

An Artificial Neural Network and Bayesian Network Model for Liquidity Risk Assessment in Banking¹

Mehrdad Farahabadi², Reza Eivazlou³, Hossein Safari⁴

Received: 2022/03/16

Accepted: 2022/08/22

Research Paper

Abstract

Active Banks in the recent economic environment are obliged to encounter in a massive gamut of risks which are closely following them. If cash is regarded as equivalent cash or cash at hand, then Liquidity risk is a kind of loss which arises of lack of fund or more specifically endured loss originating from inability of funding required capital in a reasonable way or selling off assets or being forced to have them pledged in order to cover solicited or unsolicited commitments. Hence Liquidity risk is comprised of economic loss incurred due to of providing cash and is deemed vital for operational activities of enterprises. Liquidity Mismatch in banks or maturity mismatch of sensitive assets to cash or debt may culminate in divergent of cash inflow or outflow during elapse of time which is actually stressed as Liquidity risk. In this study quarterly performance of 23 quoted banks in either Tehran Stock Exchange or Iran Farabourse are executed to model forecasted Banks' Liquidity risk by means of implementing Artificial Neural Network algorithms. Applying genetic algorithm and Levenberg–Marquardt algorithm helped utilizing the best Training method and subsequently by facilitating Principal Component Analysis (PCA) method, we managed to optimize independent variables. Finally having hidden layers been determined and exercising calculations by Bayesian network model, the artificial neural network is modeled and tested. All the mentioned process is performed by MATLAB software. Eventually fulfilling the asserted stages, a robust model for anticipating listed banks' Liquidity risk is developed and findings of models for forecasted data is elaborated.

Key Words: Liquidity Risk, Artificial Neural Network, Genetic Algorithm, Levenberg–Marquardt Algorithm, Principal Component Analysis (PCA).

JEL Classification: C45, G21.

1. DOI: 10.22034/JSE.2021.11606.1715

2. Ph.D. Student, Department of Financial Engineering, Kish International Campus, Tehran University, Kish, Iran. (Corresponding Author).

3. Assistant Professor, Department of Financial Management, Faculty of Management, Tehran University, Tehran, Iran.

4. Associate Professor, Department of Industrial Management, Faculty of Management, Tehran University, Tehran, Iran.



سازمان بورس و اوراق بهادار، مرکز پژوهش، توسعه و مطالعات اسلامی

فصلنامه بورس و اوراق بهادار، سال پانزدهم، شماره ۵۹، پاییز ۱۴۰۱، صص ۱۵۶-۱۲۱

بکارگیری شبکه هوش مصنوعی و مدل شبکه بیزین برای پیش‌بینی ریسک نقدینگی در صنعت بانکداری^۱

مهرداد فرح آبادی^۲، رضا عیوضلو^۳، حسین صفری^۴

تاریخ دریافت: ۱۴۰۰/۱۲/۲۵

تاریخ پذیرش: ۱۴۰۱/۰۵/۳۱

مقاله پژوهشی

چکیده

بانکهایی که در محیط اقتصادی کنونی فعالیت می‌کنند، باید با طیف وسیعی از ریسک‌هایی که در تعقیب آنها هستند، مقابله کنند. چنانچه نقدینگی را در دسترس بودن وجه نقد یا معادلهای نقد در نظر بگیریم، می‌توانیم ریسک نقدینگی را ریسک زیان ناشی از فقدان نقدینگی یا معادل نقد و یا بطور دقیق‌تر ریسک زیان ناشی از عدم توانایی در تأمین منابع مالی مورد نیاز در سطح معقول اقتصادی و یا اجبار به فروش دارایی یا توثیق آن به منظور پوشش تعهدات خواسته یا ناخواسته قلمداد کرد. در این پژوهش با بررسی عملکرد فصلی ۱۰ ساله (۱۳۸۹-۱۳۹۹) ۲۳ بانکهای پذیرفته شده در بورس اوراق بهادار تهران و فرابورس ایران با استفاده از شبکه هوش مصنوعی مدلی برای پیش‌بینی ریسک نقدینگی بانکها ارائه شده است. در این پژوهش با استفاده از الگوریتم لونبرگ مارکوارت^۵ (LM) و الگوریتم ژنتیک^۶ بهترین روش آموزش انتخاب و سپس به منظور بهینه سازی متغیرهای مستقل ورودی مدل، الگوریتم تحلیل مولفه اصلی^۷ (PCA) بکار گرفته شده است. در نهایت پس از تعیین تعداد لایه‌های بهینه نهانی و بهره‌گیری از شبکه مدل بیزین (BN) شبکه عصبی طراحی و ریسک نقدینگی بانکهای پذیرفته شده در بازار سرمایه کشور مدل‌سازی و نتایج تحلیل یافته‌های حاصل از پیش‌بینی این مدل ارائه شده است.

واژه های کلیدی: ریسک نقدینگی، شبکه هوش مصنوعی، الگوریتم ژنتیک، الگوریتم لونبرگ مارکوارت، الگوریتم تحلیل مولفه اصلی (PCA).

طبقه بندی موضوعی: G21 , C45.

DOI : 10.22034/JSE.2021.11606.1715

۲. دانشجوی دکترا، گروه مهندسی مالی، پردیس کیش، دانشگاه تهران، کیش، ایران. (نویسنده مسئول).

۳. استادیار، گروه مدیریت مالی، دانشکده مدیریت، دانشگاه تهران، تهران، ایران.

۴. دانشیار، گروه مدیریت صنعتی، دانشکده مدیریت، دانشگاه تهران، تهران، ایران.

5. Levenberg-Marquardt Algorithm

6. Genetic Algorithm

7. Principal Component Analysis

مقدمه

بطور کلی بازارهای پولی به عنوان منبع اصلی تأمین مالی کوتاه مدت نقشی اساسی در تولید و اشتغال بنگاههای اقتصادی هر کشور ایفا می کنند. بانکهای تجاری در کنار دیگر مؤسسات پولی و اعتباری از اصلی ترین بازیگران این بازارها محسوب می شوند. بانکهای تجاری با جذب انواع سپرده های کوتاه مدت و بلند مدت مبادرت با اعطای انواع وام، اعتبار و خدمات تضامین به اشخاص و بنگاههای تجاری می کنند. از طرفی بانکهای تجاری بدلیل رعایت الزامات کفایت سرمایه تعیین شده توسط بانکهای مرکزی مستلزم تأمین منابع مالی مورد نیاز از طیف وسیعی از سپرده گذاران به منظور رعایت حداقل سرمایه تعیین شده توسط مراجع نظارتی هستند. از آنجائیکه بانکها از بزرگترین بازیگران بازارهای پول محسوب می شوند وظایف خطیری را در حفظ منافع ذینفعان گوناگونی چون سپرده گذاران، سرمایه گذاران (فعلی و بالقوه)، دولتها، بنگاههای اقتصادی و غیره بر عهده دارند. مدیریت صحیح منابع نقدینگی بانک از وظایف بسیار مهمی است که بر عهده مدیران اجرایی آنها قرار داده شده است که به دلایل پیش گفته همواره از اهمیت بسیار زیادی برخوردار بوده هست (ونکت و دیگران، ۲۰۱۶). بانکها به عنوان بزرگترین نهادهای مالی در بازارهای مالی همواره در معرض انواع ریسکهای مالی قرار دارند. ریسکهای مالی متشکل از انواع ریسکهای نقدینگی به همراه ریسک اعتباری، ریسک عملیاتی و ریسک بازار است. از آنجائیکه مدیریت ریسک نقدینگی و کنترل عدم تقارن سررسیدهای سپرده های بانکی و وامها به عنوان یکی از نگرانی های جدی مدیران بانکی محسوب می شود، در پژوهش حاضر از زاویه عدم تطابق زمانی درآمدها و مخارج بانکها و پس از این، منابع ورود و خروج نقدی ناشی از این منابع به ریسک نقدینگی نگریسته شده است. با توجه به اینکه تاکنون ریسک نقدینگی همواره در سیطره دیگر ریسکهای مالی همچون ریسکهای اعتباری قرار داشته و همواره از منظر این ریسکها بدان نگریسته شده است، به این مقوله در صنعت بانکی کمتر پرداخته شده که این موضوع نیز ضمن اینکه تعریفی جامع و مانع برای ریسک نقدینگی را با اشکالاتی همراه می سازد، مسأله تعریف عوامل تعیین کننده بر مدل سازی و پیش بینی میزان ریسک نقدینگی را نیز بیشتر به دلیل وجود روندهای پیچیده زمانی و رفتارهای تصادفی در داده های مربوط به این مسأله، به عنوان امری پیچیده به وجود آورده است. اگر نقدینگی را قابلیت در دسترس بودن وجه نقد یا معادل آن در نظر بگیریم، پس می توان ریسک نقدینگی را به ریسک زیان ناشی از عدم توانایی در تأمین نقدینگی به شیوه ای معقول و اقتصادی یا فروش

یا توثیق دارایی‌ها به ارزش دفتری به منظور پوشش تعهدات پیش‌بینی شده یا نشده دانست. بنابراین ریسک نقدینگی می‌تواند به عنوان ریسک زیان اقتصادی متحمل شده در تلاش برای ایمن‌سازی وجه نقد شمرده شود که برای فعالیتهای تجاری بسیار حیاتی است (بنکس، ۲۰۱۴). همچنین ریسک نقدینگی ریسک بالفعل یا بالقوه ناشی از عدم توانایی یک موسسه در ایفای تعهدات یا بدهی‌های سررسید شده بدون تحمل زیانهای غیرقابل قبول نیز تعریف شده است (سوپرانو، ۲۰۱۵). در مطالعات اخیر، ریسک نقدینگی بیشتر به ریسکی گفته می‌شود که بانکها قادر به ایفای تعهدات کوتاه مدت خود (همچون بازپرداخت تعهدات ناشی از سپرده‌ها) در زمان مناسب و با تحمل هزینه معقول و مناسب نیستند. به عبارتی در تبیین ریسک نقدینگی توجه به سه عامل: ۱) توانایی بازپرداخت و ایفای تعهدات توسط بانک؛ ۲) هزینه تأمین نقدینگی لازم و ۳) فوریت تأمین نقدینگی از اهمیت بالایی برخوردار است. در اینجا باید به مرزبندی صحیح و مناسب به منظور دوری از درهم آمیخته شدن موضوعات وابسته به ریسک نقدینگی و ریسک اعتباری نیز توجه شود. ممکن است یک بانک لزوماً دچار بحرانهای اعتباری نبوده و از رتبه‌های اعتباری مناسبی از سوی مؤسسات رتبه بندی اعتباری برخوردار باشد که به منزله شایستگی اعتباری بالای بانک در ایفای تعهدات بلندمدت یا به عبارتی توانمندی و تمایل بانک در ایفای تعهدات و نیز کمترین میزان آسیب پذیری از تغییرات متغیرهای کلان اقتصادی و صنعت بوده اما همواره از میزان ریسک نقدینگی بالایی برخوردار باشد. از این روست که در مطالعات صورت گرفته در مجامع آکادمیک کمتر به مقوله ریسک نقدینگی پرداخته شده و بیشتر ریسکهای اعتباری بانکها مورد ارزیابی و سنجش قرار گرفته‌اند (توانا و دیگران، ۲۰۱۸). یکی از مسائل اساسی در شناسایی و اندازه‌گیری ریسک نقدینگی، فقدان سیستمی ساده و قابل تجزیه و تحلیل برای اندازه‌گیری ریسک نقدینگی و پس از آن به کارگیری آنها توسط مدیران بانکهاست. در نبود چنین نگاهی ضمن عدم توجه به همه عوامل تأثیرگذار بر ریسک نقدینگی، بانکها هر ساله هزینه‌های هنگفتی را به دلیل عدم مدیریت مناسب ریسک نقدینگی متحمل می‌شوند. ارایه الگویی درست برای اندازه‌گیری ریسک نقدینگی بانک و تجزیه و تحلیل عوامل کلیدی مؤثر بر آن و روابط داخلی میان این عوامل و در نهایت تعیین حد مطلوب پذیرش این ریسک توسط هر بانک از محورهای اصلی مورد بحث در این پژوهش است. این پژوهش بر آن است تا با استفاده از شبکه‌های هوش مصنوعی و الگوریتم‌های تکوینی عوامل کلیدی مؤثر یادشده را به عنوان یک معیار تقریبی برای تخمین ریسک نقدینگی مورد برآورد قرار داده و با

استفاده از شبکه‌های بیزین به تخمین و تجزیه و تحلیل تابع توزیع ریسک نقدینگی مورد استفاده مبادرت کند. در نهایت با استفاده از الگوریتم‌ها و شبکه‌های یادشده سطح ریسک نقدینگی در هر یک از بانکهای مورد مطالعه مدل‌سازی می‌شود.

مروری بر پیشینه پژوهش

در ادامه برخی از پژوهش‌های تجربی که در حوزه‌های بین‌المللی و مرتبط با ارزیابی و مدل‌سازی ریسک نقدینگی بانکها انجام شده‌اند به کوتاهی مورد بحث و بررسی قرار می‌گیرند: مجید توانا، امیر رضا ابطی، دهورا دی کاپریو و مریم پور طریق (توانا و دیگران، ۲۰۱۸)، در پژوهشی با استفاده از شبکه هوش مصنوعی و مدل شبکه بیزین به پیش‌بینی ریسک نقدینگی در صنعت بانکداری پرداختند. این پژوهش مدلی را با استفاده از شبکه‌های هوش مصنوعی و شبکه بیزین پیشنهاد داده است. استفاده از این دو سیستم هوشمند الگوریتم‌های مختلفی را در برداشته که اعتبار مدل را آزمون می‌کنند. در این پژوهش از یک مطالعه در دنیای واقعی برای نشان دادن قابلیت کاربرد آن استفاده شده است و کارایی، دقت و انعطاف پذیری روشهای داده کاوی را هنگامی که رخدادهای پیچیده مدل‌سازی با معیار ریسک نقدینگی بانکها در ارتباط هستند را نشان می‌دهد.

عدنان خاشمن (خاشمن، ۲۰۱۰) در پژوهشی از شبکه عصبی برای ارزیابی ریسک اعتباری استفاده کرد. وی همچنین از مدل‌های عصبی مختلف، طرحهای یادگیرنده و سیستم‌های خبره برای این مقصود استفاده کرد. در این پژوهش سیستمی برای ارزیابی ریسک اعتباری معرفی می‌شود که از مدل‌های شبکه عصبی کنترل شده بر پایه الگوریتم‌های یادگیری استوار بر تکثیر استفاده می‌کند. همچنین در این پژوهش از سه شبکه عصبی برای تصمیم‌گیری راجع به اینکه رویکرد اعتباری قبول یا رد شود، استفاده شده است. ارزیابی و امتیازدهی اعتباری، یکی از تکنیک‌های کلیدی تحلیل در ارزیابی ریسک اعتباری است که زمینه‌ای فعال برای انجام پژوهش‌ها در بخش ریسک مالی بوده است.

فلیکس جی لوپز اتیوریکا و ایوان پاستور سانز (لوپز و دیگران، ۲۰۱۵)، در پژوهشی به تصویرسازی و پیش‌بینی ورشکستگی با استفاده از شبکه‌های عصبی پرداختند. در این مقاله که به مطالعه بانکهای تجاری در آمریکا پرداخته و از سیستم‌های خبره نیز کمک گرفته شده است، مدلی از شبکه‌های عصبی برای مطالعه ورشکستگی بانکها در ایالات متحده آمریکا با در نظر

گرفتن جنبه‌های خاص بحران مالی اخیر، در نظر گرفته شده است. در این پژوهش پرسپترون چند لایه‌ای و نقشه‌های خود سازماندهی شده برای نشان دادن ابزاری که احتمال بحران مالی را تا سه سال قبل از وقوع نشان دهند، ترکیب شده‌اند.

چن فانگ شی و جن وی وو (شی و دیگران، ۲۰۱۷)، در مقاله‌ای با استفاده از شبکه‌های عصبی تجمیعی به پیش‌بینی ورشکستگی و امتیاز اعتباری شرکتهای تجاری پرداختند. در این مقاله با استفاده از شبکه‌های عصبی مبتنی بر سه گروه از داده‌ها، عملکرد گروه‌بندی منفرد به عنوان مبنای اصلی در مقایسه با گروه‌بندی چندگانه و گروه‌بندی متنوع مورد بررسی قرار گرفتند. در قیاس با گروه‌بندی منفرد به عنوان شاخصی برای دقت میانگین برآورد، گروه‌بندی چندگانه تنها در یکی از مجموعه داده‌ها عملکرد بهتری داشته‌اند. گروه‌بندی متنوع در هر حال عملکرد ضعیف‌تری را به نمایش گذارده‌اند.

چندانگ هانگ، جیند هایو، مین ژائو و سایرین (هانگ و دیگران، ۲۰۱۶)، با استفاده از شبکه‌های عصبی پیچیده و کاربرد ریاضیات به تجزیه و تحلیل شبکه‌های عصبی پیچیده کسری استوار بر ارزش پرداختند. در این مقاله برای نخستین بار ثبات و تفکیک طبقات مختلفی از شبکه‌های عصبی پیچیده کسری استوار بر ارزش مورد بررسی قرار گرفته است. تابع مورد استفاده در این موارد می‌تواند بوسیله جداسازی بخشهای واقعی و مجازی آن توضیح داده شود. با استفاده از تأخیر زمانی به عنوان پارامتر تفکیک، رفتارهای دینامیکی که ثبات پذیری‌های بدون علامت محلی را شامل می‌شوند مورد بحث و بررسی قرار گرفته تا شرایط ضرورت انجام تفکیک فراهم شود. افزون بر آن مشخص شد، نقطه شروع تفکیک می‌تواند همزمان با افزایش سفارشها افزایش یابد. در نهایت نمونه‌ای کاربردی برای صحت‌گذاری بر درستی نتایج بدست آمده ارایه شد.

ویو لوی، زیدانگ وانگ، ژائو هو لیو و سایرین (لوی و دیگران، ۲۰۱۷) به بررسی معماری عمیق در شبکه‌های عصبی و کاربرد آنها در علوم کامپیوتری پرداختند. در این پژوهش، برخی از معماری‌های یادگیری سریع که بطور گسترده‌ای مورد استفاده قرار می‌گیرند به همراه کاربردهای آنها مورد بحث و بررسی قرار گرفت. سپس برای چهار معماری یادگیری سریع به نام‌های: شبکه‌های عصبی ثبت خودکار، محرمانه، باور عمیق و ماشین محدود شده بولتزمن یک رویکرد به روز رسانی شده‌ای ارایه شد. در این مقاله انواع مختلفی از شبکه‌های عصبی عمیق و پیشرفت‌های اخیر مورد بررسی و تلخیص قرار گرفته‌اند.

پتچام (پتچام، ۲۰۱۸)، در پژوهشی به بررسی مدل ریسک نقدینگی با استفاده از شبکه عصبی مصنوعی پرداخت، این مطالعه بیش از روش سری زمانی و جایگزینی آن با یک روش تا حدودی جدید به نام مدل ریسک نقدینگی با استفاده از شبکه‌های عصبی مصنوعی است، افزون بر آن در این پژوهش یک روش به منظور بهبود روش‌های سری زمانی و به عنوان نتیجه یک رابط کاربر گرافیکی ساده با هدف آسان‌پیش‌بینی توسعه یافته است. نتایج رابط کاربر گرافیکی نشان داد که شبکه عصبی مصنوعی توانایی پیش‌بینی دقیقی در جهت ریسک نقدینگی نسبت به مقادیر واقعی دارد.

کاسینیلی (کاسینیلی، ۲۰۱۳)، عوامل موثر بر ریسک نقدینگی بانک در چارچوب منطقه یورور را مورد بررسی قرارداد، نتایج کار وی نشان می‌دهد که بانک‌های بزرگتر در خطر بیشتری از ریسک نقدینگی هستند، در حالی که بانک‌های با سرمایه بالاتر نشان دهنده نقدینگی بهتر در دراز مدت هستند. کیفیت دارایی تنها بر روی میزان ریسک نقدینگی کوتاه مدت اثر می‌گذارد. با در نظرگیری پارامتر تخصص، بانک‌هایی که متمرکز بر فعالیت‌های وام دهی هستند، ساختار بودجه آسیب‌پذیرتری را از خودشان نشان می‌دهند و در آخر مدیریت ریسک نقدینگی در بحران، تنها در افق کوتاه مدت تغییر می‌یابد.

بین یان و بین سو (یان و دیگران، ۲۰۱۳)، ریسک موجود در کسب و کار مالی اجرایی را به کمک شبکه‌های بیزی با رویکردی متفاوت، مدل کرده‌اند. در این مقاله انواع ریسک‌های موجود در این حوزه در چهار دسته جای می‌گیرند: ریسک‌های اعتباری، ریسک‌های اخلاقی، ریسک‌های قانونی و ریسک‌های مدیریت. برای تمام ریسک‌ها تنها دو حالت وجود دارد، یا ریسک وجود دارد یا خیر. سپس با تعریف جدیدی از ریسک، ریسک کلی کسب و کار محاسبه شده است. آنها با بهره‌گیری از تئوری evidence و با این ایده که چون در یک شبکه بیزی تمام عوامل وقوع یک پدیده ظاهر نمی‌شوند و ما تنها آن دسته از عواملی را وارد شبکه می‌کنیم که یا از آنها اطلاع داریم یا از اهمیت بالایی برخوردارند، برای ریسک، یک بازه قائل شدند و نه یک عدد مشخص. این بازه به کمک تئوری احتمال در این مقاله اندازه‌گیری شده است.

هدف پژوهش

هدف اصلی این پژوهش ارائه مدلی برای پیش‌بینی ریسک نقدینگی در بانک‌های پذیرفته شده و درج شده در بورس اوراق بهادار تهران و فرابورس ایران است، از این رو با تعریف عملیاتی ریسک

نقدینگی در بانک‌ها به بررسی عوامل اثرگذار بر روی ریسک نقدینگی بانک‌ها پرداخته و عوامل با بیشترین تاثیر را بر روی ریسک نقدینگی و نیز اثرات آنها بر یکدیگر را مورد بررسی قرار داده و در نهایت تنظیمات و پارامترهای یک سیستم بهینه پیش‌بینی میزان و احتمال ریسک نقدینگی برای هر بانک را با استفاده از شبکه‌های عصبی مصنوعی مدل‌سازی می‌کند.

روش پژوهش

از آنجا که در این پژوهش به اندازه‌گیری ریسک نقدینگی در بانکهای پذیرفته شده در بورس اوراق بهادار تهران و فرابورس ایران پرداخته شده است و نتایج آن مورد استفاده مدیران این بانکها، نهادهای سیاستگذار همچون شورای عالی پول و اعتبار، نهادهای نظارتی همچون بانک مرکزی و سازمان بورس و اوراق بهادار و نیز جامعه تحلیل و سرمایه‌گذاری کشور قرار خواهد گرفت و برای ایشان مفید فایده خواهد بود، بنابراین می‌توان این پژوهش را از نوع پژوهش‌های توسعه‌ای-کاربردی دانست، چرا که به توسعه کاربردهایی از داده کاوی و شبکه هوش مصنوعی در مورد مسائل دنیای واقعی خواهد پرداخت. به عبارتی این پژوهش از نوع داده، کمی و از دیدگاه روش در رده پژوهش‌های تجربی قرار می‌گیرد. برای مدل‌سازی ریسک نقدینگی از نسبت‌های ترازنامه بهره گرفته شده که هر کدام از این نسبت‌ها، از شاخص‌های ریسک نقدینگی به شمار می‌آیند. سپس با تعریف ریسک به عنوان عدم توانایی بانک در پاسخگویی به تعهدات جاری، ورودی‌ها و مقادیر هدف را بر اساس داده‌های ۱۰ ساله جمع‌آوری شده از دوره سه ماهه سوم سال مالی منتهی به پایان اسفند ۱۳۸۹ تا سه ماهه دوم سال مالی منتهی به اسفند ۱۳۹۹، وارد شبکه عصبی کرده و تابع ریسک (بنا به تعریف) تخمین زده می‌شود. سپس با ترکیب شبکه‌های عصبی با سری‌های زمانی، توانایی پیش‌بینی ریسک نقدینگی توسط شبکه عصبی، آزمایش خواهد شد. در قسمت بعد، شبکه بیزی مدل‌سازی می‌شود. ابتدا داده‌ها از حالت کمی، به صورت داده‌های دسته‌ای تغییر شکل پیدا می‌کنند. پس از ایجاد ساختار و تخمین پارامترهای شبکه بیزی، به پیش‌بینی و استنتاج ریسک نقدینگی در این نوع مدل‌سازی پرداخته خواهد شد.

ابزار گردآوری اطلاعات و داده‌ها

به منظور تهیه ادبیات موضوع استفاده از منابع معتبر انگلیسی، رسالات، کتب و پایان‌نامه‌های نگارش شده قبلی در دستور کار قرار گرفت. همچنین با توجه به ماهیت متغیرهای پژوهش، داده‌های موردنیاز از ۴۷۵ صورتهای مالی سالانه و شش ماهه حسابرسی شده و میان دوره‌ای سه

ماهه و نه ماهه ۲۳ بانک پذیرفته شده در بورس اوراق بهادار تهران و فرابورس ایران از نرم افزار بورس ویو (BourseView) (متعلق به شرکت پردازش اطلاعات مالی پویا ثبت شده به شماره ۱۰۹۶۳ مورخ ۱۳۹۰/۱۰/۴ نزد سازمان بورس و اوراق بهادار) استخراج و پس از مطابقت و صحت سنجی با صورتهای مالی حسابرسی افشا شده توسط ناشران در سامانه اطلاع رسانی ناشران (کدال) مورد استفاده قرار گرفت.

الگوریتم فرآیند متدولوژی پژوهش

همان طور که اشاره شد ماهیت این پژوهش از نوع پیش بینی و مدلسازی است و به منظور پیش بینی ریسک نقدینگی از روش های یادگیری ماشین و به صورت خاص از شبکه های عصبی و شبکه های بیزین استفاده شده است. مدل پیشنهادی در این پژوهش از دو فاز مکمل یعنی فاز شبکه هوشمند عصبی^۱ (ANN) و فاز مدل شبکه بیزین^۲ (BN) تشکیل می شود. این دو فاز دو کارکرد مختلف را بر عهده دارند. به بیان دقیق تر در حالیکه ANN می تواند برای تقریب روند کلی ریسک مورد استفاده قرار گرفته و از شناسایی و ارائه میزان تاثیر هر یک از عوامل ناتوان است و یا از عملکرد مناسبی برخوردار نیست، روش BN قادر به یافتن تأثیرگذارترین عامل و میزان تأثیر هر عامل بر ایجاد ریسک نقدینگی خواهد بود. افزون بر این رویکرد BN اجازه می دهد تا احتمال رخ دادن ریسک نقدینگی حتی وقتی که همه شاخص ها اندازه گیری نشده باشند تعیین شد. بنابراین فازهای ANN و BN مکمل همدیگر به حساب می آیند. نتایج ریسک نقدینگی بدست آمده بوسیله روش ANN هم تکمیل کننده روش دیگر است و هم بوسیله نتایج بدست آمده از روش BN تکمیل می شود.

پارامترهای کلیدی و نقش آنها در فرآیند یادگیری

نتایج بدست آمده از هر دو فاز ANN و BN مبتنی بر تکنیک های یادگیری هستند. در گام نخست یک شبکه اولیه (با وزن تصادفی برای ANN ها و توزیع احتمالی فرض شده برای BN) ایجاد می شود. این شبکه بوسیله مجموعه ای از داده ها آموزش داده می شود تا نتایج نهایی با الگو یا توزیع داده های اصلی نزدیک شود. الگوریتم مورد استفاده برای آموزش شبکه عصبی،

1. Artificial Neural Network
2. Bayesian Network model

الگوریتم گرادیانت-دیسنت^۱ و برای BN تخمین حداکثر درستنمایی^۲ است. از آنجاییکه آموزش الگوریتم‌ها یک رویه استاندارد است، انتخاب پارامترهای درست اهمیت ویژه‌ای پیدا می‌کند. به عبارتی مهمترین مسئله یافتن پارامترهای مناسب برای آموزش توابع ارایه شده بوسیله ANN و توزیع احتمال BN برای برازش^۳ داده‌هاست.

در این مدل دو مجموعه پارامتر وجود دارد:

مجموعه وزن‌های مختلف در ANN ها؛ و

مجموعه پارامترهای تابع توزیع احتمال در BN.

در آموزش شبکه عصبی، تابعی از متغیرهای ورودی را تعریف کرده (مجموعه داده‌ها) و سعی در یافتن بهترین وزن (ضرایب) برای متغیرها می‌کند. به محض اینکه این تابع به اندازه کافی فراگرفته شود، آماده تقریب ارزشهای هدف و پس از آن پیش‌بینی روند ریسک نقدینگی خواهد بود. در فرآیند یادگیری بوسیله قاعده بیز هر نود، بوسیله متغیر ورودی تعریف شده و فرض می‌شود که دارای توزیع مسبوق به سابقه‌ای است. توزیع‌های سابق هر عامل بوسیله همان نوع از عوامل توصیف می‌شوند. سپس این توزیع‌ها برای توصیف توزیع ریسک نقدینگی مورد استفاده قرار گرفته و پس از دریافت شواهد کافی بهبود می‌یابد و به تدریج توزیع واقعی مجموعه داده‌ها فراگرفته می‌شود. نتیجه حاصل یک توزیع احتمال است که توانایی دارد احتمال رخداد ریسک نقدینگی را با فرض وجود شاخص‌های موجود محاسبه کند.

شبکه عصبی مصنوعی چند لایه

شبکه عصبی مورد استفاده یک شبکه عصبی چند لایه^۴ (MLP) است که توسط معماری تغذیه آتی^۵ (FF) تعبیه و معرفی شد. این شبکه از معماری به دلیل ارتباط قوی و مداوم با الگوریتمی معروف به الگوریتم یادگیری به پشتوانه تکثیر^۶ (BPL) بسیار عمومیت یافتند. یکی از عناصر اصلی در طراحی یک ANN، شناسایی صحیح الگوریتم یادگیری برای استفاده در طول فرآیند یادگیری و بروزرسانی وزن‌هاست. برای این مسئله می‌توان از یک سازوکار یادگیری و یا یادگیری نظارت شده که قاعده یادگیری مناسبی را همچون قاعده گرادیانت

1. Gradient-Descent
2. Maximum Likelihood Estimation
3. Fitting
4. Multilayer perceptron
5. Feed Forward
6. Back Propagation Learning

دیسنت را بکار بسته و ارزش‌های وابسته را تعدیل کند، استفاده کرد. در میان بسیاری از الگوریتم‌های مشهور در ریاضیات و علم محاسبات، بیشتر از الگوریتم لونبرگ-مارکواردت^۱ (LMA) برای حل مسایل بهینه سازی که از منحنی ژنتیک متناسب با مسایل بدست می‌آید، استفاده می‌شود. این الگوریتم بین دو الگوریتم گاوس-نیوتن^۲ (GNA) و روش گرادینت دیسنت درون یابی برقرار می‌کند. LMA قدرتمندتر از GNA است اما همانند بسیاری از الگوریتم‌های از این دست، تنها یک کمینه داخلی را که لزوماً بهترین کمینه در سطح کلی نیست، پیدا می‌کند. پس از این بردار خروجی با استفاده از این اوزان و خروجی‌ها محاسبه شده و تفاوت بین خروجی‌ها و اوزان هدف به عنوان هزینه معرفی می‌شوند تا خطای شبکه عصبی در تخمین به دست آید.

معرفی داده‌ها

برای نگارش پژوهش حاضر از دو گروه داده استفاده شده است. داده‌هایی که در ساخت متغیرهای مستقل مورد استفاده قرار گرفته‌اند و داده‌هایی که در ساخت متغیرهای وابسته مورد استفاده قرار گرفته‌اند. از این رو شاخص‌های یک تا ۹ به شرح زیر به عنوان متغیرهای مستقل استفاده شده است. تمامی شاخص‌های نوشته شده در این بخش از صورتهای مالی ۲۳ بانک یاشده به مدت ۱۰ سال در دوره‌های فصلی از نرم افزار بورس ویو (Bourse View) در قالب فایل‌های خروجی اکسل استخراج شده و سپس در نرم افزار متلب مورد استفاده قرار گرفته‌اند. در ادامه هر یک از اقلام تشکیل دهنده شاخص‌های نامبرده تشریح می‌شوند:

شاخص یک: نسبت آنی است که از تقسیم دارایی‌های نقدی بانک الف بر بدهی‌های جاری بانک الف حاصل می‌شود. به عبارتی در این شاخص صورت کسر را موجودی نقد بانک و مخرج آن را حاصل جمع بدهی‌های با سررسید کمتر از یکسال بانک شامل بدهی به بانک مرکزی، بدهی بانک به دیگر بانک‌ها و مؤسسات اعتباری، ذخیره مالیات بر درآمد و سود سهام پیشنهادی و پرداختنی تشکیل می‌دهد. شاخص دو: که از حاصل تقسیم اعتبارات اعطایی بانک الف به دیگر بانکها تقسیم بر مجموع دارایی‌های نقدی در بانک الف حاصل می‌شود. به عبارتی در این شاخص صورت کسر را مطالبات از سایر بانک‌ها و مؤسسات اعتباری و مخرج آن را موجودی نقد بانک تشکیل می‌دهد.

1. Levenberg-Marquardt algorithm

2. Gauss-Newton algorithm

شاخص سه: که از حاصل تقسیم سپرده‌های بلند مدت بانک الف بر سپرده‌های کوتاه مدت بانک الف بدست می‌آید. به عبارتی در این شاخص، صورت کسر را سپرده‌های سرمایه‌گذاری مدت‌دار بانک و مخرج آن را مجموع سپرده‌های دیداری، سپرده‌های قرض‌الحسنه و پس‌انداز و مشابه و سایر سپرده‌های بانک تشکیل می‌دهد.

شاخص چهار: که از حاصل تقسیم اعتبارات اعطایی بانک الف به دیگر بانکها بر اعتبارات اعطایی بانکهای دیگر به بانک الف بدست می‌آید. به عبارتی در این شاخص صورت کسر را مطالبات از سایر بانکها و مخرج آن را بدهی به بانکها و موسسات اعتباری تشکیل می‌دهد.

شاخص پنج: که از حاصل تقسیم جمع تسهیلات اعطایی بانک الف بر جمع سپرده‌های بانک الف بدست می‌آید. به عبارتی در این شاخص صورت کسر را تسهیلات اعطایی به سایر بانکها، تسهیلات اعطایی و مطالبات از اشخاص دولتی، تسهیلات اعطایی و مطالبات از اشخاص غیردولتی و مخرج آن را سپرده‌های دیداری، سپرده‌های قرض‌الحسنه و پس‌انداز و مشابه، سپرده‌های سرمایه‌گذاری مدت‌دار و سایر سپرده‌ها تشکیل می‌دهد.

شاخص شش: که از حاصل تقسیم اوراق بهادار با درآمد ثابت و یا صکوک منتشره بانک الف بر جمع دارایی‌های بانک الف بدست می‌آید. به عبارتی در این شاخص صورت کسر را مجموع اوراق منتشره بانک همچون اوراق مشارکت، اوراق اجاره و سایر اوراق بهادار با درآمد ثابت منتشره و مخرج آن را جمع دارایی‌های بانک تشکیل می‌دهد.

شاخص هفت: که از حاصل تقسیم سپرده‌های فرار یا ناپایدار بانک الف بر جمع بدهی‌های بانک الف بدست می‌آید. به عبارتی در این شاخص صورت کسر را مجموع سپرده‌های دیداری و سپرده‌های قرض‌الحسنه و پس‌انداز و مخرج کسر را جمع بدهی‌های بانک تشکیل می‌دهد.

شاخص هشت: که از حاصل تقسیم سرمایه‌گذاری‌های کوتاه مدت بانک الف بر جمع دارایی‌های بانک الف بدست می‌آید. به عبارتی در این شاخص صورت کسر را سرمایه‌گذاری در اوراق بهادار سریع معامله بانک (که عمدتاً متشکل از سهام شرکت‌های بورسی و فرابورسی می‌باشند) بر جمع دارایی‌های بانک تشکیل می‌دهد.

شاخص نه: که از حاصل تقسیم مطالبات بانک الف از بانک مرکزی بر جمع سپرده‌های بانک الف بدست می‌آید. به عبارتی در این شاخص صورت کسر را مطالبات از بانک مرکزی و مخرج آن را مجموع سپرده‌های دیداری، سپرده‌های قرض‌الحسنه، پس‌انداز و مشابه، سپرده‌های سرمایه‌گذاری مدت‌دار و سایر سپرده‌ها تشکیل می‌دهد.

همچنین شاخص دهم با نام نسبت جاری در پژوهش حاضر به عنوان متغیر وابسته مورد استفاده قرار گرفته است.

شاخص ده: که به عنوان متغیر وابسته می‌توان از آن به عنوان شاخصی برای اندازه گیری ریسک نقدینگی یاد کرد، از حاصل تقسیم دارایی‌های جاری بانک الف بر بدهی‌های جاری بانک الف بدست می‌آید. به عبارتی در این شاخص صورت کسر را مجموع موجودی نقد، مطالبات از بانک مرکزی، مطالبات از سایر بانکها و موسسات اعتباری، تسهیلات اعطایی کوتاه مدت به شرکتهای عضو گروه و سایر اشخاص، سایر حسابها و اسناد دریافتی و سرمایه‌گذاری کوتاه مدت در اوراق بهادار و مخرج آن را مجموع بدهی به بانک مرکزی، بدهی به بانکها و مؤسسات اعتباری، ذخیره مالیات بر درآمد، سپرده‌های دیداری اشخاص، سود سهام پیشنهادی و پرداختنی و ذخایر و سایر بدهی‌ها تشکیل می‌دهد. هر یک از اقلام تشکیل دهنده شاخص‌های یادشده بر اساس تعاریف صورت گرفته در استانداردهای حسابداری در ایران و نیز بخشنامه‌های بانک مرکزی در صورتهای مالی بانکها شناسایی و مورد استفاده قرار گرفته و پس از تأیید حسابرس مستقل و بازرس قانونی به عموم سرمایه‌گذاران از طریق سامانه اطلاع رسانی ناشران (کدال) به عموم سرمایه‌گذاران افشا شده که متعاقباً در این پژوهش مورد استفاده قرار گرفته‌اند.

با توجه به موارد بالا می‌توان مدل کلی پژوهش را به صورت زیر حاوی فهرست متغیرهای مستقل و وابسته نوشت.

$$X_{10}(t+1)=ANN_BAYES[X_1(t), X_2(t), X_3(t), X_4(t), X_5(t), X_6(t), X_7(t), X_8(t), X_9(t)]$$

همچنین به منظور سنجش روایی مدل استخراج شده، به دلیل آن که در این مدل از متغیر وابسته تاریخی استفاده می‌شود، از روش‌هایی که مقدار پیش‌بینی شده را با مقدار واقعی در زمان‌های گذشته مقایسه می‌کند، استفاده شده است. به عبارتی از شاخص MSE و RMSE که معیاری برای ارزیابی کیفیت مدل است، به منظور این مقایسه استفاده شده است. هم‌چنین از بازه تاریخی سال ۱۳۸۹ تا ۱۳۹۹ برای آموزش مدل استفاده شده است.

جامعه آماری

جامعه آماری پژوهش حاضر متشکل از ۲۳ بانک بورسی و فرابورسی (بانکهای اقتصاد نوین، انصار، ایران زمین، آینده، پارسیان، پاسارگاد، پست بانک، تجارت، حکمت، خاورمیانه، دی،

رسالت، رفاه، سامان، سرمایه، سینا، شهر، صادرات، قوامین، کارآفرین، گردشگری، ملت و مهر اقتصاد) برای دوره ۱۰ ساله از سه ماهه سوم سال ۱۳۸۹ تا سه ماهه دوم سال ۱۳۹۹ مورد استفاده قرار گرفته اند. جدول ۱ وضعیت تعداد صورتهای مالی منتشره هر بانک در دوره ده ساله نامبرده را در مجموع نشان می دهد:

جدول ۱. جدول تعداد صورتهای مالی منتشره بانکها

ردیف	نام بانک	تعداد صورتهای مالی منتشره در کدال
۱	اقتصاد نوین	۴۰
۲	پاسارگاد	۴۰
۳	تجارت	۴۰
۴	سینا	۴۰
۵	دی	۴۰
۶	کارآفرین	۴۰
۷	ایران زمین	۳۹
۸	سرمایه	۳۹
۹	ملت	۳۹
۱۰	پارسیان	۳۸
۱۱	گردشگری	۳۷
۱۲	پست بانک	۳۶
۱۳	صادرات	۳۶
۱۴	آینده	۳۴
۱۵	حکمت	۳۴
۱۶	انصار	۳۳
۱۷	رسالت	۳۱
۱۸	خاور میانه	۳۰
۱۹	سامان	۲۱
۲۰	مهر اقتصاد	۱۳
۲۱	شهر	۱۱
۲۲	قوامین	۷
۲۳	رفاه	۴
	جمع	۷۲۲


۴۰ داده فصلی برای ۴ دوره ۱۰ ساله در مجموع ساختار داده‌های مورد استفاده در این پژوهش را تشکیل می‌دهد. در مجموع در این پژوهش از ۷۲۲ ردیف و ۶۹۱۱ سلول (شاخص‌های مورد محاسبه برای ۲۳ بانک به مدت ۱۰ سال و برای ۴ دوره فصلی در هر سال) استفاده شده است.

فرایند اجرای مدل‌سازی با شبکه عصبی

در این پژوهش، به منظور معماری مناسب برای پیش‌بینی نقدینگی شبکه عصبی، در ابتدا شاخص‌های ده گانه نقدینگی بدست آمده و مورد محاسبه قرار گرفت. پس از حذف داده‌های پرت مبادرت به تشکیل پایگاه داده‌ای لازم به منظور پیش‌پردازش‌ها و پالایش‌های لازم از دیدگاه تکنیکی و محتوایی بر روی داده‌ها صورت گرفته و در نهایت انبار داده‌های مورد نظر تشکیل شد. سپس داده‌های لازم برای آموزش شبکه از طریق واسطه کاربری و فراخوانی نرم‌افزار شبکه عصبی از طریق نرم‌افزار MATLAB استخراج شد. پس از آموزش شبکه، آزمایش شبکه با داده‌های واقعی انجام تا مانده نقدینگی تخمین زده شود و میزان خطای پیش‌بینی تعیین شد. داده‌های مورد استفاده در این پژوهش، ۱۰ شاخص محاسبه شده برای ۴۰ دوره سه ماهه ۲۳ بانک است. به منظور اجرای پیش‌بینی با شبکه عصبی، ابتدا باید شبکه با داده‌های حقیقی مورد آزمایش قرار گیرد. به همین منظور ۷۰ درصد از داده‌ها برای آموزش، ۱۵ درصد برای پیش‌بینی و ۱۵ درصد برای مرحله تست مورد استفاده قرار گرفتند.

معماری مدل شبکه عصبی

شبکه عصبی در این پژوهش از نوع MLP بیزین انتخاب شد و دلیل اصلی آن توانایی پیش‌بینی این شبکه در مورد روابط غیر خطی است. با توجه به این‌که پیشتر داده‌های پرت شناسایی شده‌اند، این مدل می‌تواند قابلیت‌ها و مزیت‌های بیشتری را از خود بروز دهد. شبکه عصبی طراحی شده برای این رساله به صورت زیر است:



در طراحی معماری شبکه عصبی باید موارد زیر مشخص شده باشد:

۱. متغیرهای مستقل، کدام متغیرها هستند و آیا می‌توان تعداد آن‌ها را کمتر کرده یا تبدیلی بر روی آن انجام داد تا بتوان قدرت پیش‌بینی مدل را افزایش داد؟ ۹ متغیر مستقل به صورت‌های زیر مورد استفاده قرار گرفته است:
 - الف- متغیرهای نه‌گانه به صورت مستقیم در مدل مورد استفاده قرار گرفته است.
 - ب- متغیرهای مستقلی که در تحلیل رگرسیون مقادیر Pvalue کمتر از ۰,۰۵ داشته‌اند، مورد استفاده قرار گرفته است.
 - ج- روی متغیرهای نه‌گانه روش PCA اجرا شده است و پس از آن، شبکه عصبی اجرا شده است.
 ۲. شبکه عصبی با چه الگوریتمی آموزش داده شده است؟ در این پژوهش شبکه‌های عصبی با استفاده از الگوریتم لونیبرگ مارکوآرڈت به عنوان یک الگوریتم ابتکاری و الگوریتم ژنتیک به عنوان یک الگوریتم فرا ابتکاری استفاده شده است.
 ۳. تعداد لایه‌های نهانی در شبکه‌های عصبی چگونه تعیین شده است؟ در ابتدا بهترین مدل از ترکیب مدل‌های بالا به دست خواهد آمد و بعد از آن سعی می‌شود تا بهترین تعداد لایه‌ها برای مدل به دست آید. در ابتدا تعداد لایه‌ها برابر با ۵ در نظر گرفته می‌شود، اما بعد از آن که بهترین حالت با توجه به متغیر مستقل و الگوریتم آموزش به دست آمد، می‌توان تعداد لایه‌های بهینه را به دست آورد.
 ۴. توابع انتقال در شبکه‌های عصبی این پژوهش با توجه به ادبیات موضوع و سایر پژوهشها از نوع Tansig در نظر گرفته شده است.
 ۵. در این پژوهش، ۷۰ درصد از داده‌ها برای آموزش، ۱۵ درصد برای اعتبارسنجی^۱ و ۱۵ درصد نیز برای آزمون^۲ شبکه عصبی مورد استفاده قرار گرفته است. نحوه انتخاب این داده‌ها نیز به صورت تصادفی بوده است.
- در نتیجه می‌توان مراحل و تحلیل‌های لازم برای اجرای این الگوریتم را بدین صورت ارائه کرد:
۱. اجرای شبکه عصبی با دو الگوریتم آموزش ژنتیک و لونیبرگ مارکوآرڈت و مقایسه آن به منظور انتخاب بهترین الگوریتم؛
 ۲. اجرای شبکه عصبی با استفاده از سه دسته داده نه‌گانه، داده حاصل از تحلیل رگرسیون و داده حاصل از تحلیل PCA؛

1. Validation

2. Test

۳. بهینه‌سازی تعداد لایه‌های نهانی شبکه عصبی.

در نهایت جدول (۲) به شرح زیر مراحل اجرای الگوریتم را نشان می‌دهد:

جدول ۲. مراحل اجرای الگوریتم

مرحله	هدف	ورودی	الگوریتم های اجرا	خروجی
۱	انتخاب بهترین روش آموزش	متغیرهای نه گانه مستقل متغیر وابسته	شبکه عصبی با آموزش لونبرگ شبکه عصبی با آموزش ژنتیک	روش آموزش مناسب
۲	انتخاب بهترین ترکیب متغیرهای مستقل (لایه ورودی)	متغیرهای نه گانه مستقل متغیر وابسته روش آموزش مناسب (خروجی مرحله ۱)	شبکه عصبی با متغیرهای مستقل زیر: (۱) متغیرهای نه گانه (۲) متغیرهای رگرسیون (۳) متغیرهای حاصل از PCA	بهترین ترکیب از متغیرهای مستقل
۳	تعیین تعداد لایه‌های بهینه (لایه پنهان)	متغیرهای نه گانه مستقل متغیر وابسته (خروجی مرحله ۲) روش آموزش مناسب (خروجی مرحله ۱)	شبکه عصبی	تعداد لایه‌های بهینه پنهان

مرحله ۱) اجرای شبکه عصبی با روش‌های آموزش متفاوت


در این قسمت شبکه عصبی مورد نظر با استفاده از دو روش لونبرگ و ژنتیک با مختصات زیر آموزش می‌بیند. بطور کلی روش لونبرگ به عنوان یک روش ابتکاری و روش ژنتیک به عنوان یک روش فراابتکاری در شبکه‌های عصبی مطرح بوده و مورد استفاده قرار می‌گیرند:

پارامتر	مقدار
نسبت داده‌های آموزش	۷۰ درصد
نسبت داده‌های اعتبارسنجی	۱۵ درصد
نسبت داده‌های آزمون	۱۵ درصد
توابع انتقال	Tansig
تعداد لایه‌های نهانی	۵
متغیر مستقل	شاخص‌های یک تا نه
متغیر وابسته	شاخص ۱۰
روش آموزش	لونبرگ (۱) ژنتیک (۲)

در این بخش فرآیند آموزش داده‌ها که توسط روش لونیبرگ انجام شده است شرح داده می‌شود. این روش در جعبه ابزار نرم افزار متلب به عنوان پیش فرض قرار دارد. روش لونیبرگ یک الگوریتم بهینه سازی است که به خاطر کاربرد آن در مسایلی که بصورت منحنی متناسب سازی می‌شوند بسیار محبوبیت دارد اما همچون دیگر الگوریتم‌های بهینه سازی دارای یک نقطه ضعف است و آن اینکه این روش قادر است نقاط حداقل محلی را که لزوماً در سطح جهانی حداقل نیستند را بیابد. افزون بر آن کیفیت پاسخهای دریافتی زمانی مناسب است که اوزان اولیه (و از این رو شبکه اولیه) تاحدودی خوب حدس زده شده باشد و نسبت علامت به خطا از پنج بیشتر باشد. به همین خاطر بطور موازی از یک الگوریتم فرا ابتکاری یا همان الگوریتم ژنتیک هم استفاده شد. از آنجایی که الگوریتم ژنتیک رفتاری تصادفی داشته و به نقطه ابتدایی وابسته نیست، به منظور اطمینان از کارکرد صحیح الگوریتم لونیبرگ در این پژوهش مورد استفاده قرار گرفت. جدای از اینکه استفاده از روش ژنتیک از برخی از برگشت‌های روش لونیبرگ نیز اجتناب می‌کند (برای مثال ریسک گرفتار شدن در دام کمینه های محلی)، استفاده از الگوریتم ژنتیک بر این نکته نیز تأکید می‌کند که مجموعه داده‌ها به میزان کافی متناسب هستند که توسط دیگر الگوریتم‌ها نیز به مدل درآیند. اگرچه همانگونه که در ادامه نیز نشان داده می‌شود روش لونیبرگ به میزان چشمگیری بهتر از روش ژنتیک به مرحله اجرا درآمده و قادر است تا الگوهای داده‌ها را به میزان دقیق‌تری شناسایی کند. هدف ما رسیدن به خطای مطلوب یعنی خطای در حدود صفر است. بنابراین ۹ نورون برای لایه ورودی و یک نورون در لایه خروجی در نظر گرفته شده است. سپس برای رسیدن به بهترین ساختار، نورون های لایه پنهان را یک به یک به شبکه افزوده و در هر بار شبکه را آموزش می‌دهیم تا به کمترین خطا و در نتیجه بهترین ساختار برسیم. برای این منظور نرم افزار متلب مجموعه داده‌های آموزش را با استفاده از تابع DivideRand بطور تصادفی به ۳ گروه شامل آموزش، اعتبار سنجی و آزمون تقسیم کرده و عملیات آموزش را براین اساس تا رسیدن به ساختار بهینه ادامه می‌دهد. منحنی اعتبارسنجی این امکان را به شبکه می‌دهد که از آموزش بیش از حد شبکه^۱ جلوگیری شود و زمانی که این منحنی به حداقل مقدار خود رسیده و شروع به افزایش می‌کند، عملیات آموزش متوقف می‌شود که این نقطه همان طور که در شکل مشاهده می‌شود، نقطه بهینه شبکه است که در

1. Overfitting or Overlearning

مرحله ۳۸۷ بدست آمده است. در نهایت پیش‌بینی ریسک نقدینگی بوسیله روش الگوریتم لونبرگ مدل‌سازی شد. همچنین لازم به یادآوری است الگوریتم MLP در این پژوهش بر اساس فیلترینگ بیزین طراحی شده است. به عبارتی در نوروهای ما یک تابع بیزین در حال فعالیت است که برای تفکیک داده‌ها از تابع توزیع احتمال شرطی استفاده می‌کند. نتایج حاصل از اجرای الگوریتم شبکه عصبی با استفاده از روش لونبرگ برای داده‌های آزمون در شکل (۱) نشان داده شده است:




شکل ۱. نتایج اجرای الگوریتم عصبی با استفاده از روش لونبرگ

نتایج داده‌های آزمون نشانگر آن است که توزیع آزمون نرمال با میانگین منفی ۲ هزارم و واریانس ۴ صدم است و نتایج داده‌های خروجی مدل و داده‌های هدف دارای ضریب همبستگی ۹۴ درصدی هستند. همچنین میانگین مربعات خطا و مجذور میانگین مربعات خطا به ترتیب ۱ هزارم و ۴ درصد هستند.

الگوریتم ژنتیک برای آموزش شبکه عصبی، در حالت حدی برای بهترین عملکرد در نظر گرفته شده و به محدودیت‌های پردازشی توجهی نشد تا بهترین عملکرد ممکن از این الگوریتم حاصل شود. تنظیمات این الگوریتم به صورت زیر است.


پارامتر	مقدار
اندازه جمعیت	۵۰۰ ژن
تعداد گردش	۱۰۰۰ گردش
نسبت ماندگاری	۱۰ درصد
نسبت تولید مثل	۸۵ درصد
نسبت جهش	۵ درصد
فشار جهش	۲۰ درصد

در این پژوهش منظور از ژن وزنه‌های هر نورون است. با توجه به اینکه ۷ لایه داشته و هر لایه ۹ نورون دارد (۹×۷) لذا به میزان ۶۳ ژن یا همان وزن هر نورون خواهیم داشت و (۹×۶۳) ۵۶۷ متغیر خواهیم داشت. در نهایت نمودار (۱) روند کاهش تابع هدف و میانگین تابع هدف در هر گردش را نشان می‌دهد:



نمودار ۱. تابع هدف و میانگین تابع هدف

در نمودار بالا شکل آبی وضعیت خطاها را در هر مرحله آزمایش ژنتیک نشان می‌دهد. به عبارتی خط آبی بهترین جواب حاصله در هر بار آزمایش و خط قرمز میانگین همه جمعیت یا میانگین جواب‌های حاصله است. همانطور که دیده می‌شود از حدود ۶ آزمایش به بعد الگوریتم ژنتیک قادر به کشف خطای جدید و به عبارتی ایجاد بهبود جدید نبوده و میزان خطاها ثابت باقی مانده است. نتایج حاصل از اجرای الگوریتم شبکه عصبی با استفاده از روش الگوریتم ژنتیک برای داده‌های آزمون در شکل (۲) نشان داده شده است:



شکل ۲. نتایج اجرای الگوریتم عصبی با استفاده از روش الگوریتم ژنتیک

نتایج داده‌های آزمون نشانگر آن است که توزیع آزمون نرمال با میانگین ۸ هزارم و واریانس ۱۰ صدم است و نتایج داده‌های خروجی مدل و داده‌های هدف دارای ضریب همبستگی ۱۸ درصدی هستند. همچنین میانگین مربعات خطا و مجذور میانگین مربعات خطا به ترتیب ۱ درصد و ۱۰ درصد هستند. در نهایت جدول (۳) مقایسه دو روش آموزش یاد شده را نشان می‌دهد:

جدول ۳. مقایسه نتایج حاصل از روش لونیبرگ با الگوریتم ژنتیک

پارامتر	آموزش با روش لونیبرگ			آموزش با الگوریتم ژنتیک		
	آموزش	اعتبارسنجی	آزمون	آموزش	اعتبارسنجی	آزمون
میانگین خطا	-۰,۰۰۲۳۵۰۹	-۰,۰۰۷۸۹۴	-۰,۰۰۲۰۴۹	۰,۰۰۸۰۶۴۲	-۰,۰۰۶۴۸۹۸	۰,۰۰۸۵۵۹۶
انحراف معیار خطا	۰,۴۸۸۸۷	۰,۰۵۳۰۱۳	۰,۰۴۱۱۷۱	۰,۰۱۰۳۸۹	۰,۰۸۰۹۲۶	۰,۱۰۰۶
توزیع خطا	نرمال	نرمال	نرمال	نرمال	نرمال	نرمال
MSE	۰,۰۰۲۳۸۹۴	۰,۰۰۲۸۳۹۶	۰,۰۰۱۶۷۹۳	۰,۰۱۰۸۳۱	۰,۰۰۶۵۱۴۱	۰,۱۰۰۷۴
RMSE	۰,۰۴۸۸۸۲	۰,۰۵۳۲۸۸	۰,۰۴۰۹۸	۰,۱۰۴۰۷	۰,۰۸۰۷۱	۰,۱۰۰۳۷
R	۰,۸۷۶۸۹	۰,۸۲۹۳۷	۰,۹۴۳۹۷	۰,۲۸۵۹۲	۰,۰۴۰۶۷۱	۰,۱۸۱۹۱
زمان اجرا	کمتر از ۱ دقیقه			۱۵ دقیقه		

در نهایت به نظر می‌رسد بهترین الگوریتم برای آموزش، الگوریتم لونبرگ باشد که از جمله دلایل آن می‌توان به موارد زیر اشاره کرد:

۱) درجه آزادی مساله بالاست (متغیرهای پژوهش زیاد هستند) و الگوریتم ژنتیک زمان و هزینه زیادی برای همگرایی نیاز دارد. به عبارتی الگوریتم ژنتیک در فضاهای متغیرها زیاد هستند، همچون پژوهش حاضر، زمان زیادی را صرف گشتن در متغیرها برای یافتن الگوی بهینه می‌کند، بنابراین با توجه به زمان بر بودن این موضوع برای این پژوهش مناسب و به صرفه نیست. ۲) در روش لونبرگ ضریب همبستگی بالاتر و میانگین مربعات خطا کمتر از روش ژنتیک است.

۳) فضای تصمیم بسیار بزرگ است پس نمی‌شود از ژنتیک استفاده کرد.

۴) الگوریتم ژنتیک برای همگرایی نیازمند زمان زیاد است. که در این پژوهش با توجه به ابعاد و پیچیدگی‌های آن می‌تواند مشکلاتی را در اجرا به همراه داشته باشد.

مرحله ۲) اجرای شبکه عصبی با متغیرهای مستقل متفاوت

در مرحله قبل، روش آموزش لونبرگ به عنوان روش آموزش مناسب استفاده شد، اما در این قسمت باید متغیرهای مستقل افزون بر نه متغیر اصلی، به دو روش دیگر مدل‌سازی شود. به عبارتی در این بخش این موضوع بررسی می‌شود که آیا امکان کوچک‌سازی متغیرهای ورودی وجود دارد یا خیر و اگر این امکان وجود دارد تا چه حد می‌توان متغیرهای ورودی را کوچک کرد.

پارامتر	مقدار
نسبت داده‌های تست	۷۰ درصد
نسبت داده‌های اعتبارسنجی	۱۵ درصد
نسبت داده‌های آزمون	۱۵ درصد
توابع انتقال	Tansig
تعداد لایه‌های نهانی	۵
متغیر مستقل	الف) شاخص‌های ۱ تا ۹ ب) شاخص‌های حاصل از رگرسیون ج) ابعاد حاصل از روش PCA
متغیر وابسته	شاخص ۱۰
روش آموزش	لونبرگ


اجرای شبکه عصبی با استفاده از شبکه متغیرهای مستقل حاصل از تحلیل رگرسیون

در بخش قبل اجرای مدل با استفاده از ۹ متغیر ورودی (شاخص ورودی) انجام و نتایج آن ارایه شد. در این بخش مبادرت انجام رگرسیون میان ۹ متغیر ورودی (متغیرهای مستقل) و متغیر خروجی (متغیر وابسته) شد. نتایج تحلیل رگرسیون حاصل از متغیرهای ده گانه پژوهش در جدول (۴) نشان داده شده است.

جدول ۴. نتایج تحلیل رگرسیون حاصل از متغیرهای ده گانه

متغیر	ضریب	مجذور خطا	آماره t	معنی داری (pvalue)
عرض از مبدا	۱۸۵۹۴۸	۰.۲۶۷۵۰۸	۶.۹۵۱۱۲	۱۱-۱.۰۲
شاخص ۱	۰.۸۱۱۸۴۹	۰.۰۵۸۸۲	۱۳۸۰۲۱۵	۳۷-۱.۷۵
۲	۰.۰۳۱۶۳۸	۰.۰۰۴۸۲۲	۶.۵۶۱۶۶۸	۱۰-۱.۲۲
۳	۰.۰۳۵۳۱۵	۰.۰۰۶۰۸۴	۵۸۰۴۲۷۵	۰.۸-۱.۰۹
۴	۰.۰۰۰۵۶۳	۰.۰۰۱۰۶۳	۰.۵۲۹۳۱۵	۰.۵۹۶۷۹۸
۵	-۶.۳۲۰۶	۰.۴۰۷۰۸۸	-۱۵.۵۲۶۴	۴۵-۱.۹۵
۶	۱.۵۱۱۴۹۵	۱.۵۴۳۸۶۶	۰.۹۷۹۰۳۳	۰.۳۲۷۹۸۹
۷	۱.۲۴۸۸۶۲	۰.۳۷۰۲۳۳	۳.۳۷۳۱۷۵	۰.۰۰۰۷۹۵
۸	۱۰.۳۷۴۹۵	۱.۵۶۷۰۳۸	۶.۶۲۰۷۴۲	۱۱-۸.۴۲
۹	۴.۴۷۰۸۷۵	۱.۲۶۰۹۱۷	۳.۵۴۵۷۳۳	۰.۰۰۰۴۲۴

از آنجاییکه متغیرهای ۴ و ۶ دارای pvalue بیشتر از نیم هستند بنابراین بی معنی بوده و در نتیجه می توان دو شاخص ۶ و ۴ را حذف کرد. از این رو در ادامه با حذف دو شاخص یادشده دوباره به اجرای مدل شبکه عصبی کرده و نتایج حاصل از اجرای این مدل شبکه عصبی به شرح زیر ارایه می شود. نتایج حاصل از داده های آزمون با حذف دو متغیر ۴ و ۶ در شکل (۳) نشان داده شده است:



شکل ۳. نتایج اجرای الگوریتم عصبی با استفاده از شبکه متغیرهای مستقل حاصل از تحلیل رگرسیون

همانگونه که نمایان می‌شود نتایج داده‌های آزمون نشانگر آن است که توزیع آزمون نرمال با میانگین ۲ هزارم و واریانس ۴ صدم است و نتایج داده‌های خروجی مدل و داده‌های هدف دارای ضریب همبستگی ۸۵ درصدی هستند. همچنین و میانگین مربعات خطا و مجذور میانگین مربعات خطا به ترتیب ۲ هزارم و ۴ درصد هستند.

اجرای شبکه عصبی با استفاده از شبکه متغیرهای مستقل حاصل از کاهش ابعاد به وسیله PCA
 الگوریتم تحلیل مولفه اصلی یا همان روش PCA^۱ از جمله روش‌هایی است که ابعاد داده را با استفاده از یک روش خطی کاهش می‌دهد. با اجرای الگوریتم کاهش ابعاد بر روی داده‌ها، ابعاد زیر به وجود آمده است که هر یک می‌تواند نسبت مشخصی از واریانس را ایجاد کند. با اجرای این الگوریتم ۹ بعد داده جدید ایجاد می‌شود که هر یک تابعی خطی از ویژگی‌های

1. Principal Component Analysis

۹ گانه اصلی بوده که در جدول (۵) به شرح زیر منعکس شده است. بر این اساس بعد اول بیشترین واریانس و بعد ۹ کمترین واریانس را داراست.

جدول ۵. ابعاد ۹ گانه جدید متغیرهای اصلی

متغیر/بعد	۱	۲	۳	۴	۵	۶	۷	۸	۹
۱	0.000162	-0.0198	-0.01529	0.998163	-0.04393	0.03314	0.00277	-0.00273	0.001368
۲	0.035756	0.973804	0.223392	0.022689	0.000908	0.002566	0.000142	5.54E-05	0.000529
۳	-0.0144	-0.2233	0.974551	0.010506	0.004984	0.006519	8.28E-05	0.000324	0.000895
۴	0.999257	-0.03806	0.006052	-0.00082	0.000127	6.40E-05	-8.93E-07	5.93E-05	1.53E-05
۵	9.08E-06	0.000153	-0.00098	-0.05342	-0.6489	0.748283	-0.05285	-0.09127	-0.07092
۶	-4.86E-05	-0.00016	-0.00061	-0.00471	-0.10445	0.047803	-0.16712	0.71049	0.673837
۷	-0.00011	-0.00075	-0.00859	0.010936	0.750017	0.658069	0.001984	0.005085	0.064779
۸	2.76E-05	-0.00015	-6.36E-05	-0.00274	-0.02507	-0.03734	-0.00111	-0.68821	0.724111
۹	-1.10E-05	-8.32E-05	-0.00021	-0.00651	-0.05398	0.046817	0.984513	0.114927	0.111255


همچنین جدول (۶) به شرح زیر میزان واریانسی که هر یک از ابعاد جدید ارائه می‌کند را نشان می‌دهد:

جدول ۶. واریانس ابعاد ۹ گانه جدید

بعد	واریانس	نسبت واریانس	نسبت واریانس تجمعی
۱	3182.682	0.910229	0.910229
۲	177.2278	0.050686	0.960915
۳	135.4735	0.038745	0.999659
۴	1.13124	0.000324	0.999983
۵	0.031757	9.08E-06	0.999992
۶	0.023281	6.66E-06	0.999999
۷	0.0022	6.29E-07	0.999999
۸	0.001549	4.43E-07	1
۹	0.001302	3.72E-07	1

به عبارتی با استفاده از این روش، ۹ شاخص (متغیرهای مستقل) به سه شاخص تقلیل یافته و همبستگی داخلی میان متغیرها از بین می‌رود و از طرفی فرآیند آموزش شبکه عصبی با سه متغیر بهتر از ۹ متغیر انجام می‌شود. همانگونه که در جدول بالا مشخص است متغیر اول ۹۱ درصد، متغیر دوم ۹۶ درصد و متغیر سوم ۹۹ درصد از واریانس مدل را در بر داشته که در نتیجه می‌توان با سه بعد اول، ۹۹ درصد از واریانس داده‌ها را پیش‌بینی کرد. به عبارتی مدل شبکه عصبی با سه ورودی و یک خروجی آموزش داده می‌شود که این موضوع به طور چشمگیری آموزش شبکه عصبی را تسهیل می‌کند.

در ادامه اشکال نتایج داده‌های آزمون، حاصل از اجرای شبکه عصبی و با استفاده از روش PCA در ادامه آورده شده است:



شکل ۴. نتایج اجرای الگوریتم عصبی با استفاده از روش PCA

نتایج داده‌های آزمون بیانگر آن است که توزیع آزمون نرمال با میانگین ۲ هزارم و واریانس ۳ صدم است و نتایج داده‌های خروجی مدل و داده‌های هدف دارای ضریب همبستگی ۸۳

درصدی هستند. همچنین میانگین مربعات خطا و مجذور میانگین مربعات خطا به ترتیب ۱ هزارم و ۳ درصد هستند. در نهایت با استفاده از جدول (۷) به شرح زیر می توان سه مدل عنوان شده به شرح بالا را با یکدیگر مقایسه کرد:

جدول ۷. مقایسه روشهای مستقل ۹ گانه، مستقل رگرسیون و PCA

پارامتر	مستقل نه گانه			مستقل رگرسیون			PCA مستقل		
	آموزش	اعتبارسنجی	آزمون	آموزش	اعتبارسنجی	آزمون	آموزش	اعتبارسنجی	آزمون
میانگین خطا	-۰,۰۰۲۳۵۰۹	-۰,۰۰۷۸۹۴	-۰,۰۰۲۰۴۹	۰,۰۰۴۸۵۵	۰,۰۰۲۱۸۹	۰,۰۰۲۲۹۷۹	۰,۰۱۲۰۶۶	۰,۰۰۲۰۲۹۶	۰,۰۰۲۰۲۹۶
انحراف معیار خطا	۰,۴۸۸۸۷	۰,۵۳۰۱۳	۰,۴۱۱۷۱	۰,۵۲۶۶۶	۰,۶۰۵۳۴	۰,۴۸۹۷۹	۰,۴۴۳۹۲	۰,۵۴۱۱۵	۰,۳۷۱۰۳
توزیع خطا	نرمال	نرمال	نرمال	نرمال	نرمال	نرمال	نرمال	نرمال	نرمال
MSE	۰,۰۰۲۳۸۹۴	۰,۰۰۲۸۳۹۶	۰,۰۰۱۶۷۹۳	۰,۰۰۲۷۶۶۲	۰,۰۰۳۶۴۴۸	۰,۰۰۳۷۷۵۵	۰,۰۰۱۹۷۱	۰,۰۰۳۰۳۹۶	۰,۰۰۱۳۶۴۵
RMSE	۰,۴۸۸۸۲	۰,۵۳۲۸۸	۰,۴۰۹۸	۰,۵۲۵۹۵	۰,۶۰۳۷۲	۰,۴۸۷۳۹	۰,۴۴۳۹۶	۰,۵۵۱۳۳	۰,۳۶۹۴
R	۰,۸۷۶۸۹	۰,۸۲۹۳۷	۰,۹۴۳۹۷	۰,۸۴۰۹۶	۰,۸۹۹۰۳	۰,۸۵۷۰۶	۰,۹۱۵۹۲	۰,۸۳۵۷۵	۰,۸۳۲۲۸


جدول مقایسه ای بالا نتایج داده های آموزش، اعتبار سنجی و آزمون را در سه روش مستقل نه گانه، مستقل رگرسیون و مستقل PCA نشان می دهد. روش لونبرگ بدلیل سرعت بالاتر و ضریب همبستگی بیشتر بین داده های خروجی و داده های هدف مدل به روش الگوریتم ژنتیک ارجح تشخیص داده شد که نتایج آن در جدول بالا و در بخش مستقل نه گانه نشان داده شده است. نتایج حاصل از میانگین وزنی ضریب همبستگی در هر یک از سه روش یادشده در جدول بالا نشان می دهد، روش PCA نتایج بهتری را نسبت به دو روش دیگر در بر دارد. به عبارتی میانگین موزون ضرایب همبستگی نشان می دهد ضریب همبستگی داده های خروجی و داده های هدف در روش الگوریتم PCA به میزان ۰/۸۹۲ بوده که از میانگین وزنی ضریب همبستگی در روش مستقل نه گانه به میزان ۰/۸۷۳ و روش مستقل رگرسیون به میزان ۰/۸۴۹ به وضوح بالاتر است فلذا استفاده از الگوریتم PCA به عنوان بهترین روش انتخاب می شود.

مرحله ۳) تعیین تعداد لایه‌های نهانی بهینه

برای تعیین تعداد لایه‌ها نیز، بدیهی است هر چه تعداد لایه‌های بیشتر باشد، دقت بیشتر است اما تعداد لایه‌های بیشتر منجر به افزایش نیاز به توان محاسباتی می‌شود و تعداد لایه‌های بالاتر منجر به Overlearning نیز می‌شود. در نتیجه مدل با مختصات زیر اجرا شد تا بتوان بهترین تعداد لایه‌ها را مشخص کرد.

پارامتر	مقدار
نسبت داده‌های تست	۷۰ درصد
نسبت داده‌های اعتبارسنجی	۱۵ درصد
نسبت داده‌های آزمون	۱۵ درصد
توانی انتقال	Tansig
تعداد لایه‌های نهانی	۵ تا ۱۰
متغیر مستقل	ابعاد حاصل از PCA
متغیر وابسته	شاخص ۱۰
روش آموزش	لونی‌رگ

نتایج حاصل از اجرای مدل در نمودار (۲) به شرح ذیل نشان داده شده است:



نمودار ۲. نتایج داده‌های آزمون، اعتبارسنجی و آموزش برای تعیین تعداد لایه‌های بهینه

نمودار بالا روند حرکت شاخص ضریب تعیین را برای افزایش تعداد لایه‌ها از ۵ به ۱۰ در سه داده آموزش، اعتبارسنجی و آزمون نشان می‌دهد. هر چه تعداد لایه‌ها بیشتر می‌شود، دقت مدل افزایش می‌یابد اما شیب افزایش نزولی است. بنابراین می‌توان تعداد لایه‌ها را عددی در حدود ۶ تا ۱۰ در نظر گرفت. با توجه به این که کاهش ابعاد در مدل اتفاق افتاده است و حجم محاسبات مدل کاهش یافته است، بنابراین بهتر است از ۶ لایه نهانی استفاده شود. لازم به بیان است با توجه به اینکه در نرم افزار متلب به جز لایه خروجی به لایه های دیگر لایه نهانی گفته می‌شود، می‌توان نتیجه گرفت که در این پژوهش بجز لایه ورودی از ۵ لایه نهانی یا پنهان استفاده خواهد شد.

نتیجه گیری و تحلیل یافته‌های پژوهش

در نهایت می‌توان شبکه عصبی را با توجه به به جدول زیر معماری کرد:

پارامتر	مقدار
نسبت داده‌های تست	۷۰ درصد
نسبت داده‌های اعتبارسنجی	۱۵ درصد
نسبت داده‌های آزمون	۱۵ درصد
توانع انتقال	Tansig
تعداد لایه‌های نهانی	۵
متغیر مستقل	ابعاد حاصل از PCA
متغیر وابسته	شاخص ۱۰
روش آموزش	لونیبرگ


با توجه به نتایج بدست آمده از بخش قبل خلاصه پارامترهای مورد استفاده برای پیش‌بینی ریسک نقدینگی بانکها به شرح جدول بالا ارایه شده است. در جدول (۸) پیش‌بینی نسبت جاری بانکها برای نخستین دوره آتی یعنی دوره سه ماهه سوم سال ۱۳۹۹ با استفاده از مدل شبکه عصبی برای آندسته از بانک‌هایی که صورتهای مالی حسابرسی شده آنها در سه ماهه دوم سال ۱۳۹۹ سامانه کدال افشا شده‌اند، ارایه شده است:

جدول ۸. پیش‌بینی نسبت جاری بانکها

نسبت جاری پیش‌بینی شده	بانک
۱.۰۲	اقتصاد نوین
۱.۷۰	ایران زمین
۱.۴۵	پارسیان
۱.۲۴	پاسارگاد
۱.۲۶	پست بانک
۲.۸۳	تجارت
۱.۷۹	خاور میانه
۲.۲۵	دی
۴.۵۶	رسالت
۵.۵۸	رفاه
۵.۷۲	سامان
۵.۸۲	سینا
۶.۱۳	شهر
۱.۴۸	صادرات
۵.۷۵	کار آفرین
۲.۵۵	گرددشگری
۰.۹۶	ملت

از آنجایی که نسبت کمتر از دو به منزله وجود مشکلات نقدینگی در تأمین نقدینگی کوتاه مدت برای بانکها شمرده می‌شود، برآوردها نشان می‌دهد قریب به نیمی از بانکهای مورد بررسی (بانکهایی چون خاور میانه، ایران زمین، صادرات، پارسیان، پست بانک، پاسارگاد، اقتصاد نوین و ملت) نسبت جاری پیش‌بینی شده کمتر از یک را تجربه خواهند کرد که این موضوع نیازمند تأمین نقدینگی لازم برای بانک و گرفتن تدابیر پیشگیرانه به منظور جلوگیری از مشکلات احتمالی است. بخشهای مدیریت ریسک در بانکها باید توجه ویژه‌ای به ترکیب ارقام مندرج در این نسبت مالی داشته بطوریکه با تقویت دارایی‌های جاری بانک (موجودی نقد، مطالبات از بانک مرکزی، مطالبات از سایر بانکها و موسسات اعتباری، تسهیلات اعطایی کوتاه مدت به شرکتهای عضو گروه و سایر اشخاص، سایر حسابها و اسناد دریافتی و سرمایه‌گذاری کوتاه مدت در اوراق بهادار) و یا کاهش بدهی‌های جاری بانک (بدهی به بانک مرکزی، بدهی به بانکها و

مؤسسات اعتباری، ذخیره مالیات بر درآمد، سپرده‌های دیداری اشخاص، سود سهام پیشنهادی و پرداختی و ذخایر و سایر بدهی‌ها) بتوانند مخاطرات احتمالی را کاهش دهند. مدیریت هر یک از این اقلام می‌تواند سهم بسزایی را در کاهش ریسک نقدینگی بانک در دوره آتی در بر داشته باشد. نمودار (۳) وضعیت نسبتهای مقایسه ای واقعی و پیش‌بینی شده بانکهای نامبرده را نشان می‌دهد:



نمودار ۳. مقایسه نسبتهای جاری پیش‌بینی شده و واقعی بانکها


یکی از موارد با اهمیت در کنترل ریسک نقدینگی بانکها نسبت تغییر در شاخص‌های تعیین ریسک نقدینگی است. در ادامه درصد تغییرات نسبت جاری بانکها در دوره سه ماهه پیش‌بینی شده نسبت به عملکرد آخرین دوره سه ماهه واقعی محاسبه و آورده شده است. به عنوان نمونه پیش‌بینی‌ها نشانگر آن است پست بانک کاهشی ۸/۳ درصدی را در نسبت جاری دوره آتی خود تجربه کند که این خود بیانگر تشدید ریسک نقدینگی در این بانک در دوره آتی است. از آنجایی که هر یک درصد کاهش نسبت یادشده بیانگر فزونی مصارف بانک و ایجاد تعهدات کوتاه مدت است، این امر مستلزم چاره اندیشی قبلی مدیران آن برای تأمین منابع مورد نیاز است. جدول ۹ درصدهای تغییر نسبت جاری هر یک از بانکها را به تفکیک نشان می‌دهد:

جدول ۹. درصد تغییر نسبت جاری هر یک از بانکها

نام بانک	درصد تغییر پیش‌بینی شده
پست بانک	-۸.۲۷٪
کار آفرین	-۵.۰۳٪
تجارت	-۴.۷۰٪
سینا	-۴.۰۶٪
رفاه	-۲.۶۱٪
سامان	-۲.۵۹٪
شهر	-۱.۵۳٪
دی	-۱.۳۳٪
صادرات	-۰.۵۵٪
رسالت	-۰.۲۷٪
پاسارگاد	۱.۰۵٪
ایران زمین	۱.۱۳٪
خاور میانه	۱.۵۳٪
اقتصاد نوین	۱.۵۸٪
گردشگری	۳.۵۴٪
ملت	۴.۵۳٪
پارسیان	۵.۲۱٪


همچنین نمودار (۴) به شرح زیر وضعیت درصد تفاوت نسبت جاری پیش‌بینی شده و واقعی

بانکها را نشان می‌دهد:



نمودار ۴. وضعیت درصد تفاوت نسبت جاری پیش‌بینی شده و واقعی بانکها

همانگونه که مشاهده می شود بانکهای پست بانک، کارآفرین، تجارت و سینا، رفاه، سامان، شهر، دی، صادرات و رسالت به ترتیب دارای بیشترین درصدهای کاهشی در روند شاخص ریسک نقدینگی در دوره آتی خواهند بود. از طرفی پیش بینی می شود به ترتیب بانکهای پارسیان، ملت، گردشگری، اقتصاد نوین، خاورمیانه، ایران زمین و پاسارگاد بیشترین بهبود را در شاخص ریسک نقدینگی دوره آتی تجربه کند. همچنین نمودار (۵) به شرح زیر توزیع تغییر شاخص ریسک نقدینگی بانکها را در دوره آتی به صورت دسته بندی شده نشان می دهد.



نمودار ۵. توزیع روند آتی شاخص نقدینگی بانکها

همانطور که مشاهده می شود، برآوردها نشانگر آن است که ۲۵ درصد بانکها (همچون بانکهای پست بانک، کارآفرین، تجارت) کاهشی بین ۳/۳۷ تا ۸/۲۷ درصدی را در شاخص ریسک نقدینگی خود شاهد باشند. از آنجاییکه هر یک درصد کاهش در این شاخص به منزله خروج منابع مالی کوتاه مدت بانکها است، این موضوع می تواند زنگ خطر وقوع ریسک نقدینگی جدی را برای این بانکها در بر داشته که عدم مدیریت بهینه آن متعاقباً ریسکهای اعتباری و مالی بانکها را در پی خواهد داشت. به عبارتی این دسته از بانکها در منطقه خطر قرار داشته که در صورت عدم چاره اندیشی مناسب ممکن است پرداخت بدهی های کوتاه مدت خود همچون پرداخت سپرده های مشتریان، تأدیه دیون به بانک مرکزی و بدهی به سایر بانکها و مؤسسات اعتباری را با مشکلات عدیده ای روبرو سازد و حتی بانک را با بحران نقدینگی

روبرو کند. همچنین نزدیک به ۵۰ درصد بانکها دارای تغییراتی در دامنه منفی $3/37$ درصد تا مثبت $1/53$ درصدی را تجربه خواهند کرد (همچون بانکهای ایران زمین، صادرات، پاسارگاد و رسالت) که باز همانند آندسته از بانکهایی که برآورد منفی رشد شاخص ریسک نقدینگی دارند نیاز به گرفتن تدابیر پیشگیرانه برای تأمین وجوه مورد نیاز البته نه به شدت گروه قبلی، وجود دارد. گروه آخر بانکهایی هستند که پیشبینی می شود از $1/53$ درصد تا $6/43$ درصد افزایش در ریسک نقدینگی را تجربه کند (همچون بانکهای پارسیان، ملت و گردشگری). این بانکها بیشتر بانکهایی هستند که در دوره قبل با نسبت های جاری ناکافی روبرو بوده و این رشد در راستای جبران بخش کوچکی از نصاب پایین آنها محسوب می شود. در مجموع بنظر می رسد، گرفتن سیاستهای بهینه مدیریت نقدینگی، رعایت الزامات بانکداری بازل برای رعایت نصاب کفایت سرمایه، رعایت سقف نرخ سودهای تعیین شده توسط بانک مرکزی و اعطای وام و اعتبار به اشخاص دارای رتبه اعتباری دارای ارزش سرمایه گذاری می تواند از جمله سیاستهای اثرگذار بر کنترل ریسک نقدینگی بانکها محسوب شود. بانکها با مدلسازی ریسک نقدینگی خود و پیشبینی وضعیت نقدینگی دوره های بعدی با استفاده از مدل های شبکه هوش مصنوعی می توانند تا حد زیادی وقوع بحرانهای نقدینگی را پیشبینی و از آن اجتناب کنند. بحران نقدینگی یک بانک به راحتی قابل تسری به سایر بانکها و می تواند زیانهای جبران ناپذیری را برای کل نظام بانکی در پی داشته باشد. بانکها همچنین با تعیین میزان مطلوب نسبت جاری و ریسک نقدینگی قابل پذیرش متناسب با شرایط خود (با توجه به میزان و حجم سپرده های اعطایی، حجم مطالبات معوق، میزان نصاب کفایت سرمایه، ترکیب سهامداری، شرکتهای همگروه و تابعه و غیره) می توانند حد مطلوب هر یک از اقلام تشکیل دهنده تسبب نقدینگی را تعیین کرده و با هدف گذاری های صحیح مالی، اهتمام لازم را برای پابندی و رعایت حدود این اقلام و در نهایت کنترل ریسک نقدینگی بانک بکار بندند.

منابع

- اسدپور، وحید، (۱۳۹۸)، *اصول بنیادی و مرجع کاربردی شبکه‌های عصبی*، چاپ دوم، انتشارات اتی‌نگر.
- تهرانی، رضا؛ فلاح شمس، میر فیض (۱۳۸۴)؛ "طراحی و تبیین مدل ریسک اعتباری در نظام بانکی کشور"، *مجله علوم اجتماعی انسانی دانشگاه شیراز*؛ دوره بیست و دوم؛
- ریدر، راب و بی هیلی، پیتر (۱۳۹۲)، *مدیریت جریان وجوه نقد با رویکرد عملیاتی*، ترجمه سعید مستشار، چاپ اول، انتشارات بورس.
- سوری، علی (۱۳۹۵)، *اقتصاد سنجی پیشرفته جلد دوم همراه با کاربرد استاتاستیستیک و اویویوز*، چاپ ششم، نشر فرهنگ شناسی.
- مک دونالد، ماتیو، (۱۳۹۷)، *مغز ما (چگونه از مغز خود بهتر استفاده کنیم)*، ترجمه محمد رضا باطنی، چاپ اول، انتشارات فرهنگ معاصر.
- موسویان، سید عباس و میثمی حسین (۱۳۹۵)، *بانکداری اسلامی، مبانی نظری-تجارب علمی*، ویراست پنجم، انتشارات پژوهشکده پولی و بانکی بانک مرکزی جمهوری اسلامی ایران.
- ویتبای، بلی (۱۳۹۶)، *هوش مصنوعی به زبان ساده*، ترجمه حسین مجد فر و آوا بهرامی، چاپ اول، انتشارات سیزان.
- هوپر، جودیث و ترسی، دیک (۱۳۷۲)، *جهان شگفت انگیز مغز (مغز جهان سه پوندی)*، ترجمه ابراهیم یزدی، چاپ اول، انتشارات قلم.

References

- Asadpour, Vahid, (2019) Basic principles and applied reference of neural networks, second edition, *Atinegar Publication*. (In Persian).
- Banks, Eric, (2014) *Liquidity Risk, Managing, Funding and Asset Risk*, second edition, Palgrave Macmillan.
- Castagna, Antonio and Fede, Francesco, (2013) *Measuring and Managing Liquidity Risk, Wiley France Series*.
- Choudhry, Moorad, (2011) *An Introduction to Banking Liquidity Risk And Asset-Liability Management*, John Wiley & Sons Ltd.
- Costa, M.A ., Padua Braga, A . de, Menezes, B.R., (2007) Improving generalization of MLPs with sliding mode control and the Levenberg-Marquardt algorithm, *Neurocomputing*. 1342-1347 .
- Cucinelli, D. ,The determinants of bank liquidity risk within the context of Euro area, *Interdiscip. J. Res. Bus.* 2 (10) (2013) 51-64 .
- Duan, L., Huang, L., Guo, Z., Fang, X., (2017) Periodic attractor for reaction-diffusion high-order Hopfield neural networks with time-varying delays, *Comput. Math. Appl.* 233-245 .

- Haykin, Simon, (2008), Neural Networks and Learning Machines, Third Edition, Prentice Hall, London.
- Hooper, Judith, Dick, Tracy, (1993) The wonderful world of the brain, Tree pound brain of the world, First Edition, Ghalam Publication. (In Persian).
- Huang, C., Cao, J., Xiao, M. (2016) Hybrid control on bifurcation for a delayed fractional gene regulatory network, *Chaos Solitons Fractals* 19–29.
- Huang, C., Cao, J., Xiao, M., Alsaedi, A., Hayat, T. (2017) Bifurcations in a delayed fractional complex-valued neural network. *Appl. Math. Comput.* 210–227 .
- Kermani, B.G., Schiffman, S.S., Nagle, H.T., (2005) Performance of the Levenberg–Marquardt neural network training method in electronic nose applications, *Sens. Actuators* 13–22 .
- Khashman, Adnan. (2010) Neural networks for credit risk evaluation: Investigation of different neural models and learning schemes, *Expert Systems with Applications*. 6233–6239.
- Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y., Alsaadi, F.E.. (2017) A survey of deep neural network architectures and their applications. *Neurocomputing* 11–26 .
- Lopez Iturriaga, Felix J., Pastor, Sanz Ivan, (2015) Bankruptcy visualization and prediction using neural networks: A study of U.S. commercial banks, *Expert Systems with Applications*. 2857–2869.
- Nabavi-Pelesaraei , R & Abdi , S. Rafiee , (2016) Neural network modeling of energy use and greenhouse gas emissions of watermelon production systems, *J. Saudi Soc. Agric. Sci.* 38–47 ,
- McDonald, Matthew, (2018) Our Brain How to use your brain better, First Editon, Contemporary Culture Publications. (In Persian).
- Mousavan, Seyyed Abbas, Meysami, Hossein, (2016) Islamic Banking Theoretical Foundations, Scientific experiences, Fifth Edition, Publications of the Monetary and Banking Research Institute of the Central Bank of the Islamic Republic of Iran. (In Persian).
- Meredith, J. R., Raturi, A., Amoako-Gyampah, K., & Kaplan, B. (1989). Alternative research paradigms in operations. *Journal of operations management*, 8(4), 297-326.
- Petchame, Sala J., (, 2011) Liquidity Risk Modelling Using Artificial Neural Network Master of Science Thesis, Master in Artificial Intelligence, Universitat Politècnica de Catalunya, Barcelona, Spain.
- Ridder Rob, Bihilly, Pitter, (2013) Managing Cash Flow With an operational approach, First Edition, Bourse Publications. (In Persian).
- Saunders, A., & Lewis, M., P, (2009) Methods for Business Students. Prentice Hall: London.
- Saunders, A; Allen, L;(2002); “Credit Risk Measurement” Second Edition; NewYork.
- Shi, X., Feng, Y., Zeng, J., Chen, K. (2017) Chaos time-series prediction based on an improved recursive Levenberg–Marquardt algorithm, *Chaos Solitons Fractals*. 57–61.

- Soprano, Aldo, A, (2015) Liquidity Management, A funding risk handbook, Wiley France Series.
- Souri, Ali, (2016) Advanced Econometrics, Application of Stata and Eviews, Sixth Edition, Cultural publications. (In Persian).
- Tavana, Madjid, Abtahi, Amir-Reza, Di Caprio, Debora, Poortarigh, Maryam (2018) An Artificial Neural Network and Bayesian Network model for liquidity risk assessment in banking, *Neurocomputing*. 2525–2554.
- Tehrani, Reza, Fallah Shams, Mir Feiz, (2005) Designing and explaining the credit risk model in the country's banking system, *Journal of human social sciences*, The twenty-second period, Shiraz university. (In Persian).
- Tsai, Chih-Fong, Wu., Jhen-Wei (2008) Using neural network ensembles for bankruptcy prediction and credit scoring, *Expert Systems with Applications*. 2639–2649.
- Velmurugan, G., Rakkiyappan, R., Cao, J.. (2016) Finite-time synchronization of fractional-order memristor-based neural networks with time delays. *Neural Netw.* 36–46.
- Venkat, Shyam and Baird, Stephen, (2016) Liquidity Risk Management, A Practitioner's Perspective Wiley France Series.
- Whitby, Billy, (2017) Artificial intelligence in simple language, Sabzan Publicatins. (In Persian).
- Yan, Y., B. Suo, Risks analysis of logistics financial business based on evidential Bayesian network, *Math. Problems Eng.* 2013 (10) (2013), doi: 10.1155/2013/785218 .

COPYRIGHTS



This is an open access article under the CC BY-NC 4.0 license.