

Providing a comprehensive model to measure the liquidity risk of banks admitted to the Tehran Stock Exchange (case study: Bank Mellat)

Toora Azari Gargari

Assistant Professor, School of Management and Accounting, Kish International Branch, Islamic Azad University, Kish, Iran (Corresponding author).
toorajazari23@gmail.com

Mojtaba Dasturi

Professor, Faculty of Management and Accounting, University of Tehran, Tehran, Iran.

dastoori@ut.ac.ir

Reza Tehrani

Assistant professor, School of Management and Accounting, Kish International Branch, Islamic Azad University, Kish, Iran.

rtehrani@ut.ac.ir

Abstract

Lack of liquidity management of banks is one of the most important risks for any bank and if less attention is paid to liquidity risk, it may lead to irreparable consequences; Preventing liquidity risk requires a comprehensive measurement method but liquidity risk is complicated issue, and this complexity makes it difficult to provide a proper definition. In addition, defining liquidity risk determinants and formulation of the related objective function to measurement its value is a difficult task. To address these problems, in this study we propose a model that uses artificial neural networks and Bayesian networks. Design and implementation of this model includes several algorithms and experiments to validate the proposed model. In this paper, we have used Lunberg-Marquardt and Genetic optimization algorithms to teach artificial neural networks. We have also implemented a case study in Bank Mellat to demonstrate the feasibility, efficiency, accuracy and flexibility of the research liquidity risk measurement model.

Keywords: liquidity risk, banking industry, ANN, Bayesian network.

JEL Classification: E58, G24, G21, C02

مدلسازی ریسک نقدینگی بانک‌های پذیرفته‌شده در بورس اوراق بهادار تهران با استفاده از شبکه‌های عصبی مصنوعی و شبکه‌های بیزی (مطالعه موردی: بانک ملت)

تورج آذری گرگری

دانشجوی دکتری، دانشکده مدیریت - حسابداری، واحد بین‌الملل کیش، دانشگاه آزاد اسلامی، کیش،
teorajazari23@gmail.com (نویسنده مسئول).

مجتبی دستوری

استاد، دانشکده مدیریت و حسابداری، دانشگاه تهران، تهران، ایران. dastoori@ut.ac.ir

رضا تهرانی

استادیار، دانشکده مدیریت - حسابداری، واحد بین‌الملل کیش، دانشگاه آزاد اسلامی، کیش، ایران.
rtehrani@ut.ac.ir

چکیده

در صورت مدیریت نادرست یا عدم کنترل ریسک نقدینگی در یک بانک، امکان بروز صدمه‌های مالی و اعتباری و حتی ورشکستگی بانک به‌وجود می‌آید. در این مقاله روشی را پیشنهاد کرده‌ایم که از روش‌های بروز در یادگیری ماشین استفاده می‌کند و برای مقابله با این مشکلات، مدلی را پیشنهاد می‌کنیم که از شبکه‌های عصبی مصنوعی و بیزی استفاده می‌کند. متغیرهای مدل نسبت‌های نقدینگی هستند و از طریق داده‌های ترازنامه استاندارد بانکی به‌راحتی در دسترس هستند. طراحی و اجرای این مدل پیشنهادی شامل چندین الگوریتم و آزمایش جهت اعتبارسنجی مدل است. به عنوان تعریف ریسک نقدینگی بر روی مفهوم توانایی پرداخت تمرکز کرده‌ایم. همچنین یک مطالعه موردی در بانک ملت با استفاده از داده‌های صورت‌های مالی این بانک بین سال‌های ۱۳۹۰ تا ۱۳۹۶، برای نشان دادن قابلیت اجرا، کارایی، دقت و انعطاف‌پذیری مدل اندازه‌گیری ریسک نقدینگی تحقیق، پیاده‌سازی کرده‌ایم. نتایج عددی به‌دست‌آمده در مطالعه موردی نشان می‌دهد که روش هوشمند دو فازی پیشنهادی توانایی تأیید نتایج از طریق اجرای مستقل و موازی مجموعه داده‌های مشابه را دارا می‌باشد.

کلیدواژه‌ها: ریسک نقدینگی، صنعت بانکداری، شبکه عصبی مصنوعی، شبکه بیزی.

طبقه‌بندی JEL: E58, G24, G21, C02

تاریخ دریافت: ۱۴۰۰/۰۶/۱۹ تاریخ بازبینی: ۱۴۰۲/۰۲/۱۸ تاریخ پذیرش: ۱۴۰۲/۰۳/۲۳

فصلنامه راهبرد اقتصادی، سال ۱۱، شماره ۳، پیاپی ۴۲، پاییز ۱۴۰۱، صص ۵۷-۸۴

مقدمه و بیان مسئله

امروزه با اختصاص یافتن حجم زیاد منابع مالی توسط بانک‌های متعدد جهان، شاهد ایجاد بحران، زیان و حتی ورشکستگی‌های بانک‌های متعددی هستیم. بانک‌های سراسر دنیا به علل مختلفی از قبیل ریسک یا هزینه‌های ناشی از تغییرهای نرخ ارز، نرخ بهره، تورم و یا عدم بازپرداخت تسهیلات اعطایی، با چالش‌های زیادی مواجه می‌شوند. بحران‌های اقتصادی، مسئولان دستگاه‌های نظارتی و اجرایی نظام‌های مالی را ملزم به مدیریت تخصصی ریسک نهادهای مالی و به‌ویژه بانک‌ها کرده است. ریسک نقدینگی از شایع‌ترین ریسک‌هایی است که بانک‌ها با آن مواجه‌اند و مدیریت صحیح نقدینگی جهت از دست رفتن فرصت‌های سرمایه‌گذاری، بهره‌گیری از نقدینگی اضافی برای سرمایه‌گذاری و اعطای تسهیلات جدید برای بازدهی بالاتر، آمادگی برای مواجهه با شرایط بحرانی و کسری منابع نقد، از اهمیت بالایی برخوردار است. برای مدیریت صحیح نقدینگی، شناسایی ابزار مناسب و عوامل مؤثر ضروری است. یکی از مهم‌ترین عوامل مؤثر بر نقدینگی بانک‌ها، موقعیت دارایی و بدهی‌های آنها است. از طرفی، مدیریت دارایی و بدهی از عوامل حیاتی در شرح پایداری مالی بخش بانکی و اقتصاد است (Jaiswal, 2018).

در فعالیت‌های بانکی معمولاً سررسید تعهدهای اعطایی، بلندمدت‌تر از سررسید سپرده‌ها یا بدهی‌ها می‌باشد که این عدم هماهنگی در سررسید پرداخت‌ها و دریافت‌ها احتمال عدم توان پرداخت‌های بانک در سررسیدهای مختلف را به وجود می‌آورد و می‌تواند موجب از دست رفتن حُسن شهرت بانک‌ها و ورشکستگی آنها گردد. از سوی دیگر مازاد نقدینگی منجر به عدم استفاده بانک از دارایی‌های مولد و فرصت‌های موجود برای سرمایه‌گذاری می‌شود که موجب تضییع حقوق سپرده‌گذاران و سهامداران خواهد شد؛ بنابراین مدیریت نقدینگی و نظارت بر عدم تطابق سررسید سپرده‌ها و وام‌ها اصلی‌ترین نگرانی مدیران بانک‌ها می‌باشد. وظیفه مدیریت هنگامی که بانک با برداشت‌های زود هنگام روبه‌رو می‌شود، مهم‌تر است، چراکه سپرده‌های کوتاه‌مدت، اصلی‌ترین منابع مالی بانک‌ها هستند و وام‌ها نیز معمولاً برای بانک با ریسک نقدشوندگی همراه می‌باشد (Vento & Ganga, 2009). نقدینگی بیش‌از حد باعث تخصیص ناکارآمد منابع می‌شود، درحالی‌که نقدینگی کم می‌تواند منجر به کاهش نرخ

سود سپرده‌ها، ازدست‌دادن بازار و اعتبار، افزایش بدهی‌ها و درنهایت شکست بانک شود؛ بنابراین مدیریت و ارزیابی ریسک نقدینگی بسیار مهم است. ریسک نقدینگی به مجموعه پیچیده‌ای از عوامل از جمله خسارت قابل توجه ریسک عملیاتی، کاهش کیفیت اعتبار، تکیه بیش‌ازحد به استقراض کوتاه‌مدت، ریسک بازار و غیره مربوط می‌شود (Marz, 2007). لذا اندازه‌گیری ریسک نقدینگی بانک‌ها می‌تواند مدیران و تصمیم‌گیرندگان بانک‌ها را در جهت بهینه کردن میزان نقدینگی کمک کند و از اهمیت بسیار بالایی برخوردار است. هدف اصلی این مقاله طراحی یک سیستم عملی بر اساس داده‌های خام ترازنامه بانکی برای هشدار ریسک نقدینگی می‌باشد. امروزه روش‌های یادگیری ماشین در پایگاه داده‌های بزرگ می‌توانند به نتایج دقیق منجر شوند و می‌توانیم از این روش‌ها برای اندازه‌گیری ریسک نقدینگی بانک و تحلیل عوامل اصلی آن استفاده کنیم. این روش‌ها علی‌رغم قابلیت‌های گسترده در مدل‌سازی شرایط واقعی و پیش‌بینی نتایج آنی به کمک داده‌های دقیق یا ناقص، در ادبیات موضوع برای اندازه‌گیری ریسک نقدینگی بانک بسیار محدود به کار رفته‌اند. در این مقاله، به تعریف ریسک نقدینگی با تمرکز بر مفهوم قدرت پرداخت برای طراحی مدلی جهت پیش‌بینی ریسک نقدینگی مبتنی بر وام می‌پردازیم. این مدل از شبکه‌های عصبی مصنوعی^۱ و شبکه‌های بیزی^۲ برای ارزیابی ریسک نقدینگی و عوامل کلیدی آن استفاده می‌کند. روش ارزیابی حاصل شامل استفاده از الگوریتم ژنتیک^۳ و آزمایش‌های متعدد برای آموزش شبکه‌های مذکور جهت تجزیه و تحلیل داده‌هاست. برای اعتبارسنجی روش ارزیابی ریسک پیشنهادی، یک مطالعه موردی بر اساس صورت‌های مالی واقعی «بانک ملت» از قبیل ترازنامه و صورت سود و زیان از سال ۱۳۹۰ تا ۱۳۹۶، ارائه شده است. در ادامه این مقاله، ابتدا مطالعات نظری و ادبیات موضوع و سپس مدل پیشنهادی ارائه شده است و درنهایت این مدل توسط داده‌های ذکر شده حل و کارآیی آن تعیین شده است.

۱. مطالعات نظری و ادبیات موضوع

ریسک نقدینگی عبارت است از ریسک ناشی از نبود نقدینگی لازم جهت پوشش تعهدهای کوتاه‌مدت و خروجی‌های غیرمنتظره وجوه. به عبارت دیگر، ریسک نقدینگی عدم توانایی بانک در تأمین وجوه برای اعطای تسهیلات یا پرداخت به‌موقع دیون

1. Artificial Neural Networks (ANN)
2. Bayesian Network (BN)
3. Genetic Algorithm (GA)

خود نظیر سپرده‌ها است (Tripe, 1999). این ریسک عمدتاً از ساختار دارایی‌ها و بدهی‌های بانک‌ها ناشی می‌شود و منشأ اصلی آن، عدم تطابق زمانی بین جریان‌های ورودی و خروجی به بانک است؛ از این رو ریسک نقدینگی را می‌توان به دو دسته ریسک نقدینگی دارایی‌ها و منابع تقسیم نمود (Crouhy & et al., 2000). ریسک نقدینگی دارایی‌ها به عدم توانایی بانک در فروش دارایی‌های خود جهت برآوردن نیازهای نقدی غیرمنتظره اشاره دارد. ریسک نقدینگی منابع نیز به عدم جذب منابع توسط بانک به طریق عادی باز می‌گردد (اسدی‌پور، ۱۳۸۴). کمیته نظارت بر بانکداری بازل با هدف ارتقا توانمندی بانک‌ها در تأمین نقدینگی خود در سال ۲۰۱۰ استانداردی جهت مدیریت ریسک نقدینگی تحت عنوان «نسبت پوشش نقدینگی^۱» منتشر کرد. این نسبت برای بررسی اینکه آیا بانک دارای دارایی‌های نقدشونده با کیفیت بالایی جهت پوشش نیازهای کوتاه مدت خود می‌باشد یا خیر، استفاده می‌شود و به شرح زیر است (Papadamou & et al., 2021):

$$LCR = \frac{\text{ذخیره دارایی‌های با کیفیت نقد شوندگی بالا}}{\text{جریان مالی خروجی 30 روز آینده}}$$

دومین استاندارد معرفی شده توسط کمیته بازل، «نسبت تأمین مالی پایدار خالص^۲» است. این نسبت بیانگر میزان موفقیت در نحوه تأمین مالی عملیات بانکی با منابعی بایاتر است و هدف آن، ترویج تأمین مالی میان‌مدت و بلندمدت برای بانک‌ها و به شرح زیر است (Papadamou & et al., 2021):

$$NSFR = \frac{\text{منابع پایدار قابل دسترس}}{\text{منابع پایدار مورد نیاز}}$$

یکی از روش‌های تعریف و اندازه‌گیری ریسک نقدینگی استفاده از مدل نقدینگی تعدیل شده توسط ریسک سیستمی است. این مدل نظریه قیمت‌گذاری انتخابی را با اطلاعات بازار و داده‌های ترازنامه ترکیب می‌کند تا اندازه‌گیری احتمالی ریسک نقدینگی نظام‌مند را ایجاد کند (Jobst, 2014). یک روش جایگزین برای شناسایی و تحلیل ریسک نقدینگی، تخمین «تابع توزیع احتمال» آن است. رویکردی دیگر بر اساس مفهوم جریان‌های ورودی و خروجی مطابق با محدودیت جریان زیر است و بیانگر آن است که بانکی که دارای نقدشوندگی است یعنی توانایی تأمین تقاضای پول را دارد، به شرطی که در هر برهه از زمان خروجی آن از مجموع ورودی و موجودی مالی آن کمتر یا برابر باشد (Nikolaou & Drehmann, 2009):

1. Liquidity Coverage Ratio (LCR)
2. Net Stable Funding Ratio (NSFR)



Outflow $s_t \leq$ Inflow $s_t +$ Stock of money

متأسفانه تعداد مقاله‌هایی که عوامل ایجادکننده ریسک نقدینگی را تحلیل می‌کنند، اندک است. اندکی از محققان از شاخص‌های ترازنامه به‌عنوان عوامل تعیین‌کننده ریسک نقدینگی استفاده کرده‌اند. دهقانی احمدآباد و سعیدی کوشا (۱۳۹۹)، با تعریف شاخص نیاز نقدینگی به کمی‌سازی زیان ریسک نقدینگی با مدل‌های فرایند تصادفی پرداختند. هدف اصلی آنها، برآورد ارزش در معرض خطر و ارزش در معرض خطر شرطی زیان ناشی از ریسک نقدینگی در یکی از بانک‌های تجاری منتخب بوده است. بزرگ اصل؛ برزیده و صمدی (۱۳۹۷)، به بررسی رابطه توأم ریسک اعتباری و ریسک نقدینگی بانک‌ها و تأثیر آنها بر پایداری مالی در صنعت بانکداری ایران به روش پانل دیتا پرداخته و برای بررسی تأثیر ریسک‌های نقدینگی و اعتباری بر پایداری مالی از روش رگرسیون چندک استفاده شده است. اسماعیل زاده و جوانمردی (۱۳۹۶) بیان داشتند که چالش اصلی مدیریت ریسک نقدینگی، تأمین وجوه در زمان بروز بحران در سازمان‌ها و نهادهای مالی در عرصه فعالیت‌های اقتصادی است و موضوع مدیریت ریسک نقدینگی در بانک صادرات ایران را بر اساس الگوی آریما ارزیابی کردند. کفائی و راهزانی (۱۳۹۵) به بررسی تأثیر عدم اطمینان کلان اقتصادی بر ریسک نقدینگی با استفاده از مدل‌سازی واریانس ناهمسان شرطی تعمیم‌یافته و مدل نامتقارن واریانس ناهمسان شرطی و روش داده‌های تابلویی مبتنی بر داده‌های فصلی تعدادی بانک فعال در ایران پرداختند. صبری و همکاران^۱ (۲۰۲۰)، به بررسی ریسک نقدینگی در بانک‌های اسلامی و مقایسه آن با بانک‌های متداول تجاری با استفاده از یک مدل رگرسیون داده پانل با روش اثر تصادفی پرداختند. چن و همکاران^۲ (۲۰۱۸)، برای بررسی فاکتورهای ریسک نقدینگی بانک با استفاده از یک مجموعه داده پانل نامتعادل از بانک‌های تجاری در تعدادی از کشورهای پیشرفته، از یک روش اندازه‌گیری ریسک نقدینگی استفاده کردند. باتوجه به مقاله اسکانالا^۳ (۲۰۱۶) ریسک نقدینگی نیازی به پوشش حقوق صاحبان سهام ندارد بلکه نیاز به حجم کافی از دارایی نقدینگی و اوراق بهادار نقد دارد. به‌همین دلیل تنظیم ریسک نقدینگی در بانکداری بر نقدینگی مبتنی بر محدودیت‌های مالی تمرکز دارد. رحمان و بنا^۴ (۲۰۱۶)، صنعت بانکداری بنگلادش را با تمرکز بر مدیریت ریسک نقدینگی

1. Sabri & et al.

2. Chen & et al.

3. Scannella

4. Rahman & Banna

بانک‌ها بررسی کردند. آنها به مقایسه عوامل مؤثر بر ریسک نقدینگی در بانک‌های متعارف و بانک‌های اسلامی فعال در بنگلادش پرداختند. باسی و موسیس^۱ (۲۰۱۵)، نشان دادند که رابطه‌ای معنادار بین نسبت مقدار نقدینگی به جریان آن، در بانک، نسبت نقدینگی، نسبت وجوه نقد، نسبت وام به سپرده، نسبت وام به دارایی و بازده حقوق صاحبان سهام وجود دارد. کنولووا و زارمبو^۲ (۲۰۱۵) به بررسی مدیریت ریسک نقدینگی نامتوازن در بانک‌های بازرگانی لتونی و لیتوانی پرداخته و دریافتند که بانک قادر به جمع‌آوری منابع خود از طریق جذب سپرده اضافی در نرخ بهره بالاتر و یا با استفاده از فروش دارایی‌های دیگر می‌باشد و منبع دیگری از ریسک نقدینگی، حساسیت بانک به نوسانات در نرخ بهره است.

علی‌رغم قابلیت‌های فراوان ANN و BN، در مسائل اندازه‌گیری ریسک نقدینگی به‌ندرت از شیوه‌های یادگیری ماشین یا ترکیبی از آنها استفاده شده است؛ بنابراین نوآوری مقاله حاضر در راستای تکمیل خلأ موجود در ادبیات موضوع یعنی استفاده از سیستم‌های هوشمند در مسائل غیرقطعی می‌باشد.

۲. متغیرهای ورودی مدل

با توجه به مدل مبتنی بر وام، باید عوامل مرتبط با وام از جمله مجموع وام، مجموع سپرده، سپرده فرار، دارایی نقدشونده، اعتبار در بانک مرکزی استفاده شود. این موارد با آستانه‌های مشخصی که توسط متخصصان تعیین می‌شود می‌توانند به نسبت تبدیل شوند. این نسبت‌ها می‌توانند به‌عنوان شاخص‌های ریسک نقدینگی و متغیرهای ورودی مدل استفاده شوند. شاخص‌ها/ متغیرهای ورودی که برای مدل انتخاب کرده‌ایم عبارت‌اند از:

$$\begin{aligned}
 X_1 &= \frac{\text{داراییهای نقدشونده } B}{\text{بدهیهای جاری } B} & X_2 &= \frac{\text{اعتبارهای } B \text{ در } O}{\text{داراییهای نقدشونده } B} \\
 X_3 &= \frac{\text{سپرده های بلندمدت } B}{\text{سپرده های کوتاه مدت } B} & X_4 &= \frac{\text{اعتبارهای } B \text{ در } O}{\text{اعتبارهای } O \text{ در } B} \\
 X_5 &= \frac{\text{مجموع وام } B}{\text{مجموع سپرده های } B} & X_6 &= \frac{\text{اوراق قرضه } B}{\text{مجموع دارایی های } B} \\
 X_7 &= \frac{\text{سپرده های فرار } B}{\text{مجموع بدهی های } B} & X_8 &= \frac{\text{سرمایه گذاری کوتاه مدت } B}{\text{مجموع دارایی های } B}
 \end{aligned}$$

1. Bassey & Moses
2. Konovalova & Zarembo

$$X_9 = \frac{\text{اعتبارهای } B \text{ در بانک مرکزی}}{\text{مجموع سپرده های } B}$$

B برای نشان دادن «بانک ملت» و O برای نشان دادن «سایر بانک‌ها» استفاده می‌شود.

۱-۲. متغیر خروجی

متغیر خروجی باید معیار ریسک نقدینگی را برای بانک (B) فراهم کند. بهترین گزینه برای این اندازه‌گیری، جریان خالص وجه نقد B می‌باشد. با این حال، برای محاسبه این مقدار باید تمام ورودی‌ها و خروجی‌ها را مشخص کنیم و عدم تطابق سررسید را در نظر بگیریم. متأسفانه، به دلیل حساب‌های متعدد و متنوع و حجم گسترده مبادلات، دستیابی به این داده‌ها در مدت زمان کوتاه غیرممکن است؛ بنابراین در این مقاله، ریسک نقدینگی بانک به عنوان عدم توانایی B در پرداخت بدهی‌های موجود تعریف شده است و با استفاده از نسبت جاری اندازه‌گیری می‌شود:

$$X_{10} = \frac{\text{دارایی های جاری } B}{\text{بدهی های جاری } B} = \text{نسبت جاری}$$

۲-۲. تابع ریسک نقدینگی

نسبت جاری نشان‌دهنده مسئولیت‌های B در مقابل اعتبار آن است و مقدار نرمال حداقل ۱ را به خود اختصاص می‌دهد. لذا هنگامی که نسبت کنونی از این مقدار شروع به کاهش می‌کند، ریسک آشکار می‌شود. لذا، ریسک نقدینگی با استفاده از تابع زیر فرموله می‌شود:

$$L(X_{10}) = \begin{cases} 1 - x_1 & \text{if } x_1 < 1, \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

نسبت کل دارایی‌ها و کل بدهی‌ها در مقایسه با سایر رویکردهای ارزیابی ریسک نقدینگی در ادبیات موضوع، از معدود نسبت‌های مبتنی بر وام است که در حال حاضر به‌عنوان شاخص‌هایی برای اندازه‌گیری ریسک نقدینگی استفاده می‌شود. سایر نسبت‌هایی مانند LCR و NSFR که در بخش‌های مقدماتی ذکر شد، بسیار پیچیده‌اند و اجرای آنها در نظام بانکی عملی نیست. چراکه این نسبت‌ها شامل برخی از اوزان مربوط به جریان ورودی و خروجی است که به راحتی قابل محاسبه نیست؛ بنابراین در واقع هیچ مدل قابل اجرا دیگری برای مقایسه مدل حاضر وجود ندارد.

۳. مدل پیشنهادی

۳-۱. معرفی رویکرد دوفازی شبکه‌های عصبی مصنوعی و بیزی

در این مقاله رویکرد پیشنهادی شبکه عصبی مصنوعی و بیزی دو فاز مکمل را تشکیل می‌دهند: درحالی که ANN برای تقریب روند کلی ریسک و یافتن دو مورد از تأثیرگذارترین عوامل به روشی غیرکارآمد استفاده می‌شود، BN تأثیرگذارترین عامل را پیدا می‌کند و احتمال وقوع ریسک نقدینگی را تعیین می‌کند. نتایج ریسک نقدینگی حاصل از ANN با آنچه توسط BN به دست می‌آید تکمیل می‌شود. شایان ذکر است که پیاده‌سازی ANN مستقل از BN است و استفاده از خروجی یک شبکه به‌عنوان ورودی برای شبکه دیگر امکان‌پذیر نیست.

۳-۲. پارامترهای کلیدی و نقش آنها در فرایند یادگیری

در مدل مقاله ما، دو مجموعه پارامتر داریم: (۱) مجموعه‌ای از اوزان در ANN و (۲) مجموعه‌ای از پارامترهای تابع توزیع دوجمله‌ای در BN. الگوریتم‌های مورد استفاده برای یادگیری، گرادیان کاهش در فاز اول و حداکثر کردن برآورد احتمال در فاز دوم می‌باشد. در فاز اول، ANN تابعی از متغیرهای ورودی را تعریف می‌کند و سعی می‌کند بهترین وزن‌ها را برای متغیرها پیدا کند. هنگامی که این شبکه به اندازه کافی آموزش داده شد، آماده است تا مقادیر هدف را تقریب‌زده و از این طریق روند ریسک نقدینگی را پیش‌بینی کند. در فاز دوم، فرایند یادگیری از طریق قانون بیز اتفاق می‌افتد. فرض می‌شود که گره‌ها توزیع پیشین دارند. این توزیع‌های پیشین برای تعریف توزیع پیشین جهانی استفاده می‌شود که پس از دریافت داده‌های آموزش، بهبود می‌یابد و به تدریج توزیع واقعی مجموعه داده را می‌آموزد.

۳-۳. فاز یک: اندازه‌گیری ریسک نقدینگی

۳-۳-۱. شبکه عصبی مصنوعی پیشنهادی

شبکه عصبی پیشنهادی، یک پرسپترون چندلایه^۱ دارای ساختار پیشخور^۲ است. در این مقاله از دو الگوریتم بهینه‌سازی محبوب در ادبیات موضوع برای آموزش یعنی الگوریتم لونیبرگ - مارکوارت^۳ (LMA) و الگوریتم فرابتنکاری ژنتیک (GA) استفاده

1. Multi-layer perceptron (MLP)

2. Feed Forward (FF)

3. Levenberg-Marquardt

کرده‌ایم. ژنتیک یکی از قدرتمندترین شیوه جستجو است که برای حل مشکلات بهینه‌سازی استفاده می‌شود. LMA از ژنتیک قوی‌تر است، اما مانند بسیاری از الگوریتم‌های برآزش منحنی، فقط مقدار حداقل محلی (نه لزوماً مقدار حداقل جهانی) را پیدا می‌کند. برای جبران این نقص، به‌طور موازی از الگوریتم ژنتیک برای جستجوی فضای جواب‌های شدنی استفاده می‌کنیم.

۳-۴. فاز دوم: تحلیل شاخص‌های ریسک

در این مقاله از یک شبکه بیزی برای شناسایی مهم‌ترین شاخص‌های ریسک در میان متغیرهای مدل و تحلیل نحوه تأثیر آنها برهم و اندازه‌گیری ریسک نقدینگی، استفاده می‌کنیم.

۳-۴-۱. رویکرد شبکه بیزی پیشنهادی

آموزش BN در این مقاله شامل سه مرحله به شرح زیر است:

مرحله یک. یادگیری ساختار: در این مرحله، فضای گراف‌های بدون دور جهت‌دار باید کاهش یابد تا فقط شامل ساختاری باشد که یال‌های آن شدنی باشد. از این‌رو گراف بدون دور جهت‌دار بهینه باید شناسایی شود.

کاهش فضای گراف‌های بدون دور جهت‌دار: حل مسئله یادگیری ساختار شبکه‌های بیزی، پیچیده و نمایی است و هنگامیکه گره‌ها زیاد باشد نمی‌توان جستجوی کامل را در زمان معقول انجام داد؛ بنابراین می‌توان از روش‌های ابتکاری برای یافتن بهترین ساختار شبکه در بازه زمانی معقول استفاده کرد. کاهش فضای گراف‌های بدون دور جهت‌دار با استفاده از آزمون استقلال شرطی شامل الگوریتم‌های مبتنی بر امتیاز و محدودیت و الگوریتم‌های ترکیبی انجام می‌شود.

یافتن گراف‌های بدون دور جهت‌دار بهینه: با توجه به تابع توزیع احتمال جهانی پیشین مجموعه رأس‌ها و با در نظر گرفتن ساختار شبکه، گراف بدون دور جهت‌دار بهینه گرافی است که حداکثر احتمال پسین را ارائه دهد.

مرحله دوم. یادگیری پارامتر: پس از تعیین روابط مناسب بین رأس‌ها، فرایند یادگیری پارامترها آغاز می‌شود. قبل از استفاده از مجموعه داده‌ها، توزیع پیشین بر روی پارامترهای تابع توزیع احتمال‌های محلی رأس‌ها در نظر گرفته می‌شود.

مرحله سوم. استنتاج: محاسبه یک کمیت مفید از روی یک توزیع احتمال توأم.

۴. مطالعه موردی: اجرای روش پیشنهادی


در این بخش نتایج به دست آمده با استفاده از روش پیشنهادی اندازه‌گیری ریسک نقدینگی بر روی مجموعه‌ای از داده‌های واقعی ارائه شده توسط بانک ملت در بورس اوراق بهادار نشان داده شده است. این داده‌ها شامل متغیرهای مورد نیاز ورودی مدل که در بخش ۳-۱ ذکر شده‌اند، می‌باشد. در واقع، برای حل مدل باید ورودی‌های لازم به مدل داده شود تا بتوان کارایی مدل پیشنهادی را با استفاده از داده‌های واقعی موجود مورد ارزیابی قرار داد که در ادامه به این کار پرداخته شده است. مجموعه داده‌های جمع‌آوری شده مربوط به سال‌های ۱۳۹۰ تا ۱۳۹۶ است. جهت جمع‌آوری داده‌های مورد نیاز تمامی صورت‌های مالی بانک ملت از قبیل ترازنامه‌ها، صورت‌های سود و زیان از تارنمای کدال استخراج شده است. همه نسبت‌ها نرمالیزه شده‌اند، اما باید از طریق روش میانگین‌گیری استاندارد تعداد آنها افزایش یابد.

۴-۱. فاز اول: اجرا توسط ANN

در این فاز هدف تخمین تابع ریسک نقدینگی است، بدین منظور داده‌ها را به سه گروه آموزش (۶۰ درصد)، اعتبارسنجی (۲۰ درصد) و آزمایش (۲۰ درصد) تقسیم کردیم.

۴-۱-۱. ساختار شبکه

ساختار انتخابی برای یک شبکه MLP سه لایه با یک لایه مخفی و یک لایه خروجی می‌باشد. لایه ورودی شامل ۹ رأس مربوط به ۹ ورودی است که با آزمون و خطا انتخاب شد و در شکل ۱ مشخص است. ارزیابی شبکه با استفاده از روش خطای میانگین مربعات (MSE) انجام شده است. توجه داشته باشید که شبکه تقریباً با تمام ساختارها به درستی کار می‌کند. جدول ۱ نتایج ارزیابی حاصل از یادگیری شبکه LMA را گزارش می‌کند.



شکل (۱): ساختار شبکه

مطابق جدول ۱، ساختار ۱-۷-۹ در بین ساختارهای آنالیزشده ساده‌ترین ساختار سه‌لایه است و عملکرد بهتری از نظر زمان و کیفیت نسبت به ساختارهای سه‌لایه دارد.

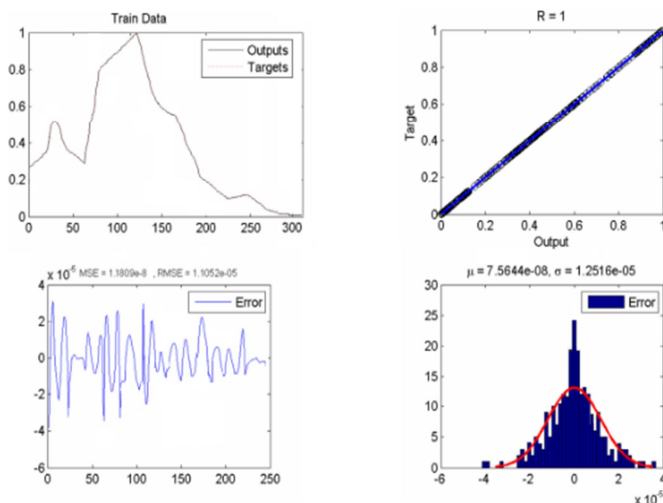
جدول (۱): مقایسه چند ساختار شبکه شذنی

ساختار شبکه	MSE	RSE	همبستگی خروجی و هدف
۱-۱-۹	۲e-۲,۱	۲e-۱,۱	۰,۹۴
۱-۲-۹	-۳e۶,۸	-۳e۶,۲	۰,۰۹۶
۱-۳-۹	-۴e۱,۲	-۴e۱,۲	۰,۹۸
۱-۴-۹	-۴e۸,۳	-۳e۳,۹	۰,۹۸
۱-۵-۹	-۵e۳,۵	-۵e۱,۹	۰,۹۸
۱-۶-۹	-۶e۳,۳	-۶e۵,۳	۰,۹۹
۱-۷-۹	-۸e۵,۲	-۶e۷,۸	۱
۱-۸-۹	-۷e۷,۱	-۵e۴,۱	۱

۲-۱-۴. یادگیری ANN

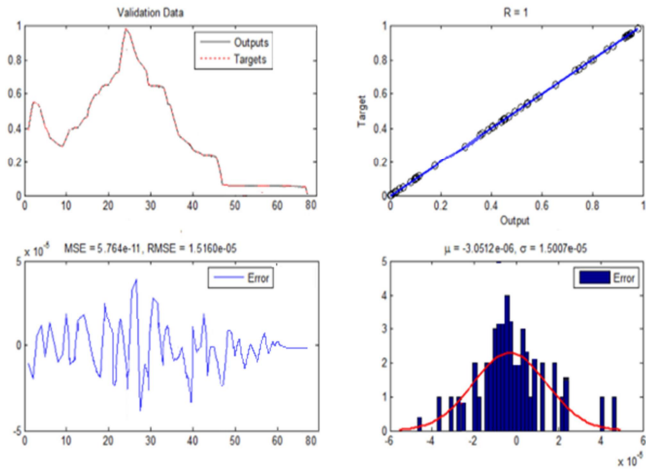
فرایند یادگیری توسط الگوریتم‌های LMA و ژنتیک اجرا شده است. نمودارهای

شکل‌های ۲ تا ۴ عملکرد LMA را در سه گروه جداگانه داده شامل داده‌های آموزش، اعتبارسنجی و آزمایش نشان می‌دهد. نتایج ارزیابی شبکه توسط ژنتیک در نمودارهای شکل‌های ۵ و ۶ مشخص است. نمودارهای شکل‌های ۲ تا ۶ نیز مربوط به کیفیت یادگیری توسط الگوریتم‌های GA و LMA است. هر نمودار ۴ زیرنمودار دارد. زیرنمودار بالا سمت چپ، خروجی‌ها و اهداف را نشان می‌دهد تا مقایسه کند که الگوی آموخته‌شده چقدر شبیه واقعیت است. زیرنمودار بالا سمت راست، همبستگی بین خروجی‌ها و اهداف را نشان می‌دهد. زیرنمودار پایین سمت چپ، خطای میانگین مربعات خروجی‌ها و اهداف را ارائه می‌دهد. زیرنمودار پایین سمت راست، نرمال بودن توزیع باقی‌مانده‌ها را بررسی می‌کند.



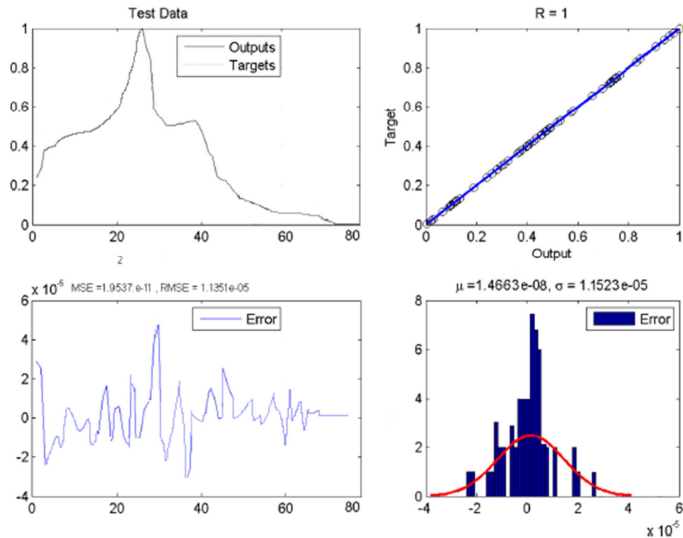
شکل (۲): ارزیابی فرایند یادگیری بر روی داده‌های آموزش اجرا شده توسط LMA

یادگیری توسط ژنتیک منجر به عملکرد ضعیف‌تر و انحراف استاندارد بیشتر می‌شود. به همین دلیل اختلاف مقیاس بین ارقام در نمودارهای نتایج مرتبط با یادگیری توسط LMA و GA وجود دارد؛ بنابراین ریسک نقدینگی در پایان توسط LMA مدل‌سازی خواهد شد. نمودارهای شکل‌های ۷ تا ۹ با نمایش روند خطاهای یادگیری، تحلیل عملکرد LMA و GA را تکمیل می‌کند. شکل ۷ نمایش گرافیکی از روند نزولی خطای یادگیری را هنگام آموزش شبکه توسط ژنتیک ارائه می‌دهد. شکل ۸ روند خطاهای یادگیری داده‌های آموزش، اعتبارسنجی و آزمایش هنگام یادگیری شبکه از طریق LMA را مقایسه می‌کند.

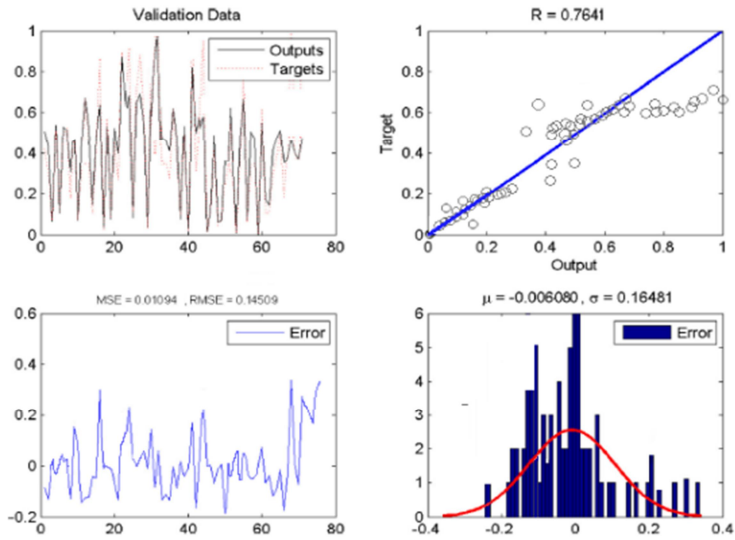


شکل (۳): ارزیابی فرایند یادگیری بر روی داده‌های اعتبارسنجی اجرا شده توسط LMA

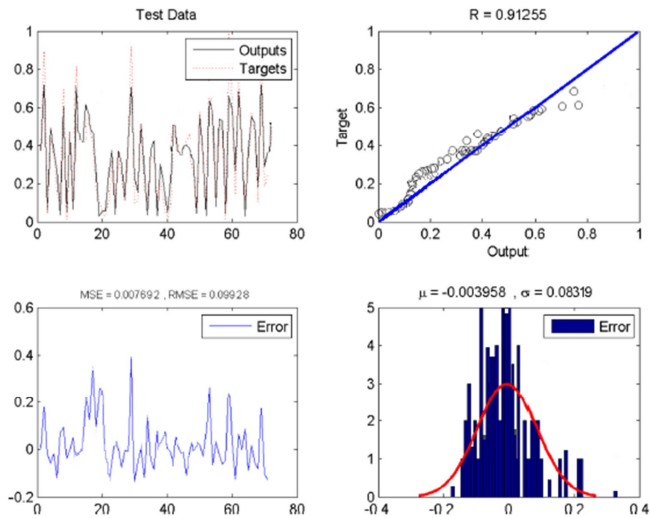
شکل ۹ مقایسه‌ای را بین مقادیر هدف و مقادیر ریسک نقدینگی آموخته شده توسط LMA نشان می‌دهد. با توجه به زمان اجرای الگوریتم‌ها، LMA امکان پیاده‌سازی قابل اعتماد را در مدت زمان نسبتاً کوتاه فراهم می‌کند.



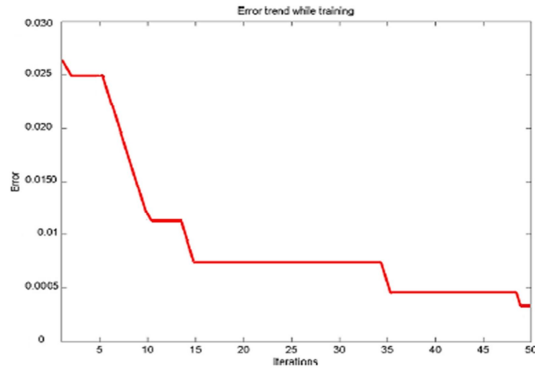
شکل (۴): ارزیابی فرایند یادگیری بر روی داده‌های آزمایش اجرا شده توسط LMA



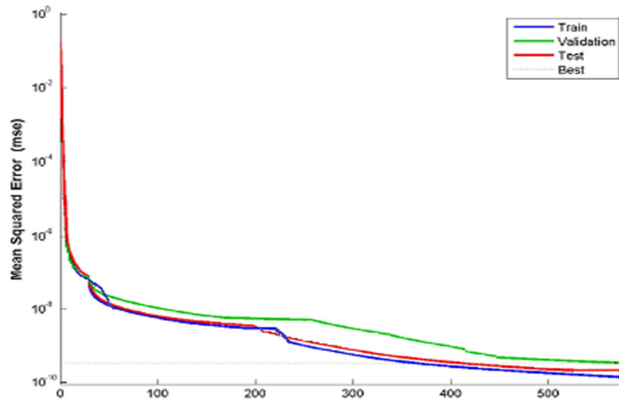
شکل (۵): ارزیابی فرایند یادگیری داده‌های اعتبارسنجی اجرا شده توسط GA



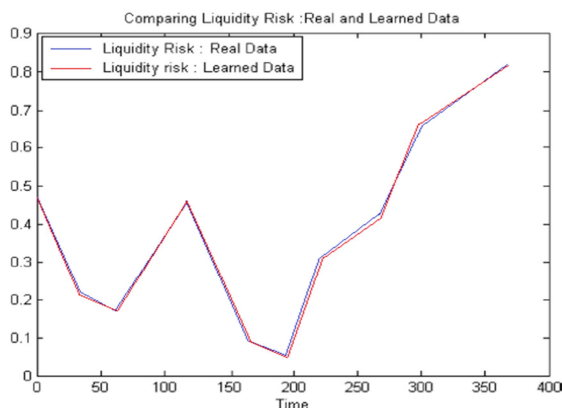
شکل (۶): ارزیابی فرایند یادگیری داده‌های آزمایش اجرا شده توسط GA



شکل (۷): روند نزولی خطای یادگیری توسط GA



شکل (۸): روند نزولی خطای یادگیری توسط LMA



شکل (۹): مقایسه مقادیر هدف و تابع ریسک نقدینگی آموخته شده توسط LMA


از طرف دیگر زمان همگرایی GA در شرایط واقعی از چندین دقیقه تا چند ساعت متغیر است. زمان اجرای GA و LMA در جدول ۲ گزارش شده است.

جدول (۲): مقایسه LMA با GA

GA	LMA	معیار مقایسه
۱۸۸ ثانیه	۹ ثانیه	زمان اجرا
۳e-۸,۶	۱۰e-۱,۱	MSE داده آموزش
-۲e۱,۱	-۱۰e۳,۱	MSE داده اعتبارسنجی
-۳e۷,۵	-۱۰e۱,۴	MSE داده آزمایش

۳-۱-۴. پیش بینی ریسک نقدینگی

به منظور پیش بینی ریسک نقدینگی، خروجی شبکه آموزش دیده بر اساس ماهیت این نوع ریسک در بانک‌ها به یک سری زمانی اتورگرسیون تبدیل شد. شکل ۱۰ توانایی شبکه آموزش دیده در پیش بینی ریسک نقدینگی بانک ملت را نشان می‌دهد. برای ارزیابی توانایی مدل پیش بینی ریسک و دقت آن، عملکرد ریسک نقدینگی تقریبی با داده‌های واقعی برای دوره زمانی مشابه مقایسه شد. نرخ خطای پیش بینی برای داده‌های گروه آزمایش ۰,۰۰۰۲۵۳ و برای داده‌های اعتبارسنجی ۰,۰۰۰۷۳۸ بود. در نتیجه با اجرای ANN پیشنهادی، پیش بینی ریسک با تفرانس پایین امکان پذیر شد.



شکل (۱۰): دقت پیش‌بینی در شبکه ANN

۲-۴. فاز دوم: اجرا توسط BN

در این فاز، مؤثرترین شاخص‌های ایجادکننده ریسک نقدینگی شناسایی شد. به‌عنوان یک نتیجه اولیه، می‌توان یکی از تولیدات ANN در فاز ۱ را در نظر گرفت. مقادیر جدول ۳ با استفاده از داده‌های گروه آزمایش به‌دست‌آمده و دو متغیر مرتبط را ارائه می‌دهند، یعنی جفت متغیری که بیشترین همبستگی را با تابع عملکرد ریسک دارند. بر اساس نتایج جدول ۲، تأثیرگذارترین شاخص‌های ریسک باید x_1 (نسبت نقدینگی) و x_5 (نسبت وام/ سپرده) باشد. با وجود این برای یافتن دو عامل مهم در میان ۹ متغیر ورودی، باید شبکه را به تعداد $\binom{9}{2}$ بار اجرا کنیم که از نظر محاسباتی کارا نیست. این نقص با اجرای تحلیل BN رفع می‌شود. برای اجرای یک BN، باید داده‌ها را گسسته کنیم. لذا هر شاخص ریسک x_i به‌عنوان یک متغیر باینری به شرح زیر تعریف می‌شود:

$$x_i = \begin{cases} 1 & \text{if } x_i \in I_i \\ 0 & \text{otherwise} \end{cases} \quad (12)$$

که در آن I_i نشانگر بازه نرمال متغیر x_i است. جدول ۴ نمایانگر مقدار نرمال شاخص‌هاست

۱-۲-۴. یادگیری ساختار BN

برای کاهش فضای گراف‌های بدون دور جهت‌دار شدنی، از چهار الگوریتم یادگیری

ساختار مطابق جدول ۵ استفاده شد. در جدول ۵، ستون «قدرت یال‌ها» قدرت روابط احتمالی بیان شده توسط یال‌های BN را نشان می‌دهد. هنگامی که آن شاخص یک آزمون استقلال شرطی باشد، قدرت یک یال یک p-value است. امتیازهای شبکه، آمارهای برازش نیکویی برای اندازه‌گیری چگونگی ساختار وابستگی داده‌ها توسط گراف بدون دور جهت‌دار می‌باشد و معیار امتیازدهی AIC استفاده شده است. مقادیر اعتبارسنجی متقابل نشان‌دهنده از بین رفتن احتمال ورود به سیستم است که این احتمال ورود به سیستم مورد انتظار منفی برای مجموعه آزمایش برای BN برازش شده در آزمایش یادگیری می‌باشد. «قدرت بوت»، قدرت و جهت یال‌ها را بیان می‌کند. بر اساس مقایسه‌های فوق، گراف بدون دور جهت‌دار تولید شده توسط الگوریتم «تابو» انتخاب شد. این گراف در شکل ۱۱ مشاهده می‌شود. برای ارزیابی اینکه آیا وابستگی احتمالی گراف بدون دور جهت‌دار انتخاب شده توسط داده‌ها پشتیبانی می‌شود یا خیر، آزمون استقلال شرطی را نیز اجرا می‌کنیم. با توجه به یک زنجیره علی از سه رأس، A، B و C، فرض‌های آزمون عبارت است از:

$$H_0 = A \perp C \mid B \quad H_1 = A \perp C \mid B$$

معیار استقلال اطلاعات متقابل (mi) با $\alpha = 0.05$ است؛ بنابراین اگر $p\text{-value} < \alpha$ باشد، فرض صفر رد شده و می‌توان یال را برای درج در گراف بدون دور جهت‌دار در نظر گرفت. جدول ۶ نتایج آزمون استقلال شرطی بر روی همه یال‌های گراف شکل ۱۱ را به منظور بررسی اعتبار یال‌ها نشان می‌دهد. این آزمون وابستگی بین گمان‌های به‌دست‌آمده توسط تابو را تأیید می‌کند.

۴-۲-۲. یادگیری پارامتر

فرایند یادگیری پارامترها توسط تابعی انجام می‌شود که متناسب با پارامترهای BN انتخاب شده با توجه به ساختار آن و مجموعه داده موجود می‌باشد. تابع عملکرد ریسک که پیش از این توسط ANN ساخته شده بود، اکنون توسط BN ساخته شده و نتایج مقایسه شده است. از دو معیار ارزیابی برای امتیازدهی BN برازش شده استفاده شده است که برای آنها مقدار احتمال ورود به سیستم را می‌توان از فرمول زیر به‌دست آورد:

$$-2 \times \log \text{likelihood} + k \times npar \quad (13)$$

که در آن npar تعداد پارامترهای مدل برازش شده می‌باشد، $k=2$ برای AIC

معمول و $k = \log(n)$ ، با تعداد n مشاهده، برای BIC یا SBC (معیار بیزی شوارتز) می‌باشد. در این مقاله مقادیر زیر را به دست آمده است:


$$AIC = -1030.223$$

$$BIC = -1086.245$$

هر چه مقدار حاصل بیشتر باشد بهتر است.

جدول (۶): آزمون استقلال شرطی در شبکه بیز آموخته شده در مطالعه موردی

ci.test	یال‌ها
$mi = 10,439, df = 1, p\text{-value} = 0,00389$	$x9 \rightarrow x1$
$mi = 142,89, df = 1, p\text{-value} < 0,0004$	$x1 \rightarrow x4$
$mi = 43,390, df = 1, p\text{-value} = 0,0002$	$x4 \rightarrow x2$
$mi = 59,543, df = 1, p\text{-value} = 0,0064$	$x8 \rightarrow x9$
$mi = 61,142, df = 1, p\text{-value} = 0,005$	$x7 \rightarrow x8$
$mi = 51,512, df = 1, p\text{-value} = 0,0042$	$x2 \rightarrow x10$
$mi = 65,561, df = 1, p\text{-value} = 0,0054$	$x4 \rightarrow x5$
$mi = 23,902, df = 1, p\text{-value} = 0,0032$	$x9 \rightarrow x4$
$mi = 28,463, df = 1, p\text{-value} = 0,0046$	$x6 \rightarrow x7$
$mi = 11,453, df = 1, p\text{-value} = 0,0002$	$x8 \rightarrow x5$
$mi = 4,903, df = 1, p\text{-value} = 0,245$	$x1 \rightarrow x10$
$mi = 3,535, df = 1, p\text{-value} = 0,363$	$x4 \rightarrow x10$
$mi = 12,746, df = 1, p\text{-value} = 0,0007$	$x5 \rightarrow x3$
$mi = 33,165, df = 2, p\text{-value} = 0,0010$	$x1, x9 x4$
$mi = 27,456, df = 2, p\text{-value} = 0,0105$	$x4, x8 x5$
$mi = 273,219, df = 2, p\text{-value} < 0,0000002$	$x1, x2 x10$
$mi = 68,345, df = 2, p\text{-value} = 0,0003$	$x1, x4 x10$
$mi = 69,834, df = 2, p\text{-value} = 0,0004$	$x2, x4 x10$



شکل (۱۱): شبکه ییزی آموزش داده‌شده برای تعیین تأثیر گذارترین شاخص‌های ریسک

۴-۲-۳. استنتاج

پس از برآورد پارامتر، دریافتیم که عوامل مؤثر در ریسک نقدینگی چیست و طبقه‌بندی عوامل از بیشترین به کمترین تأثیر چگونه است. فرض کنید همه شاخص‌های ریسک نقدینگی به جز نمایه ۱، مقادیر نرمال را نشان می‌دهند؛ بنابراین با استفاده از این شواهد احتمال حاشیه‌ای ریسک نقدینگی را اندازه‌گیری کنید. این کار را با کمی تغییر در شواهد تکرار کنید، یعنی فرض کنید که همه شاخص‌ها مقادیر نرمال را به جز نمایه ۲ نشان دهند، برای هر شاخص تا آخرین شاخص تکرار کنید. مقادیر گزارش شده در جدول ۷ بیان می‌کند که X_5 و X_1 مهم‌ترین عوامل هستند. توجه کنید که پس از محاسبه پارامتر، در واقع می‌توانیم با توابع احتمال مشترک، شرطی و حاشیه‌ای به هر سؤالی در مورد ریسک نقدینگی و عوامل آن پاسخ دهیم.

جدول (۷): تأثیر هر شاخص ریسک بر ریسک نقدینگی

شاخص	تأثیر شاخص بر ریسک نقدینگی (وقتی شاخص‌های دیگر وضعیت نرمال را نشان می‌دهند)
شاخص اول	۰,۷۵۸۳۲۱
شاخص دوم	۰,۴۶۲۳۵۰
شاخص سوم	۰,۴۲۱۰۶۰

شاخص	تأثیر شاخص بر ریسک نقدینگی (وقتی شاخص‌های دیگر وضعیت نرمال را نشان می‌دهند)
شاخص چهارم	۰,۳۸۹۶۴۶
شاخص پنجم	۰,۶۵۴۵۰۰
شاخص ششم	۰,۴۲۹۸۸۱
شاخص هفتم	۰,۴۳۵۴۸۵
شاخص هشتم	۰,۰۵۲۶۳۸
شاخص نهم	۰,۴۴۲۹۰۸


۳-۴. نکاتی در مورد تست و اعتبارسنجی

برای اعتبارسنجی روش‌های اعمال‌شده، هنگام تقریب یک تابع توسط ANN، از معیارهایی مانند انحراف (بایاس)، واریانس و خطای میانگین مربعات استفاده می‌شود تا نشان دهد که شبکه به درستی آموزش داده شده است. بهترین راه برای اعتبارسنجی یک مدل یادگیری ماشین، تجزیه و تحلیل کیفیت یادگیری آن است: تمام ابزارهای مورد نیاز برای چنین تجزیه و تحلیل در حال حاضر در تک‌تک روش‌های استفاده شده توسط خود مدل موجود است. برای بهتر نشان دادن این واقعیت، ما یک شبیه‌سازی ارائه می‌دهیم که کیفیت یادگیری پارامتر را در BN پیشنهادی نشان می‌دهد. با استفاده از شبکه آموزش دیده، برای متغیرهای $X1$ تا $X10$ ، ۳۰ نمونه از تابع توزیع احتمال آموخته شده تولید کرده‌ایم. توابع توزیع احتمال حاصل از شبیه‌سازی در شکل ۱۲ نشان داده شده است. متغیرها فقط می‌توانند دو مقدار TRUE یا FALSE بگیرند که با اعداد ۰ و ۱ در امتداد محور عمودی مطابقت دارند. شکل ۱۲ داده‌های واقعی را در مقابل نمونه تابع توزیع احتمال تولید شده توسط شبکه آموزش دیده نشان می‌دهد. همان‌طور که در شکل ۱۲ مشاهده می‌شود، شبکه توانست تابع توزیع احتمال را به درستی تخمین بزند. تورفتگی و دندان‌های شکل بیانگر اشتباه‌های شبکه هنگام انجام تخمین می‌باشد.

نتیجه‌گیری

در این مقاله روشی را پیشنهاد کرده‌ایم که از روش‌های بروز در یادگیری ماشین استفاده می‌کند. متغیرهای مدل نسبت‌های نقدینگی هستند و از طریق داده‌های ترازنامه استاندارد بانکی به راحتی در دسترس هستند. علی‌رغم قابلیت‌های فراوان این

شبکه‌ها، به‌ندرت به مسائل اندازه‌گیری ریسک نقدینگی با استفاده از این روش‌های جدید یادگیری ماشین یا ترکیبی از آنها پرداخته شده است؛ بنابراین مطالعه حاضر به پرکردن یک شکاف تحقیقاتی قابل توجه کمک می‌کند و سیستم‌های هوشمند را از مسائل مدل‌سازی داده‌های بانکی دارای عدم قطعیت جدا می‌کند. در این پژوهش به‌عنوان تعریف ریسک نقدینگی بر روی مفهوم توانایی پرداخت تمرکز کرده‌ایم. همچنین یک مطالعه موردی بر اساس داده‌های بانک ملت ارائه شده است. پیاده‌سازی‌های شبکه‌های ANN و BN قادر به شناسایی مهم‌ترین عوامل ریسک و اندازه‌گیری ریسک از طریق توابع عملکردی تخمین و برآورد توزیعی هستند. هر دو مدل از طریق فرایندهای آموزش و یادگیری خاص خود مورد ارزیابی قرار گرفتند و نتایج بسیار سازگاری حاصل شد. همچنین نتایج عددی به‌دست‌آمده در مطالعه موردی نشان می‌دهد که روش هوشمند دو فازی پیشنهادی توانایی تأیید نتایج از طریق اجرای مستقل و موازی مجموعه داده‌های مشابه را دارا می‌باشد که دلیل اصلی دیگر استفاده از این مدل است. به‌عنوان پیشنهادهایی برای پژوهش‌های آتی، توسعه مدل پیشنهادی در محیط پویا به کمک BN‌های پویا و استفاده از روش‌های یادگیری ماشین بدون نظارت می‌باشد. همچنین فرامرزی و همکاران (۱۳۹۵)، تهرانی و فلاح شمس (۱۳۸۴) و سپهری و فروش (۱۳۸۴) نشان دادند شبکه‌های عصبی مصنوعی پرسپترون در اندازه‌گیری ریسک نقدینگی از کارایی بالایی برخوردار هستند و همان‌طور که ذکر شد، در پژوهش حاضر مدل ترکیبی از شبکه‌های عصبی مصنوعی و شبکه‌های بی‌زی از بیشترین کارایی برخوردار است.



شکل (۱۲): توزیع احتمال داده‌های واقعی در مقابل توزیع احتمال نمونه‌های آموخته‌شده



جدول (۳): همبستگی شاخص‌های ریسک مطالعه موردی از طریق اجرای شبکه ANN

متغیرهای ورودی	R	RMSE	μ	σ	عملکرد آموزش	عملکرد اعتبارسنجی	عملکرد آزمایش
X1,X2	۰,۹۹۳۸	۰,۰۰۶۵	۰,۰۰۱۸	۰,۰۰۳	۰,۰۱۸۷	۰,۰۱۶۴	۰,۰۱۸۵
X1,X3	۰,۹۸۳۲	۰,۰۴۲۳	-۰,۰۰۱۸	۰,۰۷۸	۰,۰۰۱۹	۰,۰۰۱۶	۰,۰۰۱۶
x1, x4	۰,۹۹۱۲	۰,۰۲۱۲	۰,۰۰۰۳	۰,۰۱۵۵	۰,۰۰۵۳	۰,۰۰۶۶	۰,۰۰۷۳
x1, x5	۰,۹۴۲۸	۰,۰۱۷۶	-۰,۰۰۰۳	۰,۰۱۱۱	۰,۰۴۵۶	۰,۰۴۸۳	۰,۰۸۲۷
x1, x6	۰,۹۴۰۲	۰,۰۳۷۷	۰,۰۰۱۴	۰,۰۲۸۹	۰,۰۱۹۱	۰,۰۱۸۴۷	۰,۰۱۶۳۸
x1, x7	۰,۸۹۲۷	۰,۰۵۱۲	۰,۰۰۴۸	۰,۰۵۲۵	۰,۰۱۰۱	۰,۰۱۰۹	۰,۰۱۱۸
x1, x8	۰,۹۳۷۲	۰,۰۲۸۹	۰,۰۰۷۴	۰,۰۱۹	۰,۰۲۵۹	۰,۰۲۲۸	۰,۰۳۰۴
x1, x9	۰,۸۸۹۲	۰,۰۱۰۱	۰,۰۰۴	۰,۰۱۴۸	۰,۰۶۲۱	۰,۰۶۲۳	۰,۰۵۸۲
X2, x3	۰,۹۹۱۵	۰,۱۹۷۱	-۰,۰۸۳۹	۰,۱۷۳۹	۰,۰۱۵۹	۰,۰۱۷۶	۰,۰۲۱۲
X2, x4	۰,۹۱۱۱	۰,۱۶۳۲	-۰,۰۳۸۲	۰,۱۵۲۵	۰,۰۱۹۳	۰,۰۱۲۸	۰,۰۱۵۷
X2, x5	۰,۹۶۵۸	۰,۰۵۱۲	-۰,۰۱۴۲	۰,۰۴۹۸	۰,۰۰۵۳	۰,۰۰۶۱	۰,۰۱۷۰
X2, x6	۰,۹۲۹۴	۰,۱۵۲۹	-۰,۰۹۲۷	۰,۱۴۷۶	۰,۰۲۹۸	۰,۰۲۹۸	۰,۰۲۲۷
X2, x7	۰,۹۱۶۳	۰,۱۱۸۹	۰,۰۰۲۸	۰,۰۷۴۶	۰,۰۲۷۶	۰,۰۲۷۳	۰,۰۲۳۸
X2, x8	۰,۹۲۷۴	۰,۱۱۹۹	-۰,۰۱۵۹	۰,۰۹۵۹	۰,۰۰۳۴	۰,۰۰۳۱	۰,۰۰۲۹
X2, x9	۰,۹۹۹۲	۰,۰۵۰۱	۰,۰۱۹۲	۰,۰۵۷۲	۰,۰۰۰۴	۰,۰۰۱۰	۰,۰۰۰۸
X3, x4	۰,۸۴۲۱	۰,۱۴۸۸	-۰,۰۰۱۲	۰,۱۹۸۳	۰,۰۲۵۲	۰,۰۲۶۳	۰,۰۲۶۳
X3, x5	۰,۹۲۵۲	۰,۰۵۲۴	۰,۰۲۸۰	۰,۰۴۳۸	۰,۰۰۴۵	۰,۰۰۴۱	۰,۰۰۱۹
X3, x6	۰,۹۸۸۰	۰,۰۴۳	۰,۰۲۱۹	۰,۱۸۹۳	۰,۰۱۱۵	۰,۰۱۱۹	۰,۰۱۴۸
X3, x7	۰,۹۹۳۲	۰,۰۴۲۷	-۰,۰۰۲۹	۰,۰۴۸۳	۰,۰۰۶۲	۰,۰۰۶۰	۰,۰۰۶۴
X3, x8	۰,۹۹۲۰	۰,۰۳۱۰	۰,۰۰۳۸	۰,۰۲۸۶	۰,۰۸۳۵	۰,۰۸۶۱	۰,۰۷۳۵
X3, x9	۰,۹۵۷۸	۰,۰۳۸۱	-۰,۰۰۴۸	۰,۰۳۸۷	۰,۰۳۸۵	۰,۰۳۳۳	۰,۰۲۹۵
X4, x5	۰,۹۱۸۴	۰,۰۴۱۸	۰,۰۰۳۱	۰,۰۲۷۷	۰,۰۰۱۸	۰,۰۰۱۷	۰,۰۰۱۹
X4, x6	۰,۹۶۸۹	۰,۱۸۶۶	-۰,۰۳۸۲	۰,۱۹۵۴	۰,۰۵۷۲	۰,۰۵۱۸	۰,۰۵۴۵
X4, x7	۰,۹۳۹۵	۰,۰۶۱۲	-۰,۰۰۱۹	۰,۰۵۸۵	۰,۰۱۹۲	۰,۰۲۰۲	۰,۰۲۷۴
X4, x8	۰,۹۱۲۷	۰,۰۱۰۶	۰,۰۰۰۱	۰,۰۲۲۷	۰,۰۵۸۶	۰,۰۵۹۴	۰,۰۶۰۶
X4, x9	۰,۹۶۹۲	۰,۰۴۲۸	-۰,۰۰۸۲	۰,۰۴۴۱	۰,۰۲۸۸	۰,۰۳۰۳	۰,۰۳۱۸
X5, x6	۰,۹۷۳۹	۰,۰۴۱۷	-۰,۰۰۳۱	۰,۰۴۹۷	۰,۰۵۸۴	۰,۰۵۸۸	۰,۰۵۱۵
X5, x7	۰,۸۰۳۹	۰,۰۳۹۱	-۰,۰۰۱۸	۰,۰۵۸۹	۰,۰۰۵۷	۰,۰۰۵۳	۰,۰۰۵۲

متغیرهای ورودی	R	RMSE	μ	σ	عملکرد آموزش	عملکرد اعتبارسنجی	عملکرد آزمایش
X5, x8	۰,۹۹۳۰	۰,۰۱۰۰	۰,۰۰۱۲	۰,۰۲۸۷	۰,۰۳۷۵	۰,۰۳۵۹	۰,۰۳۹۸
X5, x9	۰,۹۱۸۴	۰,۰۴۰۳	-۰,۰۰۰۲	۰,۰۲۸۵	۰,۱۵۸۴	۰,۱۵۸۴	۰,۱۳۰۵
X6, x7	۰,۷۲۹۲	۰,۰۴۹۹	۰,۰۰۶۹	۰,۰۵۲۳	۰,۰۳۶۳	۰,۰۳۱۵	۰,۰۲۹۳
X6, x8	۰,۹۹۳۸	۰,۰۳۱۰	۰,۰۰۱۶	۰,۰۳۱۱	۰,۲۳۷۴	۰,۲۲۷۳	۰,۱۸۳۶
X6, x9	۰,۹۷۵۸	۰,۰۵۵۵	۰,۰۰۱۸	۰,۰۴۸۳	۰,۰۵۸۷	۰,۰۳۸۶	۰,۰۳۲۷
X7, x8	۰,۹۱۳۸	۰,۰۶۲۹	۰,۰۱۶۹	۰,۰۵۹۲	۰,۰۰۴۷	۰,۰۰۴۹	۰,۰۰۴۳
X7, x9	۰,۹۱۳۳	۰,۰۵۱۹	۰,۰۱۴۹	۰,۰۸۲۲	۰,۰۰۶۴	۰,۰۰۶۸	۰,۰۰۶۷
X8, x9	۰,۹۸۹۳	۰,۰۲۸۵	-۰,۰۰۰۱	۰,۰۲۶۴	۰,۰۶۲۵	۰,۰۵۹۳	۰,۰۵۳۷

جدول (۴): بازه‌ها/مقادیر نرمال برای شاخص‌های ریسک مطالعه موردی

X10	X9	X8	X7	X6	X5	X4	X3	X2	X1
۱	۱۰ درصد	۲۱ درصد	۱۵ درصد	۱۵ درصد	۷۵-۸۵ درصد	۱	بیش از یک در شرایط تورم	۱	۵-۹ درصد

جدول (۵): الگوریتم‌های یادگیری ساختار مورد استفاده در مطالعه موردی برای

رویکرد BN

قدرت بوت	اعتبارسنجی متقابل	امتیازها	قدرت یال‌ها			الگوریتم یادگیری (تعداد آزمایش)		
۰,۵۴۹۳ ۰,۹۸۵۴ ۰,۴۵۵۲ ۰,۷۸۹۵ ۰,۶۳۸۵	X5 به X2 X10 به X2 X1 به X4 X4 به X5 X1 به X10	۲,۳۱۱۵	-۱۱۶۵۶۷	۰,۰۰۱۹ ۰,۰۰۲۸ ۱۵۰-۱,۴۰۱ ۰,۴۹۹۸ ۰,۰۰۰۰۷	X4 به X5 X4 به X6 X8 به X9 X1 به X10 X2 به X10	۰,۰۰۰۱ ۰,۰۰۰۰۳ ۰,۰۰۰۸۶ ۰,۰۰۷۰۸ ۰,۰۰۰۸۱	X2 به X1 X4 به X1 X1 به X3 X5 به X3 X2 به X5	(۱۷۵) Gs
۰,۶۴۹۰ ۰,۶۴۰۰ ۰,۷۸۲۴ ۰,۵۴۵۴ ۰,۶۲۴۳ ۰,۶۲۰۰ ۰,۹۸۰۲ ۰,۵۴۵۲	X5 به X3 X1 به X4 X2 به X4 X5 به X4 X6 به X7 X8 به X9 X1 به X10 X2 به X10	۲,۱۰۰۵۷	-۱۱۰۰۵۷	۰,۰۰۱۴ ۰,۰۰۳۴ ۰,۰۰۰۰۷ ۰,۰۰۰۰۱ ۰,۰۰۰۰۵	X4 به X5 X6 به X7 X7 به X8 X8 به X9 X1 به X10	۰,۰۰۰۹ ۰,۰۰۰۱ ۰,۰۰۷۱۰ ۰,۰۰۰۰۴ ۰,۰۰۰۸۵	X2 به X4 X10 به X2 X5 به X3 X1 به X4 X9 به X4	(۲۴۵) Iamb
۰,۹۷۰۰ ۰,۶۸۰۰	X10 به X2 X5 به X3	۲,۱۶ ۵۵	۶,۵۷	۰,۰۰۱۹ ۳,۳۱۴۳	X4 به X5 X9 به X7	۰,۴۲۸۰ ۰,۰۰۰۰۸	X3 به X1 X4 به X2	(۱۷۶) Fast.iamb

قدرت بوت	اعتبارسنجی متقابل	امتیازها	قدرت یال‌ها			الگوریتم یادگیری (تعداد آزمایش)	
			X9 به X8	X10 به X1	X3 به X5		
۰,۷۵۰۰ X1 به X4			۰,۰۱۷۶	X9 به X8	۰,۰۰۰۰۱	X10 به X2	
۰,۷۵۸۷ X5 به X4			۰,۰۰۰۰۴	X1 به X10	۰,۰۰۰۰۱	X1 به X4	
۰,۶۴۳۳ X9 به X8			۰,۱۵۳۰	X3 به X10	۰,۰۵۸۵	X3 به X5	
۰,۷۰۵۴ X1 به X10							
۰,۷۵۴۷ X4 به X1	۲,۱۶۳۲	-۱,۰۴۸,۲۴	-۵,۸۶۴۷	X7 به X6	-۹۵,۲۳۴۵	X4 به X1	
۰,۸۹۹۷ X10 به X1			-۳,۳۶۰۱	X5 به X8	-۲۶,۲۰۹۴	X2 به X4	
۰,۷۲۰۳ X10 به X2			-۱۸,۲۲۰۳	X10 به X1	-۲۵,۴۸۶۵	X9 به X8	
۰,۸۸۹۰ X2 به X4			-۶,۲۰۱۴	X10 به X4	-۲۰,۳۸۲۶	X8 به X7	
۰,۹۱۲۰ X5 به X4			-۲,۰۰۱۳	X3 به X5	-۱۸,۲۸۹۶	X10 به X2	
۰,۷۵۳۸۱ X3 به X5							
۰,۷۲۰۰ X6 به X7							
۰,۷۴۶۵ X5 به X8							
۰,۸۲۵۶ X7 به X8							
۰,۶۵۵۴ X4 به X9					-۱,۸۵۹۶	X1 به X9	-۲۱,۱۵۴۴
۰,۷۶۰۰ X8 به X9							
۰,۵۹۳۸ X4 به X10							

فهرست منابع

اسماعیل‌زاده، علی و جوانمردی، حلیمه (۱۳۹۶). طراحی الگویی مناسب مدیریت نقدینگی و پیش‌بینی ریسک آن در بانک صادرات ایران. *اقتصاد مالی (اقتصاد مالی و توسعه)*، ۱۱(۳۹).

بزرگ اصل، موسی؛ برزیده، فرخ و صمدی، محمدتقی (۱۳۹۷). تأثیر ریسک نقدینگی و ریسک اعتباری بر پایداری مالی در صنعت بانکداری ایران؛ رهیافت رگرسیون چندک. *فصلنامه علمی پژوهشی دانش مالی تحلیل اوراق بهادار*، ۱۱(۳۸).

تهرانی، رضا و فلاح شمس لیالستانی، میرفیض (۱۳۸۴). طراحی و تبیین مدل ریسک اعتباری در نظام بانکی کشور. *علوم اجتماعی و انسانی دانشگاه شیراز*، ۲۲(۲)، ۴۵-۶۰.

دهقانی احمدآباد، محمدرضا و سعیدی کوشا، مهدی (۱۳۹۹). برآورد سنجه‌های ریسک زیان نقدینگی در بانک‌های تجاری با استفاده از فرایندهای تصادفی. *فصلنامه راهبرد مدیریت مالی*، ۸(۲).

سپهری، محمدمهدی و فروش، حمید (۱۳۸۴). مقایسه روش‌های خطی سنتی با

تکنیک شبکه‌های عصبی مصنوعی در پیش‌بینی قیمت سهام بورس تهران. کنفرانس بین‌المللی فناوری اطلاعات و دانش، (۲).
 فرامرزی، مرزبان؛ یعقوبی، ثریا؛ کریمی، حاجی و سروریان، جواد (۱۳۹۵). ارزیابی کارایی شبکه عصبی مصنوعی در پیش‌بینی روند بیابان زایی با استفاده از سیستم اطلاعات جغرافیایی GIS (مطالعه موردی: دشت دهلران، ایلام). سنجش از دور و سامانه اطلاعات جغرافیایی در منابع طبیعی (کاربرد سنجش از دور و GIS در علوم منابع طبیعی)، ۷(۳)، ۶۱-۷۷.
 کفائی، محمدعلی و راهزانی، محبوبه (۱۳۹۵). بررسی تأثیر ناطمینانی کالان اقتصادی بر ریسک نقدینگی بانک‌های ایران. فصلنامه پژوهشنامه اقتصادی. سال شانزدهم، (۶۲)، پاییز، ۳-۶۲.

- Bassey, G. E. & Moses, C. E. (2015). Bank Profitability and Liquidity Management: A Case Study of Selected Nigerian Deposit Money Banks, University Of Uyo. *International Journal of Economics, Commerce and Management*, 3(4), 1-24.
- Chen, Y. K.; Shen, H. H. & Kao, L. (2018). Bank Liquidity Risk and Performance. *Review of Pacific Basin Financial Markets and Policies*, 21(1).
- Crouhy, M.; Galai, D. & Mark, A. (2000). A comparative analysis of current credit risk models. *Journal of Banking and Finance*, 24(1-2), 59-117.
- Drehmann, M. & Nikolaou, K. (2009). Funding Liquidity Risk: Definition and Measurement. *European Central Bank, Working Paper Series March*, No. 1024.
- Jaiswal, S. (2018). Relationship between Asset and Liability of Commercial Banks in India, 1997-2008. *International Research Journal of Finance and Economics*, (49), 43-58.
- Jobst, A. A. (2014). Measuring systemic risk-adjusted liquidity (SRL): a model approach. *J. Bank. Financ*, (45), 270-287.
- Konovalova, N. & Zarembo, J. (2015). Imbalanced Liquidity Risk Management: Evidence from Latvian and Lithuanian Commercial Banks. *Copernican Journal of Finance and accounting*, 4(1).
- Matz, L. (2007). *Scenario analysis and stress testing*. in: L. Matz, P. Neu (Eds.), *Liquidity Risk Measurement and Management*. John Wiley & Sons Inc, New Jersey, pp. 37-64 .
- Papadamou, S.; Sogiakas, D.; Sogiakas, V. & Syriopoulos K. (2021). The role of net stable funding ratio on the bank lending channel: evidence from European Union. *Journal of Banking Regulation*, (22), 287-307.
- Rahman, M. L. & Banna, S. H. (2016). Liquidity Risk Management: A Comparative Study between Conventional and Islamic Banks in Bangladesh. *Journal of Business and Technology (Dhaka)*, 10(2), 18-35.

- Sabri Mohammad, Mehmet Asutay, Rob Dixon, Elena Platonova (2020). *Liquidity risk exposure and its determinants in the banking sector: A comparative analysis between Islamic, conventional and hybrid banks*. Journal of International Financial Markets, Institutions and Money. Volume 66.
- Scannella, E. (2016). Theory and regulation of liquidity risk management in banking. *International Journal of Risk Assessment and Management*, 19(1/2), 4-21.
- Tripe, D. (1999). *Liquidity Risk in Banks-A New Zealand Perspective*. New Zealand, Massey University.
- Vento, G. A. & La Ganga, P. (2009). Bank liquidity risk management and supervision: which lessons from recent market turmoil. *J. Money Invest. Bank*, (10), 78-125.

