌کارگیری تحلیل سلسله‌مراتبی فازی و شبکهٔ عصبی ترکیبی درجهٔ بالا به ارزیابی ریسک اعتباری اشخاص حقیقی متقاضی اعتبار از بانک ملت طی سال‌های ۱۳۸۳ تا ۱۳۸۷ پرداختند. مدل تجربی این پژوهش قادر است احتمال نکول وام را با دقت ۸۴ درصد پیش‌بینی کند.

روح الامینی، ششمانی و خرم (۱۳۹۴) با کمک هوش مصنوعی، رتبه‌بندی اعتباری مشتریان حقیقی در بانک مسکن را انجام دادند. آن‌ها در این پژوهش از متغیرهای سن، وضعیت تأهل، تعداد فرزندان، تحصیلات، شغل و میزان

1. Asymmetric information

درآمد برای پیش‌بینی احتمال نکول تسهیلات استفاده کردند. نتایج نشان می‌دهد که مدل شبکهٔ عصبی با انتخاب ویژگی عملکرد دقیق‌تری در پیش‌بینی نکول درخواست‌کنندگان وام در مقایسه با مدل شبکهٔ عصبی با انتخاب تمام ویژگی دارد.

حسینی و زیبایی (۱۳۹۴) با به‌کارگیری روش شبکهٔ عصبی مصنوعی به ارزیابی ریسک اعتباری متقاضیان وام از بانک کشاورزی شهرستان ممسنی پرداختند. نتایج پژوهش آن‌ها نشان می‌دهد که روش شبکهٔ عصبی قادر است احتمال نکول اعتبار اعطایی این بانک را با دقت ۹۵/۵ درصد پیش‌بینی کند.

قاسمی و دنیایی هریس (۱۳۹۵) به‌کمک رویکرد شبکهٔ عصبی، به اندازه‌گیری ریسک اعتباری مشتریان بانک توسعهٔ تعاون شهر تهران پرداختند. برای این منظور، بر اساس نظر خبرگان، از شاخص‌هایی مانند داشتن سابقهٔ بدهی بانکی و چک برگشتی، نسبت بدهی، طول عمر حساب مشتری و سابقهٔ فعالیت مشتری بهره بردند. سپس با روش الگوریتم تشخیص الگوی شبکهٔ عصبی، به تعیین خوشه‌های بهینه اقدام کردند و متقاضیان اعتبار را به سه گروه پُرریسک، ریسک متوسط، کم‌ریسک طبقه‌بندی کردند.

باقری و حق‌شناس کاشانی (۱۳۹۷) با استفاده از روش شبکهٔ عصبی، به ارزیابی ریسک اعتباری تعاونی‌های شهری پرداختند. نتایج پژوهش آن‌ها نشان می‌دهد که شبکهٔ عصبی به‌کار رفته توانسته است با کارایی ۹۹/۱ درصد، ریسک اعتباری را مطابق با واقع برآورد کند. همچنین میزان خطای روش شبکهٔ عصبی نسبت به مدل‌های اقتصادسنجی کمتر است که این امر نشان‌دهندهٔ توانایی مدل شبکهٔ عصبی به‌کار رفته در بهبود محاسبهٔ ریسک اعتباری مشتریان است[1].

آنجلینی، دی تولو و رولی[2] (۲۰۰۸) به ارزیابی ریسک اعتبارات اعطایی به مشاغل کوچک ایتالیایی با کمک شبکهٔ عصبی پرداختند. نتایج نشان می‌دهد که شبکه‌های عصبی می‌توانند در یادگیری و تخمین تمایل پیش‌فرض وام گیرنده بسیار موفق باشند، مشروط بر اینکه تجزیه‌وتحلیل دقیق داده‌ها، پیش‌پردازش داده‌ها و آموزش انجام شود.

خشمان[3] (۲۰۰۹) با کمک مدل شبکهٔ عصبی و استفاده از داده‌های تأیید اعتبار استرالیا، به ارزیابی ریسک اعتباری پرداخت. نتایج این پژوهش نشان می‌دهد که شبکه‌های عصبی با یک و دو لایهٔ پنهان، می‌توانند به‌طور مؤثر در پردازش خودکار برنامه‌های اعتباری استفاده شوند. وی سال بعد همین پژوهش را روی داده‌های تأیید آلمان که بیش از ۱۰۰۰ مورد بود، انجام داد. برای این منظور، برای هر مورد اعتبار اعطایی، ۲۴ ویژگی عددی استخراج کرد که بر اساس آن درخواست پذیرفته یا رد می‌شد. در این پژوهش، ۹ طرح یادگیری با نسبت‌های مختلف داده‌های آموزشی به اعتبارسنجی بررسی شد. نتایج تجربی نشان داد که مدل شبکهٔ عصبی، تحت طرح یادگیری LS4، عملکرد بهینه را برای سیستم ارزیابی ریسک اعتباری ارائه می‌دهد (خشمان، ۲۰۱۰).

بخت و التر[4] (۲۰۱۴) با کمک رویکرد شبکه‌های عصبی، به ارزیابی ریسک اعتباری بانک‌های تجاری اردن

---

۱. از رویکرد شبکه عصبی در مطالعات دیگر مربوط به اقتصاد مالی، مانند بهینه‌سازی استراتژی معاملات زوجی (فلاح‌پور و حکیمیان، ۱۳۹۸)، محاسبهٔ وجه نقد مورد نیاز شعبه‌های بانک‌ها (باغبانی و اسکندری، ۱۳۹۶) و طراحی بهینهٔ اوراق بهادارسازی (عباسیان، ابراهیمی و فرزانگان، ۱۳۹۴) استفاده شده است.

2. Angelini, Di Tollo & Roli
3. Khashman
4. Bekhet and Eletter

پرداختند. نتایج آن‌ها نشان می‌دهد که مدل رگرسیون لجستیک از نظر میزان دقت کلی، کمی بهتر از مدل تابع پایه شعاعی[1] عمل می‌کند.

ژانگ، ما و ونگ[2] (۲۰۲۲) یک شبکهٔ عصبی ترکیبی Logistic-CNN-BiLSTM را برای پیش‌بینی ریسک اعتباری شرکت‌های املاک و مستغلات که طراحی کردند که در بازار سهام شانگهای و شنزن، طی دورهٔ زمانی ۲۰۱۷ تا ۲۰۲۰ وجود داشتند. نتایج آن‌ها نشان می‌دهد که رویکرد مورد استفادهٔ پژوهش در مقایسه با مدل‌های PSO-SVM، RS-PSO-SVR و PSO-BP نتایج تجربی بهتری را ارائه می‌کند و بر این اساس، آن‌ها مدل Logistic-CNN-BiLSTM-att را برای پیش بینی ریسک اعتباری شرکت‌های املاک و مستغلات فهرست شده توصیه کردند.

سینهوراج و پاتریک[3] (۲۰۲۳) به پیش‌بینی واجد شرایط بودن وام با استفاده از شبکهٔ عصبی فازی عمیق مبتنی بر بهینه‌سازی ترکیبی تطبیقی پرداختند. نتایج پژوهش آن‌ها نشان می‌دهد، این روش با حداکثر دقت، حساسیت و ویژگی، به‌ترتیب تقریباً ۹۵درصد، ۹۵/۴درصد و ۹۷/۳درصد بهتر عمل می‌کند.

ژانگ، یان و ون[4] (۲۰۲۳) از رویکرد شبکه‌های عصبی عمیق با تنظیم L1 و L2 برای پیش‌بینی ریسک اعتباری شرکتی استفاده کردند. آن‌ها ثابت کردند که وقتی منظم‌سازی L1 به لایهٔ نرمال‌سازی دسته‌ای DNN اضافه شد، هیچ اثر منظم‌سازی وجود نداشت. علاوه بر این، ثابت کردند که اضافه‌کردن محدودیت‌های L2 روی یک تنظیم L1 می‌تواند مشکل را حل کند. در انتهای مقاله، آن‌ها یک مطالعهٔ موردی از داده‌های اعتباری با داده‌های زنجیرهٔ تأمین و شبکه را برای نشان دادن برتری الگوریتم HDNN تحلیل کردند.

روش‌شناسی پژوهش

در این بخش ابتدا روش‌شناسی پژوهش ارائه می‌شود و در مرحلهٔ بعدی، داده‌های پژوهش معرفی خواهد شد. شبکهٔ عصبی مصنوعی، مدل خاصی از شبکه است که روش عملکرد مغز را شبیه‌سازی می‌کند. شبکهٔ عصبی یک سیستم غیرخطی با عناصر محاسباتی بسیار ساده است. در یک کاربرد خاص، شبکه عملکرد پردازش و ذخیره‌سازی اطلاعات از سیستم عصبی انسان را تقلید می‌کند. به‌دلیل ساختار منحصربه‌فردش، از آن برای حل مسائلی استفاده می‌شود که نمی‌توان آن‌ها را با روش‌های معمولی و ساده انجام داد. در ساختار این شبکه، تعداد نرون‌های لایهٔ ورودی (x1,x2,…,xd) برابر است با تعداد خصوصیات موجود برای تصمیم‌گیری در خصوص هر یک از نمونه‌های داده‌ها. به بیان دیگر، ورودی شبکه خصوصیات نمونه‌هاست. همچنین تعداد نرون‌های لایهٔ خروجی شبکه (z1,z2,…,zc) برابر است با تعداد کلاس‌های داده‌ها و هر نود در لایهٔ خروجی، متناظر است با یک کلاس خاص در مجموعه داده‌ها. بخش دیگر ساختار این شبکه، لایهٔ پنهان یا لایهٔ میانی آن (y1,y2,…,yc) است. تعداد لایه‌های پنهان معمولاً یک لایه در نظر گرفته می‌شود. تعداد بیشتر لایه‌های پنهان، مسئله را پیچیده و اجرای آن را زمان‌بر می‌کند. علاوه بر این محققان

1. Radial basis function
2. Zhang, Ma & Wang
3. Sindhuraj & Patrick
4. Zhang, Ma & Wan

اثبات کرده‌اند که به‌جای در نظر گرفتن لایه‌های پنهان متعدد، می‌توان الگوریتم آموزشی روش را به دفعات بسیاری روی داده‌های آموزشی تکرار کرد تا به پاسخ بهینه دست یافت. بنابراین در اغلب موارد، یک لایه پاسخ‌گوی حل مسئله است. مسئلهٔ مهم دربارهٔ لایهٔ پنهان، انتخاب تعداد نرون‌های این لایه است. هرچه این تعداد افزایش یابد، قابلیت یادگیری شبکه افزایش می‌یابد؛ ولی در مقابل پیچیدگی زمانی و محاسباتی فرایند آموزش نیز افزایش می یابد. در نهایت این تعداد وابسته به تعداد داده‌های آموزش خواهد بود و باید به‌صورت تجربی محاسبه شود.

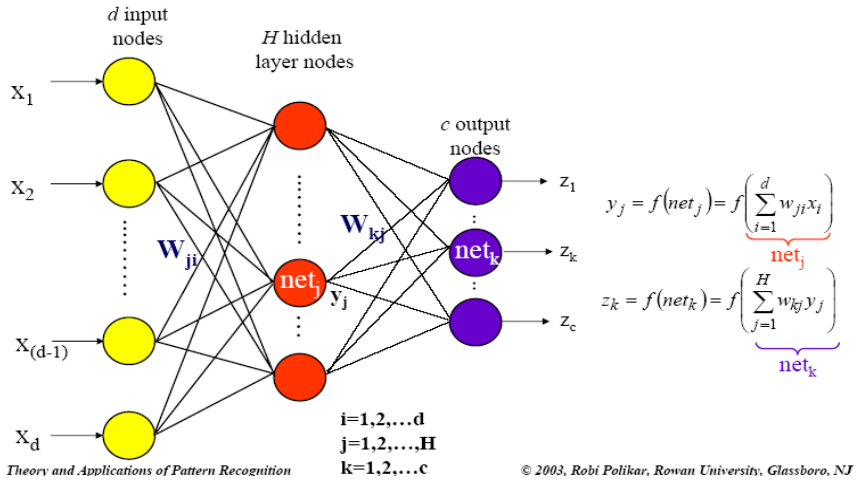

$$y_j = f(net_j) = f\left(\sum_{i=1}^{d} w_{ji} x_i\right) \quad \text{net}_j$$

$$z_k = f(net_k) = f\left(\sum_{j=1}^{H} w_{kj} y_j\right) \quad \text{net}_k$$

شکل ۱. ساختار کلی یک شبکهٔ عصبی پرسپترون چند لایه

شبکهٔ مورد استفاده در این پژوهش، شبکهٔ عصبی پرسپترون با ساختار پس‌انتشار خطاست که در شکل ۱ نمایش داده شده است. در این روش، به‌کمک داده‌های متغیرهای مستقل و با دادن وزن‌های مختلف به آن‌ها، پیش‌بینی متغیر هدف با کمینه‌سازی تابع زیان تکرار می‌شود. برای تکرار روش‌های مختلفی وجود دارد که پُرکاربردترین آن‌ها روشِ پس‌انتشارِ خطا است.

مفهوم عصب (نِرون) در شبکهٔ عصبی، برگرفته از عصب در مغز انسان است. بنابراین شبکهٔ عصبی برگرفته از رفتار میلیون‌ها نِرون در مغز انسان است. یک مدل عصب معمولی متشکل از چند بخش زیر است (شکل ۱):

۱. ورودی به‌طوری که $p_1, p_2, \dots p_n$ بیانگر نمونه‌هایی از n عصب ورودی است.

۲. وزن‌ها و آستانهٔ شبکه، $w_{1,1}, w_{1,2}, w_{1,3}, \dots, w_{1,n}$ بیانگر وزنه‌ای شبکه است که درجه اتصال بین اعصاب و ورودی ها را تعیین می‌کند. B بیانگر آستانهٔ شبکه است که به‌عنوان وزنی از یک ورودی ثابت ۱ در نظر گرفته شده است. به خاطر اینکه وزن‌ها و آستانهٔ شبکه، هر دو قابل تنظیم‌اند، اعصاب و حتی شبکهٔ عصبی قادر است که برخی از ویژگی‌ها را نشان دهد. بنابراین قابل تنظیم بودن وزن‌های عصبی و آستانه‌ها یکی از مشخصه‌های اصلی قابلیت یادگیری شبکهٔ عصبی است.

۳. واحد جمع[1]، مجموع وزن‌دار شده از سیگنال‌های ورودی را از طریق رابطهٔ ۱ انجام می‌دهد:

1. Summation

$$n = \sum_{i=1}^{n} p_i \times w_{1,i} + b$$ رابطهٔ ۱)

۴. تابع فعال‌سازی تابعی است که برای تخمین خروجی روی نِرون‌های ورودی انباشت شده در هریک از نِرون‌های لایهٔ پنهان به‌کار می‌رود. معمولاً می‌توان از تابعی خطی، لگاریتمی، تانژانت یا سیگموئید، به‌عنوان تابع فعالیت استفاده کرد. یک نمونه از به‌کارگیری تابع فعالیت، برای تخمین خروجی از طریق نِرون‌های لایهٔ ورودی، در رابطهٔ ۲ آورده شده است که در آن، f تابع فعالیت است که روی مجموع حاصل‌ضرب نِرون‌های ورودی (p) در وزن‌ها اتصال‌دهنده (w) به‌علاوهٔ بایاس (b) نگاشت شده است:

$$a = f\left(\sum_{i=1}^{n} p_i \times w_{1,i} + b\right)$$ رابطهٔ ۲)

ساختار شبکهٔ عصبی

شبکهٔ عصبی متشکل از چندین لایه است. این لایه‌ها حاوی اعصاب مختلفی‌اند. این ساختار در شکل ۲ بیان شده است. معمولاً به‌کارگیری نِرون‌های بسیار در لایهٔ پنهان، به قابلیت تطبیق و یادگیری بهتری منجر خواهد شد؛ اما حجم محاسباتی بالاتر خواهد رفت. بنابراین، انتخاب تعداد لایه و اعصاب خیلی مهم است. اکثر ساختارهای مشترک سه لایه دارند: لایهٔ ورودی، لایهٔ پنهان و لایهٔ خروجی. فرایند یادگیری و آموزش، فرایندی از تغییر ثابت وزن‌ها و آستانه است. وزن‌ها و آستانه‌های مختلف، به خروجی‌های مختلفی منجر می‌شوند. اگر خروجی‌ها مناسب نباشند، وزن‌ها و آستانه‌ها تغییر داده خواهند شد تا به هم‌گرایی[1] برسد. به خاطر ساختار و قابلیت یادگیری[2] شبکهٔ عصبی، این نوع شبکه برای مسائلی مناسب است که امکان مدل کردنشان با استفاده از روش‌های ساده و معمول نیست.

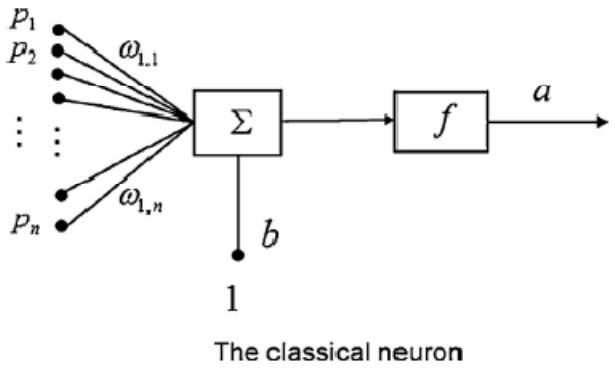

شکل ۲. ساختار معمولی عصب

1. Convergence
2. Learning

شبکهٔ عصبی بازگشتی

شبکهٔ عصبی بازگشتی، متشکل از مجموعه‌ای از شبکه‌های عصبی است که قادر بـه پـردازش داده‌هـای متـوالی اسـت. ساختار شبکهٔ بازگشتی از سه لایه تشکیل شده است: لایهٔ ورودی، لایهٔ نادیده‌انگاری اطلاعات و لایهٔ خروجی. اطلاعات مسئله از طریق لایهٔ ورودی به شبکه وارد می‌شود و سپس با استفاده از قوانین، می‌توان آن‌ها را انتخـاب کـرد. بـه بیـان دیگر قوانین موجب حفظ اطلاعات صرفاً منطبق با الگوریتم و فراموشی اطلاعات غیرمنطبق با الگوریتم مـی‌شـود. لایـه اطلاعات انتخابی توسط الگوریتم را انتقال می‌دهد و تصمیم‌گیری برای انطباق اطلاعات و در نتیجه انتخاب شدنشـان، از طریق تابع فعالیت در رابطهٔ ۳ محاسبه می‌شود. برای تأیید یا رد اطلاعات و تصمیم‌گیری برای انتقالشان بـه نِـرون‌هـای شبکهٔ عصبی، از تابع فعالیت به‌همراه عملیات ضرب استفاده می‌شود. رایج‌ترین تابع فعالیـت، مـدل سـگموئید اسـت. هـر عنصر خروجی حاصل از لایهٔ تابع فعالیت سیگموئید، در بازه [۰,۱] قرار دارد و نرمال است و میـزان انتقـال اطلاعـات بـه نِرون‌ها را در لایهٔ بعدی شبکه نشان می‌دهد؛ به‌طوری که عدد صفر، به‌معنای عدم انتقال اطلاعات و عـدد ۱، بـه‌معنـای انتقال اطلاعات است و مادامی که عدد به ۱ نزدیک‌تر باشد، درصد بیشتر انتقال اطلاعات را نشان می‌دهد. شبکهٔ عصـبی بازگشتی حاوی لایهٔ دیگر با نام تابع فعالیت تانژانت هایپربولیک است که در رابطهٔ ۴ تعریف شده است. این تابع فعالیـت مسئولیت به‌روزرسانی وضعیت نِرون‌ها را در پی دارد:

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$ رابطهٔ ۳)

$$\tanh(x) = \frac{e^{x} - e^{-x}}{e^{x} + e^{-x}}$$ رابطهٔ ۴)

لایهٔ ورودی شبکهٔ بازگشتی، تعیین‌کنندهٔ آن دسته از اطلاعاتی است کـه بایـد نادیـده گرفتـه شـود و بـه عبـارتی، مسئولیت نادیده‌گرفتن اطلاعات و عدم انتقال آن‌ها به نِرون‌های لایهٔ خروجی را برعهده دارد. همان طور که در رابطـهٔ ۵ توصیف شده است، نماد h_{t-1}، خروجی نِرون قبلی و x_t، ورودی نِرون فعلی و σ، تابع فعالیـت و w، وضـعیت نِـرون‌هـا C_{t-1} هستند که در بازه [۰,۱] قرار دارند.

$$f_t = \sigma\left(W_f . [h_{t-1} - x_t] + b_f\right)$$ رابطهٔ ۵)

لایهٔ ورودی مسئولیت تعیین میزان اطلاعاتی را دارد که باید به وضعیت نِرون افزود شود؛ به‌طوری که در ابتدا لایـهٔ ورودی که متشکل از تابع فعالیت سیگموئید است، به تعیین آن دسته از اطلاعاتی می‌پردازد که باید بـه‌روزرسـانی شـود، سپس با مراجعه به لایهٔ فعالیت تانژانت هایپربولیک، بردارهای کاندید $\hat{c}_t$ تعیین می‌شود و در نهایت تصـمیم‌گیـری بـرای وضعیت نِرون مطابق با رابطهٔ ۶ انجام می‌گیرد.

$$C_t = f_t * C_{t-1} + i_t * \hat{C}_t$$ رابطهٔ ۶)

روش محاسبهٔ پارامتر i_t و $\hat{C}_t$ براساس رابطه‌های ۷ و ۸ به‌صورت زیر خواهد بود:

$$i_t = \sigma(W_i.[h_{t-1}, x_t] + b_i)$$ رابطهٔ ۷)

$$\hat{C}_t = tanh(W_c.[h_{t-1}, x_t] + b_c)$$ رابطهٔ ۸)

برای کنترل تعداد واحدهای عصبی فعلی که باید فیلتر شوند یا کنترل تعداد واحدهای وضعیتی که باید فیلتر شوند، از رابطه‌های ۹ و ۱۰ استفاده می‌شود.

$$o_t = \sigma(W_o.[h_{t-1}, x_t] + b_o)$$ رابطهٔ ۹)

$$h_t = O_t * \tanh(C_t)$$ رابطهٔ ۱۰)

معرفی داده‌ها

همان طور که در مقدمه تشریح شد، در این پژوهش به‌منظور ارزیابی و پیش‌بینی ریسک اعتباری متقاضیان، از مدل شبکهٔ عصبی استفاده می‌شود. برای این کار، ابتدا بایستی متغیرهای توضیحی مهم اثرگذار بر متغیر وابسته یا متغیری که قصد داریم آن را پیش‌بینی کنیم، انتخاب نماییم. در این پژوهش از داده‌های مربوط به ۲۱۷۰ مورد اعتبار اعطایی از صندوق ضمانت صادرات ایران، طی دورهٔ زمانی ۱۳۸۷ تا ۱۳۹۷ استفاده شده است. متغیر وابسته نکول یا عدم نکول، اعتبار پرداختی به شخص i است. اگر اعتبار پرداختی در موعد سررسید تسویه شده باشد، مقدار عددی متغیر برابر صفر می‌شود؛ اما اگر تمام یا بخشی از اعتبار پرداختی تسویه نشده باشد، مورد مذکور نکول محسوب شده و مقدار عددی متغیر برای آن برابر ۱ می‌شود و صندوق ضمانت صادرات ایران برای آن پرونده، خسارت پرداخت کرده است. چینگ چیانگ و همکاران[1] (۲۰۱۲) معتقدند که استفاده از نظر کارشناسان بر اساس تجربه‌هایشان بهترین شیوهٔ انتخاب متغیرهاست. همچنین در مطالعه دیگری که پژوهشگران همین مقاله انجام دادند و تأیید کردند و در شمارهٔ آتی فصلنامهٔ اقتصاد مالی به چاپ خواهد رسید، از میان ۶۹ متغیر توضیحی بالقوهٔ اثرگذار بر نکول تسهیلات پرداختی که در جدول ۱ ارائه شده است، شش متغیر استان محل فعالیت اعتبار گیرنده، ذی‌نفع ضمانت‌نامه (بانک اعتبار دهنده)، تعداد کارکنان، کد نسبت جاری، نرخ سود واقعی و نرخ رشد اقتصادی، مهم‌ترین متغیرهای (دارای ضریب معنادار آماری) اثرگذار بر احتمال نکول وام با روش پروبیت انتخاب شده‌اند.

یافته‌های پژوهش

به‌منظور اجرای مدل شبکهٔ عصبی، ابتدا کلیه متغیرهای موجود در جدول ۱ در شبکهٔ عصبی استفاده شد. برای این منظور با استفاده از نرم‌افزار متلب و مدل شبکهٔ عصبی سه نوع آموزش لونبرگ، بیزین و گرادیان مزدوج شبکه آموزش داده شده است و نتایج خروجی مدل در جدول ۲ ارائه شده است.

1. Yeh, Lin & Hs

جدول ۱. متغیرهای مورد استفاده در مدل‌های پروبیت

ردیف	نام متغیر	نام اختصاری	ردیف	نام متغیر	نام اختصاری
۱	استان	X۱	۳۶	نرخ رشد درآمد ملی	X۳۶
۲	گروه کالایی	X۲	۳۷	نرخ رشد تولید ناخالص ملی به قیمت بازار	X۳۷
۳	گروه ریسک کشوری	X۳	۳۸	نرخ رشد تولید ناخالص داخلی به قیمت پایه بدون نفت	X۳۸
۴	ذی‌نفع	X۴	۳۹	نرخ رشد تولید ناخالص داخلی به قیمت پایه	X۳۹
۵	مدت اعتبار	X۵	۴۰	نرخ تورم به درصد	X۴۰
۶	نوع شرکت	X۶	۴۱	فروش خالص	X۴۱
۷	نوع فعالیت	X۷	۴۲	سود ناخالص	X۴۲
۸	تعداد پرسنل	X۸	۴۳	سود یا زیان عملیاتی	X۴۳
۹	سابقهٔ فعالیت به سال	X۹	۴۴	سود خالص	X۴۴
۱۰	مدرک تحصیلی	X۱۰	۴۵	سود انباشته	X۴۵
۱۱	شهرت صادرکننده	X۱۱	۴۶	جمع دارایی‌های جاری	X۴۶
۱۲	نوع مالکیت محل کار	X۱۲	۴۷	دارایی‌های ثابت مشهود	X۴۷
۱۳	سال‌های حضور در محل کار	X۱۳	۴۸	جمع دارایی‌های غیر جاری	X۴۸
۱۴	نوع صورت مالی	X۱۴	۴۹	جمع کل دارایی‌ها	X۴۹
۱۵	نسبت جاری	X۱۵	۵۰	کل بدهی جاری	X۵۰
۱۶	کد نسبت آنی	X۱۶	۵۱	تسهیلات بلندمدت	X۵۱
۱۷	روند فروش	X۱۷	۵۲	جمع کل بدهی	X۵۲
۱۸	نظریه مالی کارشناس	X۱۸	۵۳	سرمایه	X۵۳
۱۹	سنوات صادراتی	X۱۹	۵۴	حقوق صاحبان سهام	X۵۴
۲۰	میانگین منبع صادراتی	X۲۰	۵۵	جمع بدهی و حقوق صاحبان سهام	X۵۵
۲۱	نحوهٔ صدور	X۲۱	۵۶	نسبت جاری	X۵۶
۲۲	تعداد بازار هدف	X۲۲	۵۷	نسبت آنی	X۵۷
۲۳	تعداد ضمانت‌نامه‌های قبلی	X۲۳	۵۸	نسبت دارایی جاری	X۵۸
۲۴	نحوهٔ تسویه تعهدات	X۲۴	۵۹	نسبت مالکانه	X۵۹
۲۵	میزان ماندهٔ بدهی	X۲۵	۶۰	نسبت سود خالص	X۶۰
۲۶	گردش	X۲۶	۶۱	نسبت سود عملیاتی	X۶۱
۲۷	نرخ سود واقعی	X۲۷	۶۲	بازده فروش	X۶۲
۲۸	سود عملیاتی به حقوق صاحبان سهام	X۲۸	۶۳	بازده ارزش ویژه	X۶۳
۲۹	نسبت کل بدهی به کل دارایی	X۲۹	۶۴	بازده دارایی	X۶۴
۳۰	درصد تغییرات نرخ ارز در دورهٔ اعتبار	X۳۰	۶۵	بازده سرمایه در گردش	X۶۵
۳۱	دوره اعتبار به‌روز	X۳۱	۶۶	دوره وصول مطالبات	X۶۶
۳۲	نرخ سود تسهیلات	X۳۲	۶۷	دوره گردش کالا	X۶۷
۳۳	نوع ضمانت‌نامه (ارزی/ ریالی)	X۳۳	۶۸	دوره گردش عملیات	X۶۸
۳۴	درصد وثیقهٔ نوع اول	X۳۴	۶۹	سود عملیاتی به دارایی‌ها	X۶۹
۳۵	درصد وثیقهٔ نوع دوم	x35	۷۰		

جدول ۲. نتایج شبکهٔ عصبی بر اساس کلیهٔ متغیرهای مستقل

ردیف	نوع آموزش	تعداد نرون‌های لایهٔ پنهان	دقت کل برآوردی به درصد	حداکثر تعداد گروه‌های اعتباری متمایز
۱	لونبرگ ـ مارکوارت	۲۶	۹۴/۵	۵
۲	تنظیم بیزی	۱۰	۹۵/۵	۳
۳	گرادیان مزدوج مقیاس شده	۱۱	۹۶/۲	۵

هر یک از این مدل ها با ۱ تا ۳۰ نرون در لایهٔ پنهان آزمون شده و بهترین نتایج آن استخراج شده است. همان گونه که ملاحظه می‌شود، بر اساس مدل لونبرگ با ۲۶ نرون در لایهٔ پنهان دقت کل برآورد مدل به ۹۴/۵ درصد رسیده است. این بدان معناست که ۹۴/۵ درصد از خروجی‌های واقعی مدل، به‌خوبی برازش و برآورد شده است. به عبارتی، حدود ۹۴/۵ درصد از نتایج خروجی مدل، مطابق با واقعیت و تشخیص مدل در تفکیک مشتریان بدحساب (نکول کرده) از خوش‌حساب (تسویه کرده) موفق عمل کرده است. بر اساس مدل بیزین با تعداد ۱۰ نرون در لایه پنهان، به دقتی معادل ۹۵/۵ درصد رسیده‌ایم و در نهایت، بر اساس مدل گرادیان مزدوج با تعداد ۱۱ نرون در لایهٔ پنهان، به دقتی معادل ۹۶/۲درصد دست یافتیم که نتیجه‌ای بسیار عالی محسوب می‌شود.

جدول آشفتگی مدل گرادیان مزدوج نیز به قرار جدول ۳ است. همان گونه که ملاحظه می‌شود، تعداد ۱۸۸۸ مشتری در گروه مشتریان خوش‌حساب برازش شده است که به‌درستی در همین گروه شناسایی و قرار گرفته است. به بیان دیگر، ۸۷ درصد از تعداد کل مشتریان در گروه مشتریان خوش‌حساب، در گروه مربوط به خود و به‌درستی شناسایی شده‌اند. همچنین تعداد ۱۸۷ مشتری در گروه مشتریان بدحساب، در گروه مربوط به خود و به‌درستی شناسایی شده‌اند (۸/۶درصد). در مجموع، به‌کمک این مدل، تعداد ۲۰۸۷ مشتری از ۲۱۷۰ مشتری، یعنی معادل ۹۶/۲ درصد از مشتریان در گروه‌های خوش‌حساب و بدحساب به‌درستی شناسایی و تفکیک شده است.

جدول ۳. ماتریس آشفتگی شبکهٔ عصبی گرادیان مزدوج (با کل متغیرهای مستقل)

خروجی مدل	هدف مدل: ۰	هدف مدل: ۱	
۰	۱۸۷۹ ٪۸۶/۶	۴۹ ٪۲/۳	٪۹۷/۵ ٪۲۵
۱	۳۴ ٪۱/۶	۲۰۸ ٪۹/۶	٪۸۶ ٪۱۴
	٪۹۸/۲ ٪۱/۸	٪۸۱ ٪۱۹	٪۹۶/۲ ٪۳/۸

اما همان گونه که می‌دانیم، مدل‌های شبکهٔ عصبی برای استفاده از big data بسیار مناسب‌اند، به همین دلیل نتایج خروجی این قسمت نیز بسیار عالی به‌دست آمد. حال می‌خواهیم ببینیم که چنانچه تنها از متغیرهای مستقل حاصل شده از مدل‌های اقتصادسنجی در مدل باینری پروبیت استفاده می‌کردیم، چه نتایجی از شبکهٔ عصبی به‌دست می‌آمد. بدین

منظور، ابتدا مدل شبکهٔ عصبی را فقط بر اساس شش متغیر مستقل استخراج شده از مدل پروبیت و بر اساس سه نوع آموزش پیش‌گفته در شبکهٔ عصبی اجرا کردیم. نتیجهٔ نهایی در جدول ۴ ارائه شده است.

جدول ٤. نتایج شبکهٔ عصبی بر اساس متغیرهای مستقل مدل پروبیت

ردیف	نوع آموزش	تعداد نرون‌های لایهٔ پنهان	دقت کل برآوردی به درصد	حداکثر تعداد گروه‌های اعتباری متمایز
۱	لونبرگ ـ مارکوارت	۲۴	۸۶/۵	۴
۲	تنظیم بیزی	۳۰	۸۹/۲	۴
۳	گرادیان مزدوج مقیاس شده	۲۸	۹۰/۴	۱۰

جدول آشفتگی مدل گرادیان مزدوج نیز در جدول ۵ درج شده است. همان گونه که ملاحظه می‌شود، تعداد ۱۸۹۱ مشتری در گروه مشتریان خوش حساب برازش شده است که به‌درستی در همین گروه قرار گرفته است. به بیان دیگر ۸۷/۱ درصد از تعداد کل مشتریان، در گروه مشتریان خوش‌حساب، در گروه مربوط به خود و به‌درستی شناسایی شده‌اند. همچنین تعداد ۷۱ مشتری در گروه مشتریان بدحساب، در گروه مربوط به خود و به‌درستی شناسایی شده‌اند (۳/۳درصد). در مجموع، تعداد ۱۹۶۲ مشتری از ۲۱۷۰ مشتری، یعنی معادل ۹۰/۴ درصد از مشتریان در گروه‌های خوش‌حساب و بدحساب به‌درستی توسط مدل شناسایی شده است.

جدول ۵. ماتریس آشفتگی شبکهٔ عصبی گرادیان مزدوج (با متغیرهای مستقل مدل پروبیت)

خروجی مدل	هدف مدل: ۰	هدف مدل: ۱
۰	۱۸۹۱ ٪۸۷/۱	۱۸۶ ٪۸/۶	٪۹۱ ٪۹
۱	۲۲ ٪۱	۷۱ ٪۳/۳	٪۷۶/۳ ٪۲۳/۷
	٪۹۸/۸ ٪۱/۲	٪۲۷/۶ ٪۷۲/۴	٪۹۰/۴ ٪۹/۶

حال چنانچه نتایج شبکهٔ عصبی را بر اساس متغیرهای مستقل مدل اقتصاد سنجی پروبیت مقایسه کنیم، ملاحظه می‌کنیم که نتایج خروجی بر اساس مدل گرادیان مزدوج، مبین تفکیک مشتریان بر اساس متغیرهای مستقل مدل پروبیت از ۸ به ۱۰ گروه افزایش یافته است؛ این بدان معناست که برای رتبه‌بندی مشتریان نیز مدل شبکه‌های عصبی ارجحیت و دقت بیشتری داشته و بهتر می‌تواند مشتریان را به لحاظ رتبهٔ اعتباری و احتمال قصور دسته‌بندی کند. تفکیک مشتریان و رتبه‌بندی آن‌ها برای مدل شبکهٔ عصبی گرادیان مزدوج و بر اساس متغیرهای مستقل مدل پروبیت در شکل ۳ ارائه شده است. همان طور که ملاحظه می‌شود با حرکت از گروه اعتباری A با کمترین نسبت خسارت

(۰درصد) تا گروه اعتباری J با بیشترین نسبت خسارت (۵۳ درصد)، نسبت خسارت افـزایش یافتـه و ریسـک اعتبـاری و احتمال نکول نیز افزایش می‌یابد.

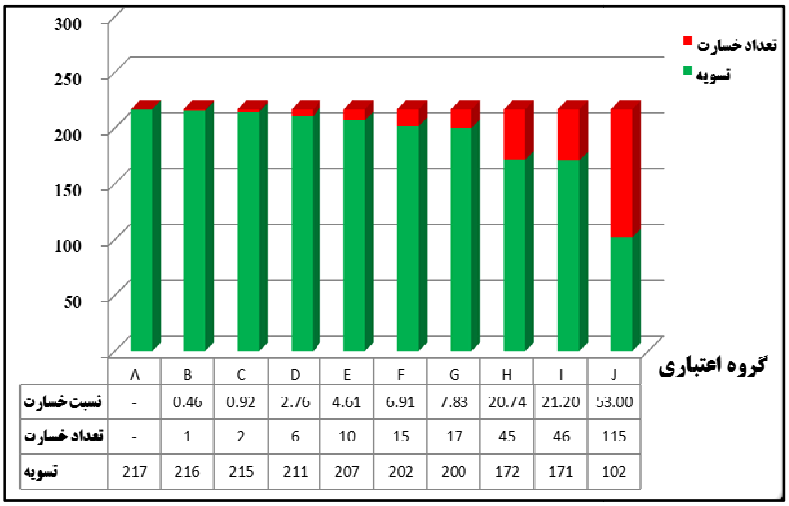

	A	B	C	D	E	F	G	H	I	J
نسبت خسارت	-	0.46	0.92	2.76	4.61	6.91	7.83	20.74	21.20	53.00
تعداد خسارت	-	1	2	6	10	15	17	45	46	115
تسویه	217	216	215	211	207	202	200	172	171	102

شکل ۳. گروه‌بندی بر اساس شبکهٔ عصبی S.C.G (متغیرهای مستقل در مدل پروبیت)

نتیجه‌گیری

در این پژوهش با استفاده از اطلاعات ۲۱۷۰ پروندهٔ اعتباری مربوط به مشتریان صندوق ضمانت صادرات ایران، ابتـدا ۶۹ متغیر مستقل درون و برون سازمانی مؤثر بر احتمال نکول تسهیلات اعطایی از سـوی ایـن صـندوق گـردآوری شـد. بـر اساس مقالهٔ قبلی در حال چاپ نویسندگان این مقاله، با استفاده از روش اقتصادسنجی پروبیـت، شـش متغیـر توضـیحی شامل استان محل فعالیت اعتبار گیرنده، ذی‌نفع ضمانت‌نامه (بانک اعتبار دهنده)، تعداد کارکنان، نسبت جاری، نرخ سـود واقعی و نرخ رشد اقتصادی، به‌عنوان مهم‌ترین متغیرهای اثرگذار بر احتمال نکول وام، به‌عنوان متغیرهای مـورد اسـتفاده در مدل شبکهٔ عصبی انتخاب شدند. سپس بر اساس مدل شبکهٔ عصبی و با استفاده از نرم‌افزار متلب با سه شیوهٔ بیـزین، لونبرگ و گرادیان مزدوج و با ۱ تا ۳۰ نرون در لایهٔ پنهان، بهترین مدل‌ها استخراج شدند. بهتـرین مـدلی کـه بـا کلیـهٔ متغیرهای مستقل (۶۹ متغیر مستقل)، پیش‌بینی‌ای با ۹۶/۲ درصد دقت داشته است کـه از مـدل اقتصادسـنجی پروبیـت بیشتر است. از سوی دیگر با استفاده از مدل شبکهٔ عصبی، متغیرهای به‌کاررفته در مدل پروبیت آزمایش شدند که ضـمن افزایش دقت تخمین مدل، تفکیک مشتریان در گروه‌های اعتباری مختلف نیز بهتر صورت پذیرفته است و از این جهـت، مطابق با تحقیقات بین‌المللی، این موضوع نیز در پژوهش حاضر تأیید شده است که مدل‌های شبکهٔ عصبی، در مقایسه با مدل‌های مرسوم اقتصادسنجی، نتایج بهتری داشته است.

شایان توجه است که بر اساس نتایج حاصل از این پژوهش مـی‌تـوان ضـمن تفکیـک مشـتریان خـوش‌حسـاب از بدحساب و بر اساس رتبهٔ اعتباری مشتریان میزان وثایق مأخوذه از مشتریان را متناسب با وضـعیت اعتبـاری گـروه‌هـای اعتباری تنظیم کرد؛ به‌طوری که اگر مشتری جزء مشتریان خوش‌حساب و با رتبهٔ اعتباری خوب باشـد، مـی‌تـوان وثـایق

کمتری از ایشان اخذ کرد و چنانچه مشتری با ریسک اعتباری بالاتری باشد، متناسب با آن از وثایق بیشتری به‌عنوان تضمین تعهد بازپرداخت استفاده کرد. در این صورت، ضمن اندازه‌گیری ریسک اعتباری و تفکیک مشتریان، می‌توان به مدیریت بهینهٔ ریسک و پرتفوی اعتباری صندوق ضمانت صادرات ایران اقدام کرد و با استفاده از نتایج این پژوهش، میزان خسارت‌های صندوق را کاهش داد و هنگام بروز خسارت نیز، از طریق وثایق، به بازیافت مطالبات دولتی با اطمینان بیشتری اقدام کرد و موجبات افزایش توانگری مالی صندوق ضمانت صادرات ایران را فراهم آورد. همچنین در تخصیص اعتبار برای صدور ضمانت‌نامه، لازم است که علاوه بر در نظرگرفتن شاخص‌های عملکردی گیرندهٔ اعتبار، دوره‌های رکود و رونق اقتصادی را با توجه به نرخ رشد اقتصادی کشور نیز در نظر گرفت و در همین راستا، در ابتدای هر سال، سیاست‌های انبساطی یا انقباضی را با توجه به نرخ رشد اقتصادی تعیین کرد. برای این منظور، ضمن تغییر مناسب سقف‌های اعتباری مشتریان در هر سال می‌توان با تعیین سهم وثایق نوع اول از کل وثایق، سیاست‌های کنترلی را برای مدیریت ریسک و کاهش خسارت‌ها در نظر گرفت. از سوی دیگر با توجه به آثار نرخ سود واقعی متأثر از نرخ تورم بر ریسک اعتباری مشتریان، لازم است تا با برآوردی از این متغیر مهم در هر سال، سیاست‌های انقباضی و انبساطی لحاظ شوند تا میزان خسارت پرداختی صندوق در چارچوب معقولی قرار گرفته و کنترل شود. پژوهش حاضر بر اساس مدل‌های پروبیت و لوجیت نشان می‌دهد، متغیرهای تعداد پرسنل، نرخ رشد اقتصادی، نسبت جاری و نرخ سود واقعی از متغیرهای مهم و مؤثر بر احتمال تسویهٔ اعتبار دریافتی دارد.

منابع

باغبانی، غزاله و اسکندری، فرزاد (۱۳۹۶). محاسبه وجه نقد مورد نیاز شعبه‌ها با استفاده از تحلیل چندمتغیره خوشه‌بندی بیزی و پیاده‌سازی آن در شبکه‌های عصبی. *تحقیقات مالی*، ۱۹(۱)، ۴۱-۶۰.

باقری، نوشین و حق‌شناس کاشانی، فریده (۱۳۹۷). ارزیابی ریسک اعتباری تعاونی‌های شهری با استفاده از روش شبکهٔ عصبی. *اقتصاد و مدیریت شهری*، ۶(۴))، ۱۷-۳۳.

پورعبادالهان کویچ، محسن؛ نوبهار، الهام و رحیمی، پریسا (۱۳۹۹). تأثیر ریسک‌های کژگزینی و کژمنشی بر مطالبات غیرجاری سیستم بانکی ایران. *اقتصاد پولی مالی*، ۲۷(۲۰)، ۲۷-۴۶.

جلیلی، محمد (۱۳۸۹). سامانه اعتبارسنجی مشتریان بانکی، بیمه‌ای، مطالعه موردی: تجربه شرکت مشاوره رتبه‌بندی ایرانیان. *فصلنامه پول و اقتصاد*، ۴(۸۹)، ۲۲۱-۲۴۱.

حسینی، سید عبدالخالق و زیبایی، منصور (۱۳۹۴). مدیریت ریسک اعتباری در بانک کشاورزی شهرستان ممسنی با استفاده از مدل شبکهٔ عصبی. *اقتصاد کشاورزی (اقتصاد و کشاورزی)*، ۹(۲)، ۱۰۳- ۱۱۹.

خرمی، امیر؛ تقوی فرد، محمدتقی و خاتمی فیروزآبادی، محمدعلی (۱۳۹۹). ارزیابی ریسک اعتباری متقاضیان تسهیلات بانکی به روش استدلال مبتنی بر مورد (CBR). *مطالعات مدیریت صنعتی*، ۱۸(۵۹)، ۷۹-۱۱۶.

روح الامینی، مهدی؛ ششمانی، مجید و خرم، مهدی (۱۳۹۴). رتبه‌بندی اعتباری مشتریان حقیقی در بانک‌های تجاری با رویکرد هوش مصنوعی. *کنفرانس بین‌المللی پژوهش‌های نوین در مدیریت، اقتصاد و حسابداری*.

شوال‌پور، سعید و اشعری، الهام (۱۳۹۲). بررسی تأثیر ریسک اعتباری بر سودآوری بانک ها در ایران. *تحقیقات مالی*، ۱۵(۲)، ۲۲۹-۲۴۶.

کردبچه، حمید و پردل نوش‌آبادی، لیلا (۱۳۹۰). تبیین عوامل مؤثر بر مطالبات معوق در صنعت بانکداری ایران. *فصلنامه پژوهش‌های اقتصادی ایران*، ۱۶(۴۹)، ۱۱۷- ۱۵۰.

عباسیان، عزت‌اله؛ ابراهیمی، محسن و فرزانگان، الهام (۱۳۹۴). طراحی بهینه اوراق بهادارسازی در رابطه کارفرما ـ کارگزار براساس رویکرد استنباط بیزین از مخاطره اخلاقی. *تحقیقات مالی*، ۱۷(۱)، ۱۲۳-۱۴۰.

فلاح پور، سعید و حکیمیان، حسن (۱۳۹۸). بهینه‌سازی استراتژی معاملات زوجی با استفاده از روش یادگیری تقویتی با به کارگیری دیتاهای درون‌روزی در بورس اوراق بهادار تهران. *تحقیقات مالی*، ۲۱(۱)، ۱۹-۳۴.

قاسمی، احمدرضا و دنیایی هریس، طاهره (۱۳۹۵). اندازه‌گیری ریسک اعتباری مشتریان با رویکرد شبکهٔ عصبی در یکی از بانک‌های دولتی. *مهندسی مالی و مدیریت اوراق بهادار (مدیریت پرتفوی)*، ۷(۲۷)، ۱۵۵-۱۸۱.

قدسی پور، سیدحسن؛ سالاری، میثم و دلاوری، وحید (۱۳۹۱). ارزیابی ریسک اعتباری شرکت‌های وام‌گیرنده از بانک با استفاده از تحلیل سلسله‌مراتبی فازی و شبکهٔ عصبی ترکیبی درجه بالا. *نشریه بین‌المللی مهندسی صنایع و مدیریت تولید (نشریه بین‌المللی علوم مهندسی)*، ۲۳(۱)، ۴۴-۵۴.

مهرآرا، محسن و بهلولوند، الهه (۱۳۹۵). عوامل موثر بر ریسک اعتباری بانک‌ها در ایران. *مطالعات و سیاست‌های اقتصادی*، ۱۱(۵۶)، ۲-۲۷.

نادعلی زاده، آمنه؛ هژبر کیانی، کامبیز؛ حسینی، شمس‌الدین و پیکارجو، کامبیز (۱۴۰۰). عدم تقارن آثار تکانه‌های قیمت نفت بر ریسک اعتباری بانک‌ها در ایران. *پژوهش‌های اقتصادی (رشد و توسعه پایدار)*، ۲۱(۱)، ۶۳-۹۲.

نظرپور، محمد نقی و اولاد، مریم (۱۳۹۷). اولویت‌بندی عوامل مؤثر بر کژگزینی و کژمنشی در بانکداری بدون ربا (مطالعه موردی: بانک صنعت و معدن). *اقتصاد اسلامی*، ۱۸(۶۹)، ۱۷۳-۱۹۹.

نیلساز، حمید؛ راسخ، عبدالرحمان؛ عصاره، علیرضا و سینایی، حسنعلی (۱۳۸۶). کاربرد شبکه‌های عصبی در رتبه‌بندی اعتباری فروش اقساطی متقاضیان وام. *پژوهش‌های اقتصادی ایران*، ۹(۳۲)، ۸۵-۱۰۹.

References

Abbasian, E., Ebrahimi, M., & Farzanegan, E. (2015). Optimal design of securitization in a principal-agent relationship based on Bayesian inference for moral hazard. *Financial Research Journal*, *17*(1), 123-140. doi: 10.22059/jfr.2015.50708 (*in Persian*)

Angelini, E., Di Tollo, G., & Roli, A. (2008). A neural network approach for credit risk evaluation. The quarterly review of economics and finance, 48(4), 733-755.

Baghbabi, G., & Eskandari, F. (2017). Estimation of Input & Output Cash of Tejarat Branches in order to Calculate Branches' Required Cash Via Multivariate Bayesian Clustering Analysis and the Implementation in Neural Network. *Financial Research Journal*, *19*(1), 41-60. doi: 10.22059/jfr.2017.60152 (*in Persian*)

Bagheri, N. & Haghshenas Kashani, F. (2018). Credit Risk Assessment of Urban Cooperatives Using Neural Network Method. *Journal of Urban Economics and Management*, 6 (24), 17-33. (*in Persian*)

Bekhet, H. A., & Eletter, S. F. K. (2014). Credit risk assessment model for Jordanian commercial banks: Neural scoring approach. *Review of Development Finance*, 4(1), 20-28.

Binici, M. & Hutchison, M. (2018). Do credit rating agencies provide valuable information in market evaluation of sovereign default Risk? *Journal of International Money and Finance,* 85, 58-75.

Dendramis, Y., Tzavalis, E. & Adraktas, G. (2018). Credit risk modelling under recessionary and financially distressed conditions. *Journal of Banking & Finance*, 91, 160-175.

Fallahpour, S. & Hakimian, H. (2019). Paired Trading Strategy Optimization Using the Reinforcement Learning Method: Intraday Data of Tehran Stock Exchange. *Financial Research Journal*, *21*(1), 19-34. doi: 10.22059/frj.2018.138913.1006099 (*in Persian*)

Ghasemi, A.R. & Donyaee, T. (2016). Assessing Credit Risk Rating With Artificial Neural Network Method (The Case of an Iranian Bank). *Financial Engineering and Securities Management (Portfolio Management),* 7(27), 155-181. (*in Persian*)

Ghodsypour, S.H., Salari, M. & Delavari, V. (2012). Using Fuzzy Analytic Hierarchy Process and Hybrid of Higher Order Neural Network for Evaluation Credit Risk of Corporate. *International Journal of Industrial Engineering and Production Management (International Journal of Engineering Science),* 23(1), 44-54. (*in Persian*)

Hosseini, S. A. & & Zibaei, M. (2015). Credit risk management in agricultural bank of mamasani using neural network model. *Iranian Journal of Agricultural Economics (Economics and Agriculture Journal)*, 9(2), 103-119. (*in Persian*)

Khashman, A. (2009). A neural network model for credit risk evaluation. International Journal of Neural Systems, 19(04), 285-294.

Khashman, A. (2010). Neural networks for credit risk evaluation: Investigation of different neural models and learning schemes. Expert Systems with Applications, 37(9), 6233-6239.

Khorrami, A., Taghavifard, M. T., & Khatami Firouzabadi, S. M. A. (2020). Credit Status Assessment of Bank Loan Applicants Using CBR Method. *Industrial Management Studies*, *18*(59), 79-116. doi: 10.22054/jims.2018.18574.1660 (*in Persian*)

Nadalizadeh, A., Hojabr Kiani, K., Hoseini, Sh., Peykarjou, K. (2021). The Asymmetric Effects of Oil Price Shocks on Bank Credit Risk in Iran. *QJER*, 21(1), 63-92. (*in Persian*)

Nazarpur, M. N. & Oulad, M. (2018). Prioritizing Influenced Factors on adverse selection and moral hazard in Usury Free Banking (Case study: Bank of Industry and Mining). *Islamic Economics*, *18*(69), 173-199. (*in Persian*)

Nilsaz, H., Rasekh, A., Osareh, A., & Sinae, H. (2007). Using Neural Networks to Classify the Personal Loan Applicants. *Iranian Journal of Economic Research*, *9*(32), 85-109. (*in Persian*)

Pourebadollahan Covich, M., Nobahar, E. & Rahimi, P. (2021). The Impact of Adverse Selection and Moral Hazard on Non-performing Loans of Iran's Banking System. *Monetary & Financial Economics*, 27(20), 27- 46. (*in Persian*)

Shavvalpour, S. & Ashari, E. (2013). Determining the Relationship between Credit Risk & Profitability in Iranian Banks. *Financial Research Journal*, *15*(2), 229-246. doi: 10.22059/jfr.2013.51079 (*in Persian*)

Sindhuraj, I. C. G. L., & Patrick, A. J. (2023). Loan eligibility prediction using adaptive hybrid optimization driven-deep neuro fuzzy network. *Expert Systems with Applications*, 224, 119903.

Yeh, C. C., Lin, F. & Hsu, C. Y. (2012). A hybrid KMV model, random forests and rough set theory approach for credit rating. *Knowledge-Based Systems*, 33, 166-172.

Zhang, X., Ma, Y. & Wang, M. (2023). An attention-based Logistic-CNN-BiLSTM hybrid neural network for credit risk prediction of listed real estate enterprises. *Expert Systems*, e13299.