



ارائه مدل جامع جهت اندازه‌گیری ریسک نقدینگی بانک‌های پذیرفته‌شده در بورس اوراق بهادار تهران (مطالعه موردی: بانک ملت)

تورج آذری^۱

مجتبی دستوری^۲

رضا تهرانی^۳

تاریخ پذیرش: ۱۴۰۱/۰۳/۱۹

تاریخ دریافت: ۱۴۰۱/۰۱/۱۵

چکیده

عدم مدیریت نقدینگی بانک‌ها یکی از مهم‌ترین ریسک‌های هر بانک می‌باشد و کم‌توجهی به ریسک نقدینگی منجر به عواقب جبران‌ناپذیر می‌شود. جلوگیری از وقوع ریسک نقدینگی نیازمند یک روش اندازه‌گیری جامع می‌باشد؛ اما ریسک نقدینگی موضوعی پیچیده است و این پیچیدگی ارائه یک تعریف مناسب را دشوار می‌سازد. علاوه بر این، تعریف فاکتورهای تعیین‌کننده ریسک نقدینگی و فرمول‌بندی تابع هدف مرتبط برای تقریب و پیش‌بینی مقدار آن پیچیده است. در این تحقیق برای مقابله با این مشکلات و ارزیابی ریسک نقدینگی و فاکتورهای کلیدی آن، مدلی را پیشنهاد می‌کنیم که از شبکه‌های عصبی مصنوعی و بیزی استفاده می‌کند. طراحی و اجرای این مدل شامل چندین الگوریتم و آزمایش جهت اعتبارسنجی است. در این مقاله از الگوریتم‌های بهینه‌سازی لونبرگ-مارکوارت و ژنتیک جهت آموزش شبکه عصبی مصنوعی استفاده کرده‌ایم. همچنین یک مطالعه موردی در بانک ملت برای نشان دادن قابلیت اجرا، کارایی، دقت و انعطاف‌پذیری مدل اندازه‌گیری ریسک نقدینگی تحقیق، پیاده‌سازی کرده‌ایم.

واژه‌های کلیدی: ریسک نقدینگی، صنعت بانکداری، یادگیری ماشین، شبکه عصبی مصنوعی، شبکه بیزی.

طبقه بندی JEL: G32, G24, D83, C45, C11

۱- گروه مدیریت و حسابداری، واحد بین الملل کیش، دانشگاه آزاد اسلامی، تهران، ایران. azaritooraj@yahoo.com

۲- گروه مدیریت و حسابداری، واحد بین الملل کیش، دانشگاه آزاد اسلامی، تهران، ایران. dastoori@ut.ac.ir

۳- گروه مدیریت و حسابداری، واحد بین الملل کیش، دانشگاه آزاد اسلامی، تهران، ایران (نویسنده مسئول) tehrani@ut.ac.ir

۱- مقدمه

صنعت بانکداری یکی از مهم‌ترین بخش‌های اقتصادی کشورها است که در فعالیت‌های خود با ریسک‌های مختلفی مواجه هستند. از جمله مهم‌ترین ریسک‌های تهدیدکننده بانک‌ها، ریسک نقدینگی است که در صورت عدم مدیریت موجب ورشکستگی بانک‌ها می‌گردد (موساکوا^۱، ۲۰۱۳).

در فعالیت‌های بانکی معمولاً سررسید تعهدات 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 بوجود می‌آورد و می‌تواند موجب از دست رفتن حسن 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 روبرو می‌شود، مهم‌تر است، چراکه سپرده‌های کوتاه‌مدت اصلی‌ترین منابع مالی بانک‌ها هستند و وام‌ها نیز معمولاً برای بانک با ریسک نقدشوندگی همراه می‌باشد (ونتو و گانگا^۲، ۲۰۰۹). نقدینگی بیش از حد باعث تخصیص ناکارآمد منابع می‌شود، درحالی‌که نقدینگی کم می‌تواند منجر به کاهش نرخ سود سپرده‌ها، از دست دادن بازار و اعتبار، افزایش بدهی‌ها و در نهایت شکست بانک شود. بنابراین مدیریت ارزیابی ریسک نقدینگی بسیار مهم است. ریسک نقدینگی به مجموعه پیچیده‌ای از فاکتورها از جمله خسارت قابل توجه ریسک عملیاتی، کاهش کیفیت اعتبار، تکیه بیش از حد به استقراض کوتاه‌مدت، ریسک بازار و غیره مربوط می‌شود (مارز و نئو^۳، ۲۰۰۷). هدف اصلی این مقاله طراحی یک سیستم عملی براساس 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 فاکتورهای اصلی آن استفاده کنیم. این روش‌ها علی‌رغم قابلیت‌های گسترده در مدل‌سازی شرایط واقعی و پیش‌بینی نتایج آتی 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^۴ و شبکه‌های بیزی^۵ برای ارزیابی ریسک نقدینگی و فاکتورهای کلیدی آن استفاده می‌کند. روش ارزیابی حاصل شامل استفاده از الگوریتم ژنتیک^۶ و آزمایش‌های متعدد برای آموزش شبکه‌های مذکور جهت تجزیه و تحلیل داده‌هاست. برای اعتبارسنجی روش ارزیابی ریسک پیشنهادی، یک مطالعه موردی براساس داده‌های واقعی "بانک ملت" ارائه شده است.

1 Musakwa

2 Vento & Ganga

3 Marz & Neu

4 Artificial Neural Networks (ANN)

5 Bayesian Network (BN)

6 Genetic Algorithm (GA)

۲- مطالعات نظری و ادبیات موضوع

ریسک نقدینگی عبارت است از ریسک ناشی از نبود نقدینگی لازم جهت پوشش تعهدات کوتاه‌مدت و خروجی‌های غیرمنتظره وجوه. به عبارت دیگر، ریسک نقدینگی عدم توانایی بانک در تامین وجوه برای اعطای تسهیلات یا پرداخت به موقع دیون خود نظیر سپرده‌ها است (تراپ^۱، ۱۹۹۹). 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. 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 (کروهی و همکاران^۲، ۲۰۱۰). کمیته نظارت بر بانکداری بازل با هدف ارتقا توانمندی بانک‌ها در تأمین نقدینگی خود در سال ۲۰۱۰ استاندارد جهت مدیریت ریسک نقدینگی تحت عنوان "نسبت پوشش نقدینگی"^۳ منتشر کرد. این نسبت برای بررسی اینکه آیا بانک دارایی‌های نقدشونده با کیفیت بالای کافی جهت پوشش نیازهای کوتاه‌مدت خود را داراست یا خیر، استفاده می‌شود و در عبارت ۱ نمایش داده شده است (پاپادامو و همکاران^۴، ۲۰۲۱):

$$LCR = \frac{\text{ذخیره دارایی های با کیفیت نقد شوندگی بالا}}{\text{جریان مالی خروجی 30 روز آینده - مجموع وجه نقد خالص}} \quad (1)$$

دومین استاندارد معرفی‌شده توسط کمیته بازل، "نسبت تأمین مالی پایدار خالص"^۵ است. این نسبت بیانگر میزان موفقیت در نحوه تامین مالی عملیات بانکی با منابعی باثبات‌تر است و هدف آن، ترویج تامین مالی میان‌مدت و بلندمدت برای بانک‌ها و در عبارت ۲ نشان داده شده است (پاپادامو و همکاران^۴، ۲۰۲۱):

$$NSFR = \frac{\text{مقدار موجود بودجه پایدار}}{\text{مقدار مورد نیاز بودجه پایدار}} \quad (2)$$

یکی از روش‌های تعریف و اندازه‌گیری ریسک نقدینگی استفاده از مدل نقدینگی تعدیل‌شده توسط ریسک سیستمی است. این مدل تئوری قیمت‌گذاری انتخابی را با اطلاعات بازار و داده‌های ترازنامه ترکیب می‌کند تا اندازه‌گیری احتمالی ریسک نقدینگی سیستماتیک را ایجاد کند (جابست^۶، ۲۰۱۴). یک روش جایگزین برای شناسایی و تحلیل ریسک نقدینگی، تخمین تابع توزیع احتمال آن است. رویکردی دیگر براساس مفهوم جریان‌های ورودی و خروجی مطابق با محدودیت جریان ۳ است و بیانگر آن است که بانکی که دارای نقدشوندگی

- 1 Tripe
- 2 Crouhy et al
- 3 Liquidity Coverage Ratio (LCR)
- 4 Papadamou et al
- 5 Net Stable Funding Ratio (NSFR)
- 6 Jobst

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 (درهمان و نیکولا، ۲۰۰۹):

$$\text{Outflow } s_t \leq \text{Inflow } s_t + \text{Stock of money} \quad (3)$$

متأسفانه تعداد مقالاتی که فاکتورهای ایجادکننده ریسک نقدینگی را تحلیل می‌کنند، اندک است. اندکی از محققان از شاخص‌های ترازنامه به عنوان فاکتورهای تعیین‌کننده ریسک نقدینگی استفاده کرده‌اند.

سلیمانی و همکاران (۱۳۹۹)، به بررسی عملکرد بانک‌های خصوصی پذیرفته شده در بورس اوراق بهادار تهران پرداختند. در این پژوهش از داده‌های چهار بانک تجاری صادرات، پست بانک، تجارت و ملت استفاده شده است و به تجزیه و تحلیل آماری داده‌ها از طریق روش آزمون تی- استیودنت و تجزیه و تحلیل واریانس با استفاده از شاخص‌های کلیدی عملکرد بانک‌ها بر اساس مدل کامل^۲ پرداخته شده است.

دهقانی احمدآباد و سعیدی کوشا (۱۳۹۹)، با تعریف شاخص نیاز نقدینگی به کمی‌سازی زبان ریسک نقدینگی با مدل‌های فرآیند تصادفی پرداختند. هدف اصلی آن‌ها، برآورد ارزش در معرض خطر و ارزش در معرض خطر شرطی زبان ناشی از ریسک نقدینگی در یکی از بانک‌های تجاری منتخب بوده است.

بزرگ اصل و همکاران (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. نتایج تحقیق بیان می‌کند که بانک‌هایی که در دهک‌های بالایی توزیع پایداری قرار دارند، تأثیرپذیری کمتری از ریسک‌های اعتباری و نقدینگی دارند.

اسماعیل‌زاده و جوانمردی (۱۳۹۶) بیان داشتند که چالش اصلی مدیریت ریسک نقدینگی، تامین 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. بر اساس نتایج بدست آمده بر اساس مدل آرچ و گارچ ضرایب مربوط به معادله واریانس شرطی جمله اختلال منفی و معنی‌دار می‌باشد. بنابراین از مدل برآوردی برای پیش‌بینی ریسک نقدینگی می‌توان استفاده کرد.

احمدی شالی و وصفی (۱۳۹۶) به پیش‌بینی نقدینگی بر اساس روش آریما و مقایسه آن با روش هموارسازی نمایی دوگانه پرداختند. در این تحقیق در کنار برآورد نقطه‌ای که ممکن است با تغییراتی که صورت می‌پذیرد تفاوت معنی‌داری داشته باشد، از برآورد بازه‌ای نیز استفاده شده است. نتایج حاصل از این تحقیق نشان می‌دهد که مدل آریمای پیشنهاد شده در مقایسه با روش هموارسازی نمایی دوگانه توانایی بالایی برای مدل‌سازی و پیش‌بینی میزان نقدینگی کشور را داراست.

کدائی 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

1 Drehmann & Nikolaou

2 Camel

تابلویی مبتنی بر داده‌های فصلی تعدادی بانک فعال در ایران پرداختند. یافته‌های تحقیق حاکی از آن است نوسانات متغیرهای تولید ناخالص داخلی، نرخ تورم، نرخ ارز و شاخص قیمت سهام به عنوان مهم‌ترین متغیرهای کلان اقتصادی، تأثیر مثبت و معناداری بر ریسک نقدینگی بانک‌ها دارند.

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. یافته‌های مربوط به بانک‌های نمونه نشان می‌دهد که بانک‌های اسلامی بیشتر از بانک‌های متداول و ترکیبی در معرض ریسک نقدینگی هستند. علاوه بر این، نتایج نشان می‌دهد که دارایی‌های نقدی و بدهی‌های بلند مدت با قرار گرفتن در معرض ریسک نقدینگی ارتباط مثبت دارند. در حالی که نتایج تجربی نشان می‌دهد بدهی بلندمدت به طور قابل توجهی بر ریسک نقدینگی تأثیر می‌گذارد.

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 اسکانلا^۳ (۲۰۱۶) ریسک نقدینگی نیازی به پوشش حقوق صاحبان سهام ندارد بلکه نیاز به حجم کافی از دارایی نقدینگی و اوارق بهادار نقد دارد. به همین 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 بانک‌ها بررسی کردند. آن‌ها به مقایسه فاکتورهای موثر بر ریسک نقدینگی در بانک‌های متعارف و بانک‌های اسلامی فعال در بنگلادش پرداختند. نتایج پژوهش بیانگر آن است که اندازه بانک و خالص سرمایه در گردش تأثیر مثبت و بی‌معنا بر ریسک نقدینگی در بانک‌های اسلامی دارند.

باسی و موسیس^۵ (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.

کنوولووا و زارمبو^۶ (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.

1 Sabri et al

2 Chen et al

3 Scannella

4 Rahman & Banna

5 Bassey & Moses

6 Konovalova & Zarembo

علی‌رغم قابلیت‌های فراوان ANN و BN، در مسائل اندازه‌گیری ریسک نقدینگی به‌ندرت از تکنیک‌های 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.

۳- بیان مساله

۳-۱- متغیرهای ورودی و مدل

با توجه به مدل مبتنی بر وام، باید از فاکتورهای 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 به عنوان شاخص‌های ریسک نقدینگی و متغیرهای ورودی مدل استفاده شوند. متغیرهای ورودی مدل این مقاله مطابق زیر (عبارات ۴) می‌باشد که در آن B برای نمایش "بانک ملت" و O برای نمایش "سایر بانک‌ها" می‌باشد:

$$\begin{aligned}
 X_1 &= \frac{\text{داراییهای نقدشونده } B}{\text{بدهیهای جاری } B}, & X_2 &= \frac{\text{اعتبارهای } B \text{ در } O}{\text{داراییهای نقدشونده } B}, & X_3 &= \frac{\text{سپرده های بلندمدت } B}{\text{سپرده های کوتاه مدت } B}, & X_4 &= \frac{\text{اعتبارهای } B \text{ در } O}{\text{اعتبارهای } O \text{ در } B} \\
 X_5 &= \frac{\text{مجموع وام } B}{\text{مجموع سپرده های } B}, & X_6 &= \frac{\text{اوراق قرضه } B}{\text{مجموع دارایی های } B}, & X_7 &= \frac{\text{سپرده های فرار } B}{\text{مجموع بدهی های } B}, & X_8 &= \frac{\text{سرمایه گذاری کوتاه مدت } B}{\text{مجموع دارایی های } B} \\
 X_9 &= \frac{\text{اعتبارهای } B \text{ در بانک مرکزی}}{\text{مجموع سپرده های } B}
 \end{aligned}
 \tag{۴}$$

۳-۲- متغیر خروجی

متغیر خروجی باید معیار ریسک نقدینگی را برای بانک 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 (عبارت ۵) اندازه‌گیری می‌شود:

$$X_{10} = \frac{\text{دارایی های جاری } B}{\text{بدهی های جاری } B} = \text{نسبت جاری}
 \tag{۵}$$

۳-۳- تابع ریسک نقدینگی

نسبت جاری مقدار نرمال حداقل یک را به خود اختصاص می‌دهد و هنگامیکه نسبت کنونی از این مقدار شروع به کاهش می‌کند، ریسک آشکار می‌شود. لذا، ریسک نقدینگی با استفاده از تابع رابطه ۶ به شرح زیر فرموله می‌شود:

$$L(X_{10}) = \begin{cases} 1 - x_{10} & \text{if } x_{10} < 1, \\ 0 & \text{otherwise} \end{cases} \quad (۶)$$

نسبت کل دارایی‌ها و کل بدهی‌ها در مقایسه با سایر رویکردهای ارزیابی ریسک نقدینگی در ادبیات موضوع، از محدود نسبت‌های مبتنی بر وام است که در حال حاضر به عنوان شاخص‌هایی برای اندازه‌گیری ریسک نقدینگی استفاده می‌شود. سایر نسبت‌هایی مانند LCR و NSFRR که در بخش‌های مقدماتی ذکر شد، بسیار پیچیده‌اند و اجرای آنها در سیستم 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.

۴- مدل پیشنهادی

۴-۱- معرفی رویکرد دوفازی شبکه‌های عصبی مصنوعی و بیزی

در این مقاله رویکرد پیشنهادی شبکه عصبی مصنوعی و بیزی دو فاز مکمل را تشکیل می‌دهند: در حالی که ANN برای تقریب روند کلی ریسک و یافتن دو مورد از تأثیرگذارترین فاکتورها به روشی غیرکارآمد استفاده می‌شود، BN تأثیرگذارترین فاکتور را پیدا می‌کند و احتمال وقوع ریسک نقدینگی را تعیین می‌کند. نتایج ریسک نقدینگی حاصل از ANN با نتایج حاصل از BN تکمیل می‌شود. پیاده‌سازی ANN مستقل از BN است و استفاده از خروجی یک شبکه به عنوان ورودی برای شبکه دیگر امکان‌پذیر نیست.

۴-۲- پارامترهای کلیدی و نقش آن‌ها در فرآیند یادگیری

در این مقاله 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 بهترین وزن‌ها را برای متغیرها پیدا می‌کند. پس از آموزش دیدن کافی شبکه، مقادیر هدف را تقریب زده و از این طریق روند ریسک نقدینگی را پیش‌بینی می‌کند. در فاز دوم، فرآیند یادگیری از طریق قانون بیز می‌باشد. 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.

۴-۳- فاز ۱: اندازه‌گیری ریسک نقدینگی

۴-۳-۱- شبکه عصبی مصنوعی پیشنهادی

شبکه عصبی پیشنهادی، یک پرسپترون چندلایه^۱ دارای ساختار پیشخور^۲ (FF) است. در این مقاله از دو الگوریتم بهینه‌سازی محبوب در ادبیات موضوع برای آموزش یعنی الگوریتم لوببرگ-مارکوآرت^۳ (LMA) و الگوریتم فراابتکاری ژنتیک^۴ (GA) استفاده کرده‌ایم. ژنتیک از قدرتمندترین تکنیک جستجو است که برای حل مشکلات بهینه‌سازی استفاده می‌شود. LMA از ژنتیک قوی‌تر است اما مانند بسیاری از الگوریتم‌های برازش منحنی، فقط مقدار حداقل محلی را پیدا می‌کند. برای جبران این نقص، به طور موازی از الگوریتم ژنتیک برای جستجوی فضای جواب‌های شدنی استفاده می‌کنیم.

۴-۴- فاز ۲: آنالیز شاخص‌های ریسک و رویکرد شبکه بیز پیشنهادی

در این مقاله از یک شبکه بیزی برای شناسایی مهم‌ترین شاخص‌های ریسک در میان متغیرهای مدل و آنالیز نحوه تأثیر آنها برهم و اندازه‌گیری ریسک نقدینگی، استفاده می‌کنیم. آموزش BN در این مقاله شامل سه مرحله به شرح زیر است:

• **مرحله ۱- یادگیری ساختار:** فضای گراف‌های بدون دور جهت‌دار باید کاهش یابد تا شامل ساختاری باشد که یال‌هایش شدنی است. لذا گراف بدون دور جهت‌دار بهینه باید شناسایی شود.

کاهش فضای گراف‌های بدون دور جهت‌دار: حل مساله یادگیری ساختار شبکه‌های بیزی، پیچیده و نمایی است و اگر گره‌ها زیاد باشد نمی‌توان جستجوی کامل را در زمان معقول انجام داد. لذا از روش‌های ابتکاری برای یافتن بهترین ساختار شبکه در بازه زمانی معقول استفاده می‌شود. 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 ۲- یادگیری پارامتر:** پس از تعیین روابط مناسب بین رأس‌ها، فرآیند 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 ۳- استنتاج:** مرحله محاسبه یک کمیت مفید از روی یک توزیع احتمال توأم.

1 Multi-layer perceptron (MLP)

2 Feed Forward (FF)

3 Levenberg-Marquardt

4 Genetic metaheuristic Algorithm (GA)

۵- مطالعه موردی: اجرای روش پیشنهادی

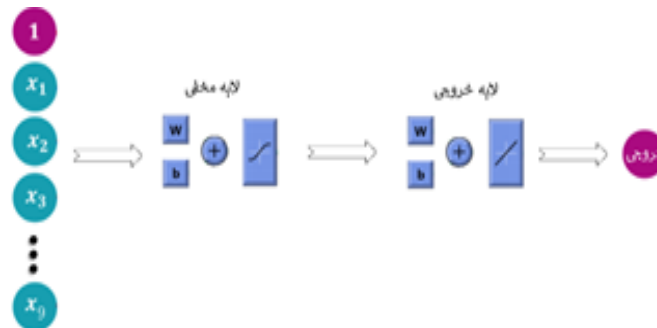
در این بخش نتایج بدست آمده با استفاده از روش پیشنهادی اندازه‌گیری ریسک نقدینگی را بر روی مجموعه‌ای از داده‌های واقعی ارائه شده توسط بانک ملت در بورس اوراق بهادار نشان می‌دهیم. مجموعه داده‌های جمع‌آوری شده مربوط به سال‌های ۱۳۹۰ تا ۱۳۹۶ است. همه نسبت‌ها نرمالیزه شده‌اند اما باید از طریق روش میانگین‌گیری استاندارد تعداد آنها افزایش یابد.

۵-۱- فاز ۱: اجرا توسط ANN

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

۵-۱-۱- ساختار شبکه

ساختار انتخابی برای 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 (شکل ۱). ارزیابی شبکه با استفاده از روش خطای میانگین مربعات^۱ (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

منبع: یافته‌های پژوهشگر

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.

1 Mean Squared Error (MSE)

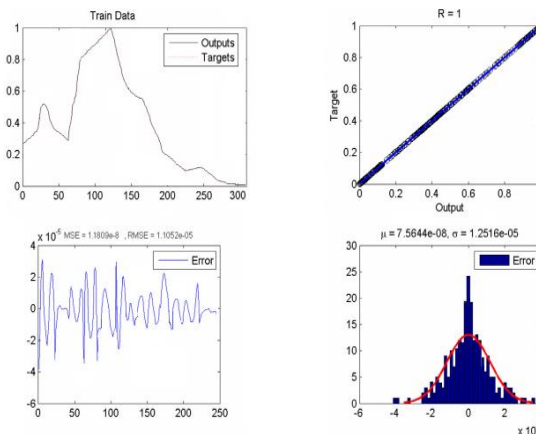
جدول ۱- مقایسه چند ساختار شبکه شذنی

ساختار شبکه	خطای میانگین مربعات	خطای استاندارد نسبی ^۱	همبستگی خروجی و هدف
۹-۱-۱	۲e-۲.۱	۲e-۱.۱	۰.۹۴
۹-۲-۱	-۳e۶.۸	-۳e۶.۲	۰.۰۹۶
۹-۳-۱	-۴e۱.۲	-۴e۱.۲	۰.۹۸
۹-۴-۱	-۴e۸.۳	-۳e۳.۹	۰.۹۸
۹-۵-۱	-۵e۳.۵	-۵e۱.۹	۰.۹۸
۹-۶-۱	-۶e۳.۳	-۶e۵.۳	۰.۹۹
۹-۷-۱	-۸e۵.۲	-۶e۷.۸	۱
۹-۸-۱	-۷e۷.۱	-۵e۴.۱	۱

منبع: یافته‌های پژوهشگر

۵-۱-۲- یادگیری ANN

فرآیند یادگیری توسط الگوریتم‌های LMA و ژنتیک اجرا شد. شکل‌های ۲ تا ۴ عملکرد LMA را در سه گروه 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 ۴ مربوط به کیفیت یادگیری توسط الگوریتم‌های ژنتیک و LMA است. هر نمودار ۴ زیرنمودار دارد. زیرنمودار بالا سمت چپ، خروجی‌ها و اهداف را برای مقایسه الگوی آموخته شده با واقعیت نشان می‌دهد، زیرنمودار بالا سمت راست، همبستگی بین خروجی‌ها و اهداف، زیرنمودار پایین سمت چپ، خطای میانگین مربعات خروجی‌ها و اهداف، و زیرنمودار پایین سمت راست، بررسی نرمال بودن توزیع باقی‌مانده‌ها را نشان می‌دهند.

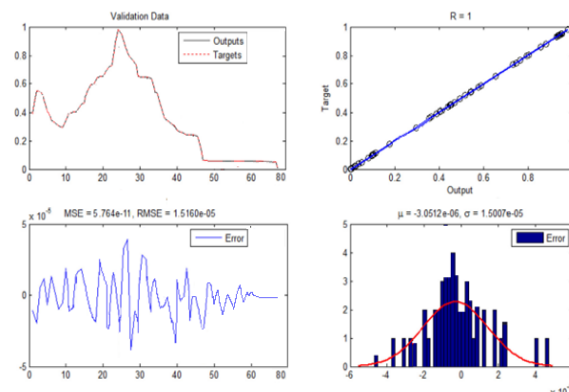


شکل ۲- ارزیابی فرآیند یادگیری بر روی داده‌های آموزش اجرا شده توسط LMA

منبع: یافته‌های پژوهشگر

1 Relative Standard Error (RSE)


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 ژنتیک وجود دارد. لذا ریسک نقدینگی در پایان توسط LMA مدل‌سازی خواهد شد. نمودارهای شکل‌های ۷ تا ۹ با نمایش روند خطاهای یادگیری، آنالیز عملکرد LMA و ژنتیک 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 فرآیند یادگیری بر روی داده‌های اعتبارسنجی اجرا شده توسط LMA

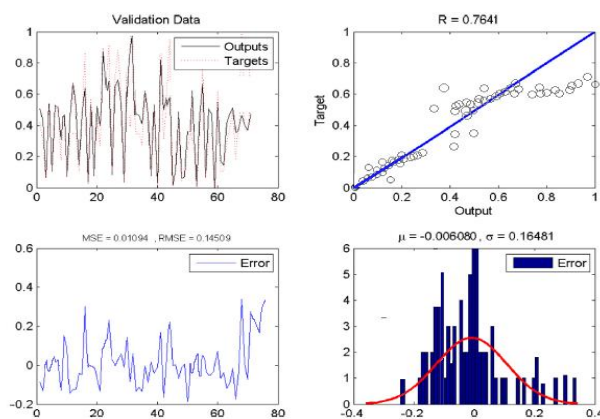
منبع: یافته‌های پژوهشگر

شکل ۹ مقایسه بین مقادیر هدف و مقادیر ریسک نقدینگی آموخته شده توسط LMA را نشان می‌دهد. باتوجه به زمان اجرای الگوریتم‌ها، LMA امکان پیاده‌سازی مطمئن را در مدت نسبتاً کوتاه فراهم می‌کند.



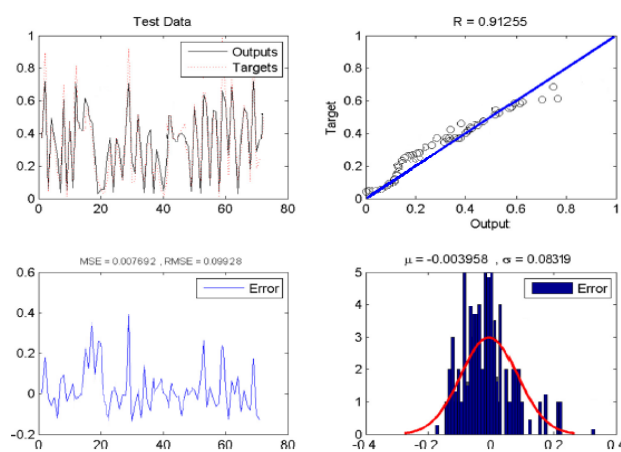
شکل ۴- ارزیابی فرآیند یادگیری بر روی داده‌های آزمایش اجرا شده توسط LMA

منبع: یافته‌های پژوهشگر



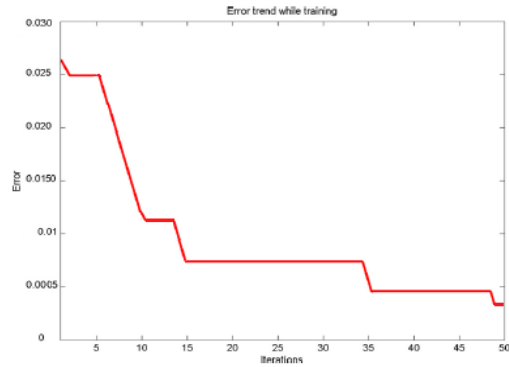
شکل ۵- ارزیابی فرآیند یادگیری داده‌های اعتبارسنجی اجرا شده توسط زنتیک

منبع: یافته‌های پژوهشگر




شکل ۶- ارزیابی فرآیند یادگیری داده‌های آزمایش اجرا شده توسط زنتیک

منبع: یافته‌های پژوهشگر



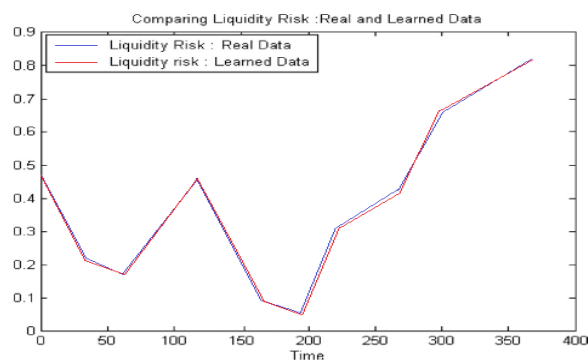
شکل ۷- روند نزولی خطای یادگیری توسط ژنتیک

منبع: یافته‌های پژوهشگر



شکل ۸- روند نزولی خطای یادگیری توسط LMA

منبع: یافته‌های پژوهشگر



شکل ۹- مقایسه مقادیر هدف و تابع ریسک نقدینگی آموخته شده توسط LMA

منبع: یافته‌های پژوهشگر

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


جدول ۲- مقایسه LMA با ژنتیک

ژنتیک	LMA	معیار مقایسه
۱۸۸ ثانیه	۹ ثانیه	زمان اجرا
۳e-۸.۶	۱۰e-۱.۱	خطای میانگین مربعات داده آموزش
-۲e۱.۱	-۱۰e۳.۱	خطای میانگین مربعات داده اعتبارسنجی
-۳e۷.۵	-۱۰e۱.۴	خطای میانگین مربعات داده آزمایش

منبع: یافته‌های پژوهشگر

۳-۱-۵- پیش‌بینی ریسک نقدینگی

به منظور پیش‌بینی ریسک نقدینگی، خروجی شبکه آموزش‌دیده بر اساس ماهیت این نوع ریسک در بانک‌ها به یک سری زمانی اتورگرسیون تبدیل شد. شکل ۱۰ توانایی شبکه آموزش‌دیده در پیش‌بینی ریسک نقدینگی بانک ملت را نشان می‌دهد. برای ارزیابی توانایی مدل پیش‌بینی ریسک و دقت آن، عملکرد ریسک نقدینگی تقریبی با داده‌های واقعی برای دوره زمانی مشابه مقایسه شد. نرخ خطای پیش‌بینی برای داده‌های گروه آزمایش ۰.۰۰۰۲۵۳ و برای داده‌های اعتبارسنجی ۰.۰۰۰۷۳۸ بود. در نتیجه با اجرای ANN پیشنهادی، پیش‌بینی ریسک با تیرانس پایین امکان‌پذیر شد.



شکل ۱۰- دقت پیش‌بینی در شبکه ANN

منبع: یافته‌های پژوهشگر

۵-۲- فاز ۲: اجرا توسط BN

در این فاز، موثرترین شاخص‌های ایجادکننده ریسک نقدینگی شناسایی شد. به عنوان یک نتیجه اولیه، می‌توان یکی از تولیدات ANN در فاز ۱ را در نظر گرفت. مقادیر جدول ۳ با استفاده از داده‌های گروه آزمایش بدست آمده و دو متغیر مرتبط را ارائه می‌دهند، یعنی جفت متغیری که بیشترین همبستگی را با تابع عملکرد ریسک دارند. براساس نتایج جدول ۲، تأثیرگذارترین شاخص‌های ریسک باید x_1 و x_5 باشد. با این وجود برای یافتن دو فاکتور مهم در میان ۹ متغیر ورودی، باید شبکه را به تعداد (۹) بار اجرا کنیم که از نظر محاسباتی کارا نیست. این نقص با اجرای BN رفع می‌شود. برای اجرای BN، باید داده‌ها را گسسته کنیم. لذا هر شاخص ریسک x_i به عنوان یک متغیر باینری به شرح رابطه ۷ تعریف می‌شود:

$$x_i = \begin{cases} 1 & \text{if } x_i \in I_i \\ 0 & \text{otherwise} \end{cases} \quad (7)$$

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

جدول ۳- همبستگی شاخص‌های ریسک مطالعه موردی از طریق اجرای شبکه ANN

متغیرهای ورودی	R	خطای جذر میانگین مربعات ^۱	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	۰.۱۵۵	۰.۰۰۵۳	۰.۰۰۶۶	۰.۰۰۷۳
x1, x5	۰.۹۴۲۸	۰.۰۱۷۶	-۰.۰۰۰۳	۰.۱۱۱	۰.۰۴۵۶	۰.۰۴۸۳	۰.۰۸۲۷
x1, x6	۰.۹۴۰۲	۰.۰۳۷۷	۰.۰۰۱۴	۰.۲۸۹	۰.۱۸۹۱	۰.۱۸۴۷	۰.۱۶۳۸
x1, x7	۰.۸۹۲۷	۰.۰۵۱۲	۰.۰۰۴۸	۰.۵۲۵	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	۰.۱۴۸	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	۰.۴۹۸	۰.۰۰۵۳	۰.۰۰۶۱	۰.۰۱۷۰
X2, x6	۰.۷۲۹۴	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	۰.۵۷۲	۰.۰۰۰۴	۰.۰۰۱۰	۰.۰۰۰۸
X3, x4	۰.۸۴۲۱	۰.۱۴۸۸	-۰.۰۰۱۲	۰.۱۹۸۳	۰.۰۲۵۲	۰.۰۲۶۳	۰.۰۲۶۳

1 Root-Mean-Square Error (RMSE)

متغیرهای ورودی	R	خطای جذر میانگین مربعات ^۱	μ	σ	عملکرد آموزش	عملکرد اعتبارسنجی	عملکرد آزمایش
X3, x5	۰.۹۲۵۲	۰.۰۵۲۴	۰.۰۲۸۰	۰.۰۴۳۸	۰.۰۰۴۵	۰.۰۰۴۱	۰.۰۰۱۹
X3, x6	۰.۹۸۸۰	۰.۱۰۴۳	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
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

منبع: یافته‌های پژوهشگر

جدول ۴- بازه‌ها/مقادیر نرمال برای شاخص‌های ریسک مطالعه موردی

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

منبع: یافته‌های پژوهشگر

۵-۲-۱- 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. هنگامیکه آن شاخص یک آزمون استقلال شرطی باشد، قدرت یک یال یک p-value است. امتیازات 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. براساس 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 کمان‌های بدست آمده توسط تابو را تأیید می‌کند.

جدول ۵- الگوریتم‌های یادگیری ساختار مورد استفاده در مطالعه موردی برای رویکرد BN

قدرت بوت	اعتبارسنجی متقابل	امتیازها	قدرت یال‌ها				الگوریتم یادگیری (تعداد آزمایش)
			X2 به X1	X4 به X1	X1 به X3	X5 به X3	
۰.۵۲۵ X2 به X5	۳.۳۲۱۵	-۱۱۶۵.۶۷	۰.۰۰۱۹	X4 به X5	۰.۰۰۰۱	X2 به X1	(۱۷۵) Gs
۰.۵۴۹۳			۰.۰۰۲۸	X4 به X6	۰.۰۰۰۰۳	X4 به X1	
۱.۰۰۰ X2 به X10			$e^{-۱.۴۰۱}$	X8 به X9	۰.۶۰۸۶	X1 به X3	
۰.۹۸۵۴			۱۵	X1 به X10	۰.۰۷۰۸	X5 به X3	
۰.۵۱۰ X1 به X4			۰.۴۹۹۸	X2 به X10	۰.۰۰۸۱	X2 به X5	
۰.۴۵۵۲			۰.۰۰۰۰۷				
۰.۱۷۶ X4 به X5							
۰.۷۸۹۵							

الگوریتم یادگیری (تعداد آزمایش)	قدرت یال‌ها	امتیازها	اعتبارسنجی متقابل	قدرت بوت
				X10 به X1 ۰.۵۰۰ ۰.۶۳۸۵
Iamb (۲۴۵)	X2 به X4 ۰.۰۰۰۹	X4 به X5 ۰.۰۰۱۴	۳.۱۰۹۸	X3 به X5 ۰.۵۴۳
	X10 به X2 ۰.۰۰۰۱	X6 به X7 ۰.۰۰۳۴		X1 به X4 ۰.۵۲۰
	X5 به X3 ۰.۰۷۱۰	X7 به X8 ۰.۰۰۰۰۷		X4 به X4 ۰.۶۴۰۰
	X1 به X4 ۰.۰۰۰۰۴	X8 به X9 ۰.۰۰۰۰۱		X2 به X4 ۱.۰۰۰
				X5 به X4 ۰.۸۹۰
				X6 به X7 ۰.۵۴۵
				X8 به X9 ۰.۵۲۰
				X1 به X10 ۰.۵۱۵
				X2 به X10 ۰.۵۱۰
				X9 به X4 ۰.۶۲۰۰
				X1 به X10 ۰.۹۸۰۳
				X2 به X10 ۰.۵۴۵۲
Fast.iamb (۱۷۶)	X3 به X1 ۰.۴۲۸۰	X4 به X5 ۰.۰۰۱۹	۳.۱۶۵۵	X2 به X2 ۰.۹۷۰۰
	X4 به X2 ۰.۰۰۰۰۸	X9 به X7 ۳.۳۱۴۳		X5 به X3 ۰.۵۶۵
	X10 به X2 ۰.۰۰۰۰۱	X9 به X8 ۰.۰۱۷۶		X3 به X3 ۰.۶۸۰۰
	X1 به X4 ۰.۰۰۰۰۱	X1 به X10 ۰.۰۰۰۰۴		X1 به X4 ۰.۵۲۰
				X5 به X4 ۰.۹۹۰
				X4 به X4 ۰.۷۵۰۰
				X5 به X4 ۰.۷۵۸۷
				X9 به X8 ۱.۰۰۰
				X3 به X5 ۰.۶۴۳۳
				X1 به X10 ۰.۵۴۰
				X7 به X5 ۰.۷۰۵۴


قدرت بوت	اعتبارسنجی متقابل	امتیازها	قدرت یال‌ها				الگوریتم یادگیری (تعداد آزمایش)
۱.۰۰۰ X4 به X1 ۰.۷۵۴۷	۲.۸۶۳۲	-۱۰۴۸.۲۴	-۵.۸۶۴۷	X7 به X6	-۹۵.۲۳۴۵	X4 به X1	Tabu (۳۲۰)
۰.۷۵۰ X10 به X1 ۰.۸۹۹۷			-۳.۳۶۰۱	X5 به X8	-۲۶.۲۰۹۴	X2 به X4	
۱.۰۰۰ X10 به X2 ۰.۷۲۰۳			-۱۸.۲۲۰۳	X10 به X1	-۲۵.۴۸۶۵	X9 به X8	
۰.۹۴۰ X2 به X4 ۰.۸۸۹۰			-۶.۲۰۱۴	X10 به X4	-۲۰.۳۸۲۶	X8 به X7	
۰.۹۵۵ X5 به X4 ۰.۹۱۲۰			-۲.۰۰۱۳	X3 به X5	-۱۸.۲۸۹۶	X10 به X2	
۰.۸۲۰ X3 به X5 ۰.۷۵۳۸۱							
۰.۸۵۰ X6 به X7 ۰.۷۲۰۰							
۰.۵۵۵ X5 به X8 ۰.۷۴۶۵							
۰.۹۷۰ X7 به X8 ۰.۸۲۵۶			-۱.۸۵۹۶	X1 به X9	-۲۱.۱۵۴۴	X5 به X4	
۰.۹۲۰ X4 به X9 ۰.۶۵۵۴							
۰.۹۲۰ X8 به X9 ۰.۷۶۰۰							
۰.۸۲۰ X4 به X10 ۰.۵۹۳۸							

منبع: یافته‌های پژوهشگر

جدول ۶- آزمون استقلال شرطی در شبکه بیز آموخته شده در مطالعه موردی

یال‌ها	ci.test
x9 → x1	۰.۰۰۳۸۹, p-value = ۱, df = ۱۰.۴۳۹mi =
x1 → x4	۰.۰۰۰۴, p-value < ۱, df = ۱۴۲.۸۹mi =
x4 → x2	۰.۰۰۰۲, p-value = ۱, df = ۴۳.۳۹۰mi =
x8 → x9	۰.۰۰۶۴, p-value = ۱, df = ۵۹.۵۴۳mi =
x7 → x8	۰.۰۰۰۵, p-value = ۱, df = ۶۱.۱۴۲mi =
x2 → x10	۰.۰۰۴۲, p-value = ۱, df = ۵۱.۵۱۲mi =
x4 → x5	۰.۰۰۵۴, p-value = ۱, df = ۶۵.۵۶۱mi =
x9 → x4	۰.۰۰۳۲, p-value = ۱, df = ۲۳.۹۰۲mi =
x6 → x7	۰.۰۰۴۶, p-value = ۱, df = ۲۸.۴۶۳mi =
x8 → x5	۰.۰۰۰۲, p-value = ۱, df = ۱۱.۴۵۳mi =
x1 → x10	۰.۰۲۴۵, p-value = ۱, df = ۴.۹۰۳mi =
x4 → x10	۰.۰۳۶۳, p-value = ۱, df = ۳.۵۳۵mi =
x5 → x3	۰.۰۰۰۷, p-value = ۱, df = ۱۲.۷۴۶mi =
x1, x9 x4	۰.۰۰۱۰, p-value = ۲, df = ۳۳.۱۶۵mi =
x4, x8 x5	۰.۰۱۰۵, p-value = ۲, df = ۲۷.۴۵۶mi =
x1, x2 x10	۰.۰۰۰۰۰۲, p-value < ۲, df = ۲۷۳.۲۱۹mi =
x1, x4 x10	۰.۰۰۰۳, p-value = ۲, df = ۶۸.۳۴۵mi =
x2, x4 x10	۰.۰۰۰۴, p-value = ۲, df = ۶۹.۸۳۴mi =

منبع: یافته‌های پژوهشگر



شکل ۱۱- شبکه بیزی آموزش داده شده برای تعیین تأثیرگذارترین شاخص‌های ریسک

منبع: یافته‌های پژوهشگر

۵-۲-۲- 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 و نتایج مقایسه شده است. از دو معیار ارزیابی برای امتیازدهی BN برآزش شده استفاده شده است که برای آن‌ها مقدار احتمال ورود به سیستم از رابطه ۸ بدست می‌آید:

$$-2 \times \log \text{-likelihood} + k \times npar, \quad (8)$$

که در آن npar تعداد پارامترهای مدل برآزش شده می‌باشد، $k=2$ برای AIC معمول و $k = \log(n)$ با تعداد n مشاهده، برای BIC یا SBC (معیاری شوارتز) می‌باشد. ما در این مقاله مقادیر زیر را بدست آوردیم (شایان ذکر است که هرچه مقدار حاصل بیشتر باشد بهتر است):

$$AIC = -1030.223, BIC = -1086.245$$

۵-۲-۳- استنتاج

پس از برآورد پارامتر، دریافتیم که عوامل موثر در ریسک نقدینگی چیست و طبقه‌بندی فاکتورها 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_1 و x_5 مهمترین فاکتورها هستند. توجه کنید که پس از محاسبه پارامتر، در واقع می‌توانیم با توابع احتمال مشترک، شرطی و حاشیه‌ای به هر سوالی در مورد ریسک نقدینگی و فاکتورهای آن پاسخ دهیم.

جدول ۷- تأثیر هر شاخص ریسک بر ریسک نقدینگی

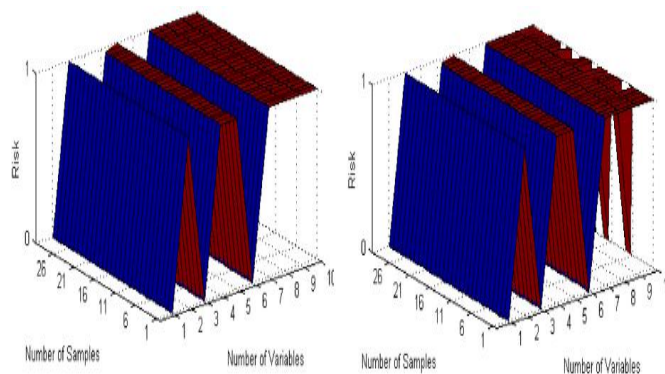
شاخص	تأثیر شاخص بر ریسک نقدینگی (وقتی شاخص‌های دیگر وضعیت نرمال را نشان می‌دهند)
شاخص اول	۰.۷۵۸۳۲۱
شاخص دوم	۰.۴۶۲۳۵۰
شاخص سوم	۰.۴۲۱۰۶۰
شاخص چهارم	۰.۳۸۹۶۴۶
شاخص پنجم	۰.۶۵۴۵۰۰
شاخص ششم	۰.۴۲۹۸۸۱
شاخص هفتم	۰.۴۳۵۴۸۵
شاخص هشتم	۰.۰۵۲۶۳۸

شاخص	تأثیر شاخص بر ریسک نقدینگی (وقتی شاخص‌های دیگر وضعیت نرمال را نشان می‌دهند)
شاخص نهم	۰.۴۴۲۹۰۸

منبع: یافته‌های پژوهشگر

۵-۳- نکاتی در مورد تست و اعتبارسنجی

برای اعتبارسنجی روش‌های اعمال شده، هنگام تقریب یک تابع توسط ANN، از معیارهایی مانند انحراف (باپاس)، 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 تکنیک‌های 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 X_1 تا X_{10} ، 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 مشاهده می‌شود شبکه توانست تابع توزیع احتمال را به درستی تخمین بزند. تورفتگی و دندان‌های شکل بیانگر اشتباهات شبکه هنگام انجام تخمین می‌باشد.



شکل ۱۲- توزیع احتمال داده‌های واقعی در مقابل توزیع احتمال نمونه‌های آموخته شده

منبع: یافته‌های پژوهشگر

۶- 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، به ندرت به مسائل اندازه‌گیری ریسک نقدینگی با استفاده از این تکنیک‌های 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 تحقیق به عنوان 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 فاکتورهای ریسک و اندازه‌گیری ریسک از طریق توابع عملکردی تخمین و برآورد توزیعی هستند. هر دو مدل از طریق فرآیندهای آموزش و یادگیری خاص خود مورد ارزیابی قرار گرفتند و نتایج بسیار سازگاری حاصل شد. نتایج عددی به دست آمده 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. به عنوان پیشنهادهایی برای تحقیقات آتی، توسعه مدل پیشنهادی در محیط پویا به کمک BNNهای پویا و استفاده از تکنیک‌های یادگیری ماشین بدون نظارت می‌باشد

فهرست مراجع

- ۱) احمدی شالی، جعفر، وصفی، مهدی، ۱۳۹۶، پیش‌بینی نقدینگی بر اساس برآورد نقطه‌ای و بازه‌ای روش آریمو و مقایسه آن با روش هموارسازی نمایی دوگانه، فصلنامه اقتصاد مالی، دوره یازدهم، شماره ۴۰، صفحه ۱۵۹ تا ۱۷۵.
- ۲) اسماعیل زاده، علی و جوانمردی، حلیمه، ۱۳۹۶، طراحی الگویی مناسب مدیریت نقدینگی و پیش‌بینی ریسک آن در بانک صادرات ایران، فصلنامه اقتصاد مالی، دوره یازدهم، شماره ۳۹، صفحه ۱۷۱ تا ۱۹۱.
- ۳) بزرگ اصل، موسی و برزیده، فرخ و صمدی، محمد تقی، 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، دوره یازدهم، شماره سی و هشتم.
- ۴) دهقانی احمدآباد، محمدرضا و سعیدی کوشا، مهدی، ۱۳۹۹، برآورد سنجه‌های ریسک زیان نقدینگی در بانک‌های تجاری با استفاده از فرآیندهای تصادفی، فصلنامه راهبرد مدیریت مالی، دوره ۸، شماره ۲.
- ۵) سلیمانی، برنا، نعمتی، مهرداد، الماسی، حسن، ۱۳۹۹، ارزیابی عملکرد بانک‌های خصوصی در بورس اوراق بهادار تهران بر اساس مدل CAMEL، فصلنامه اقتصاد مالی، دوره چهاردهم، شماره ۵۰، صفحه ۱۱۵ تا ۱۴۴.
- ۶) کدائی، محمدعلی و راهزانی، محبوبه، ۱۳۹۵، بررسی تاثیر ناطمینانی کالن اقتصادی بر ریسک نقدینگی بانکهای ایران، فصلنامه پژوهشنامه اقتصادی، سال شانزدهم، شماره ۶۲، پاییز ۱۳۹۵، ۳-۶۲.

- 7) 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, Vol. 3, Issue 4, pp.1-24.
- 8) Chen, Y.K, Shen, H.H, Kao, L., 2018, Bank Liquidity Risk and Performance. Review of Pacific Basin Financial Markets and Policies., 21(1).
- 9) Crouhy, M., Galai, D., Mark, A., 2000, A Comparative Analysis of Current Credit Risk Models, Journal of Banking and Finance, Vol. 24, No. 1-2, P 59-117.
- 10) Drehmann, M., Nikolaou, K., 2009, Funding Liquidity Risk: Definition and Measurement, European Central Bank, Working Paper Series March, No. 1024.
- 11) Jobst, A. A., 2014, Measuring Systemic Risk-adjusted Liquidity (SRL): A Model Approach, J. Bank. Financ, 45 270-287.
- 12) Konovalova, N., and Zarembo, J., 2015, Imbalanced Liquidity Risk Management: Evidence from Latvian and Lithuanian Commercial Banks, Copernican Journal of Finance and accounting, vol4, No 1.
- 13) Marz , L., Neu, p., 2007, Scenario Analysis and Stress Testing, in Liquidity Risk Measurement and Management, John Wiley & Sons Inc, New Jersey, pp. 37-64 .
- 14) Musakwa, F.T, 2013, Measuring Bank Funding Liquidity Risk, Retrieved from Actuaries.org, 10.
- 15) Papadamou, S., Sogiakas, D., Sogiakas, V., Toudas, K. 2021, The Prudential Role of Basel III liquidity Provisions towards Financial Stability, Journal of forecasting.
- 16) 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.
- 17) 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.
- 18) Scannella, E., 2016, Theory and Regulation of Liquidity Risk Management in Banking, International Journal of Risk Assessment and Management, Vol.19 No.1/2, pp.4 – 21.
- 19) Tripe, D., 1999, Liquidity Risk in Banks – A New Zealand Perspective, New Zealand, Massey University, 42.
- 20) 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.

Presenting a Comprehensive Model for Measuring the Liquidity Risk of Banks Listed on the Tehran Stock Exchange (Case Study: Mellat Bank)

Toraj Azari¹
Mojtaba Tasori²
Reza Tehrani³

Received: 04/ April/2022 Accepted: 09/ June/2022

Abstract

Lack of liquidity management of banks is one of the most important risks for any bank and lack of attention to liquidity risk leads to irreparable consequences. Preventing liquidity risk requires a comprehensive measurement method but liquidity risk is a 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 measure its value is a difficult task. To address these problems and assess liquidity risk and its key factors, 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 model. In this paper, we have used Levenberg-Marquardt and Genetic optimization algorithms to train 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, Machine Learning, Artificial Neural Network, Bayesian Network

JEL Classification: G32, G24, D83, C45, C11

1 Management and Accounting, Kish International Unit, Islamic Azad University, Tehran, Iran
azaritooraj@yahoo.com.

2 Management and Accounting, Kish International Unit, Islamic Azad University, Tehran, Iran (author and responsible) dastoori@ut.ac.ir

3 Management and Accounting, Kish International Unit, Islamic Azad University, Tehran, Iran
iranrehrani@ut.ac.ir

