

رویکرد پژوهش علم طراحی برای پیش‌بینی ریسک نقدینگی با استفاده از شبکه یادگیری کانولوشنی و تحلیل تمایل

حامد میرشک^۱، امیر البدوی^{۲*}، مهرداد کارگری^۳، محمدعلی رستگار سرخه^۴، محمد طالبی^۵

۱. دانشکده مهندسی فناوری اطلاعات، دانشگاه تربیت مدرس، تهران، ایران.

۲. دانشکده مهندسی فناوری اطلاعات، دانشگاه تربیت مدرس، تهران، ایران

۳. دانشکده مهندسی فناوری اطلاعات، دانشگاه تربیت مدرس، تهران، ایران.

۴. دانشکده مهندسی فناوری اطلاعات، دانشگاه تربیت مدرس، تهران، ایران

۵. دانشکده مدیریت، دانشگاه امام صادق (ع)، تهران، ایران.

تاریخ ارسال: ۱۴۰۲/۰۴/۰۴

تاریخ پذیرش: ۱۴۰۲/۰۹/۰۴

چکیده

روش پژوهش علمی طراحی، یا به اختصار DSR، یک رویکرد است که با استفاده از اصول علمی، به منظور تولید نتایج و محصولات اولیه و قابل انطباق بازار، در چهار مرحله اصلی به ارائه راه‌حل‌های عملی پرداخته و نهایتاً کارآیی و کاربردی بودن آن‌ها در جهان واقعی را تضمین می‌کند. DSR، با ایجاد یک الگوی نظری در مرحله نمونه‌سازی، سناریوهای واقعی را ارزیابی نموده و سپس راه‌حل‌ها را در موارد عملی بررسی می‌نماید. در این مطالعه، تلاش شده است تا با استفاده از روش پژوهش علمی طراحی، راه‌حلی نوآورانه برای پیش‌بینی ریسک نقدینگی بانک و ارائه سناریوهای پیشرو ارائه گردد. این مطالعه از رویکرد تحلیل تمایل و روش‌های یادگیری عمیق کانولوشنی در پیش‌بینی ریسک نقدینگی بهره برده و روشی ساده و موثر برای شناسایی متغیرهای کیفی پویا از اخبار اخیر مرتبط با یک بانک داخلی کشور را ارائه می‌نماید. سناریوهای پیش‌بینی شده، برای کمک به تصمیم‌گیری در زمینه مدیریت ریسک، به مسئولان بانکی در سناریوهای واقعی ارائه می‌شود. مقایسه این سناریوها با سناریوهای وقوع یافته در بانک نشان می‌دهد که روش پیشنهادی نسبت به دستورالعمل‌های کمیته بازل و سایر محدودیت‌های نظارتی بانکی اروپا، دقت نسبتاً بالایی دارد. به ترتیب، دقت پیش‌بینی برای سناریوهای مستخرج از کمیته بازل و مرجع بانکی اروپا به نسبت ۹۱٪ و ۸۲٪ است.

کلیدواژه‌ها: روش‌شناسی علم طراحی، پیش‌بینی ریسک نقدینگی، تحلیل تمایل، تحلیل سناریو

۱- مقدمه و بیان مسئله

ریسک نقدینگی یکی از با اهمیت‌ترین ریسک‌های مالی بانک‌ها می‌باشد، زیرا کمبود نقدینگی می‌تواند منجر به عدم توانایی بانک در تامین تعهدات مالی خود نسبت به سپرده‌گذاران شده و به تضعیف اعتبار آن منجر گردد. به همین دلیل، اندازه‌گیری ریسک نقدینگی به یک مسئله مهم برای بانک‌ها تبدیل شده است. روش‌های سنتی برای اندازه‌گیری ریسک نقدینگی پیچیده، زمان‌بر و پرهزینه هستند. همچنین، به دلیل پیچیدگی محاسبات، به خطاها حساس هستند. علاوه بر این، اندازه‌گیری به موقع ریسک نقدینگی می‌تواند از وقوع آسیب‌های جدی یا بحران‌ها در بانک جلوگیری نماید. در واقع، طراحی یک راهکار عملی و ایجاد محصولات کاربرپذیر می‌تواند به عنوان یک جایگزین مناسب مطرح گردد [۱، ۲].

"روش‌شناسی علم طراحی (DSR^۱)" یک رویکرد کل به جزء برای شناسایی مسئله و ساخت فرآورده‌ها و راهکارهای مناسب است. DSR با ایجاد فرآورده‌های جدید به دنبال ارائه راهحل مناسب برای مسائل موجود در فضای مسئله ب و همچنین محیطی که در آن نمونه‌گیری شده‌است را بهبود می‌دهد و پایه‌های دانش فناوری و علم را به همراه دارد. نتایج DSR شامل فرآورده‌های جدید طراحی شده و دانش طراحی (DK^۲) است که درک کامل‌تری از نحوه بهبود (یا اختلال) فرآورده‌های زمینه‌های کاربردی مربوطه خود را از طریق تئوری‌های طراحی ارائه می‌دهد [۳]. در این مطالعه، رویکرد DSR برای ساخت فرآورده‌های مرتبط با موضوع ریسک نقدینگی استفاده شده‌است. یک روش جدید برای پیش‌بینی وضعیت ریسک نقدینگی در ماه آینده و سناریوی ریسک در حال وقوع است. بر اساس مدل بازل III اصول مدیریت ریسک نقدینگی، انعطاف‌پذیری نقدینگی کوتاه‌مدت در سناریوی بحرانی حیاتی است. به همین دلیل، بانک‌ها باید ابزاری برای پیش‌بینی شاخص هدف (LCR) و سناریوهای آینده داشته باشند [۴]. ریسک پیش‌بینی شده به عنوان یک خروجی جدید باید بررسی شود تا کاربرد آن در سناریوهای ریسک نقدینگی مختلف (استرس) مورد ارزیابی قرار گیرد. در واقع با استفاده از روش DSR از روشی علمی برای پیاده‌سازی و ارزیابی سیستم پیش‌بینی ریسک نقدینگی استفاده می‌گردد. DSR مراحل مختلفی دارد: (۱) شناسایی مقتضیات طراحی، (۲) تعریف و اهداف راهکار طراحی، (۳) طراحی و توسعه راهکار، و (۴) نمایش طراحی انجام شده و نتایج کاربردی. هر مرحله شامل بررسی و ارزیابی نتایج بدست آمده است. این روش از شناسایی مقتضیات طراحی تا تعریف راهکار طراحی و طراحی و توسعه راهکار، به دنبال ایجاد مصنوعات است که پایگاه دانش را ارتقا داده و دامنه کاربرد

^۱ Design Science Research

^۲ Design Knowledge

را در تعامل با دنیای بیرونی ارزیابی کند. این یک فرآیند تکراری است که می‌تواند در هر چرخه ای تکامل یابد و اگر نتایج نهایی قابل قبول باشد، این چرخه می‌تواند بسته شود.

در مرحله شناسایی مقتضیات طراحی، مسئله اصلی مرتبط با پیچیدگی و زمان‌بر بودن محاسبات معیارهای ریسک نقدینگی است. توانا و گیسلز (۲۰۱۸ و ۲۰۲۰) پیچیدگی فرآیندهای اندازه‌گیری ریسک را شناسایی کرده‌اند [۵، ۶]. یک راه حل، پیش‌بینی ریسک نقدینگی است که می‌تواند یک رویکرد جایگزین در برخورد با مشکل اندازه‌گیری ریسک باشد. در این شرایط می‌توان از روش‌های یادگیری ماشین برای کنترل پیچیدگی‌های محاسباتی استفاده کرد. [۷] سوانکی (۲۰۱۹) اظهار داشت که شکافی در ادبیات مربوط به استفاده از هوش مصنوعی برای اندازه‌گیری ریسک نقدینگی وجود دارد. از قدرت هوش مصنوعی می‌توان برای پیش‌بینی سطح نقدینگی آینده بانک‌ها استفاده کرد. [۸] بنابراین، با استفاده از تکنیک‌های هوش مصنوعی مانند الگوریتم یادگیری ماشین، می‌توان سطح LCR را در آینده به منظور شناسایی سناریوهای استرس و انجام اقدامات مورد نیاز پیش‌بینی کرد. ارزیابی عوامل کیفی مانند تاثیر اخبار، یک تغییر نگرش در روش‌های قبلی برای پیش‌بینی ریسک نقدینگی است. با این حال، چندین مطالعه وجود دارد که نشان می‌دهد اخبار، نوسانات بازار، قیمت سهام و سایر عوامل پویا می‌توانند بر ریسک نقدینگی تأثیر گذارند. [۹، ۱۰، ۱۱، ۱۲] راه‌حل پیشنهادی با استفاده از نمونه‌های واقعی از یک معیار ارزیابی ریسک بانکی برای آزمایش میزان عملکرد مورد بررسی قرار گرفت. نتایج با استفاده از معیارهای ارزیابی مختلفی مورد نظر در نظریه یادگیری ماشین، ارزیابی شدند. در مرحله بعدی DSR، استفاده عملی از مدل پیشنهادی مورد ارزیابی قرار گرفت. مدل باید هم در شرایط نمونه اولیه و هم در شرایط واقعی ارزیابی شود. در نهایت، می‌بایست بررسی شود که آیا چرخه DSR باید بسته شود یا باید دوباره ادامه یابد. در بخش دوم، ادبیات موضوع بررسی شده است. سپس در بخش سوم، روش DSR مورد بحث قرار گرفته است. همچنین نحوه انجام هر مرحله از DSR در این مطالعه را در نظر می‌گیرد. سپس، ارزیابی مراحل DSR برای این مطالعه مورد بحث قرار می‌گیرد.

۲- پیشینه و مبانی نظری پژوهش

توانا و همکاران (۲۰۱۸) مدل جدیدی را پیشنهاد نمودند که با مطالعه موردی در دنیای واقعی از شبکه عصبی مصنوعی و شبکه‌های بیزی به منظور ارزیابی اندازه‌گیری ریسک نقدینگی استفاده می‌کند [۱۳]. همچنین، به عنوان بخشی از فرآیند بررسی و ارزیابی نظارت، گورا و همکاران (۲۰۲۲) از تکنیک‌های یادگیری ماشین، از جمله داده‌های نظارتی، برای مدل‌سازی ریسک نقدینگی استفاده نمودند [۱۴]. نتایج، ارائه سناریوهایی برای تست استرس یا سیستم هشدار اولیه (EWS) می‌باشد. چانگ هو (۲۰۱۷) مدلی

را برای پیش‌بینی ریسک نقدینگی مالی با استفاده از مدل تشخیص خطی، مدل پوربیت و مدل لاجیت پیشنهاد کرد. او از آزمون ANOVA برای انتخاب متغیرهای معنادار و مؤثر بر شرکت‌های سالم و شرکت‌های ضعیف در مورد وضعیت نقدینگی آنها استفاده نمود [۱۵].

مطالعات متعددی با استفاده از روش DSR در حوزه مدیریت ریسک نقدینگی وجود دارد. افیونگ و همکاران (۲۰۲۰) اثرات مدیریت ریسک نقدینگی بر عملکرد مالی شرکت‌های کالاهای مصرفی را با استفاده از تکنیک تحلیل رگرسیون بررسی کردند. [۱۶] ایچوری آریاس و همکاران (۲۰۱۵) یک معماری نرم افزاری را طراحی و یک سیستم اطلاعاتی به نام مدیریت ریسک نقدینگی را برای پیاده‌سازی آن پیشنهاد نمودند. این مطالعه یک راه حل بر اساس روش پژوهش DSR و مراحل پیاده‌سازی آن طراحی می‌نماید. سیستم پیشنهادی با محاسبه معیارهای نقدینگی ارزیابی شد. [۱۷] مطالعه دیگری در زمینه پزشکی قانونی دیجیتال انجام شد. علاوه بر این، رویکرد DSR برای طراحی و ارزیابی یک فرآورده مفید جهت کاهش ریسک امنیت اطلاعات در اپراتورهای مخابراتی استفاده شد. [۱۸]

سدرگرن و همکاران (۲۰۲۲) از یک رویکرد جدید به نام پژوهش طراحی کنشی^۱ یا ADR که از ترکیب روش‌های DSR و پژوهش کنشی^۲ بهره می‌برد، انجام شده است. هدف اصلی این مطالعه توسعه و اجرای یک رویکرد یکپارچه برای مدیریت ریسک و پایداری کسب‌وکار است [۱۹].

یک تحقیق جدید توسط نوبیلی و همکاران (۲۰۲۱) یک سیستم هشدار اولیه را برای شناسایی ریسک نقدینگی پیش از وقوع بحران طراحی کرده است. این تحقیق از الگوریتم‌های متنوعی مانند پیش‌بینی لجستیک LASSO، جنگل تصادفی، و افزایش گرادین شدید بهره برده و آن‌ها را ترکیب کرده است. مدل ترکیبی این روش‌ها بهبود یافته و نتایج دقیق‌تری ارائه داده‌اند [۲۰].

مطالعه ای توسط گوئرا و همکاران (۲۰۲۲) برای بررسی این موضوع انجام شد که آیا تکنیک‌های هوش مصنوعی قابلیت مدل‌سازی ریسک نقدینگی را دارند. در این تحقیق، از روش RAS برای طبقه‌بندی سطوح ریسک نقدینگی استفاده شده و نتایج آن با مدل‌های آماری سنتی مانند SVC، رگرسیون لجستیک، طبقه‌بندی Naïve Base و جنگل تصادفی مقایسه شده‌اند. نتیجه نشان می‌دهد که الگوریتم XGBOOST عملکرد بهتری دارد [۱۴]. در خصوص مبحث ریسک نقدینگی تخمین یا پیش‌بینی شاخص ریسک نقدینگی با استفاده از بررسی عوامل کمی یا کیفی مؤثر خواهد بود. به عبارت دیگر، سوانکی (۲۰۱۹) به این نکته اشاره کرد که استفاده از هوش مصنوعی به منظور پیش‌بینی ریسک نقدینگی، یک خلأ در ادبیات واقعیت دارد [۸]. از طرفی، هوش مصنوعی می‌تواند زمان‌بری را کاهش

^۱ Action Design Research

^۲ Action Research

داده و خودکارسازی و بهینه‌سازی را در فرآیند محاسبات ریسک نقدینگی تسهیل نماید [۱۳].

۱-۲- نسبت پوشش نقدینگی (LCR)

نسبت پوشش نقدینگی یکی از دو روش استاندارد کمیته نظارت بازل است و ارزیابی می‌کند که آیا یک بانک قادر خواهد بود در طی ۳۰ روز آینده از دارایی‌های باکیفیت خود، جریان نقدی خالص خود را پوشش دهد یا خیر. این معیار به شرح زیر تعریف می‌شود:

$$LCR = \frac{HQLA}{Total\ Net\ Cash\ Flow\ Amount} \geq 100\%$$

دارایی‌های نقدی با کیفیت یا HQLA

جریان‌های خروجی خالص طی ۳۰ روز آینده یا Total Net Cash Flow Amount

جریان‌های ورودی در ۳۰ روز آینده - جریان‌های خروجی طی ۳۰ روز آینده = Total Net Cash Flow

سه عامل در محاسبه نسبت پوشش نقدینگی نقش مهمی ایفا می‌کنند:

۱) ارزش دارایی‌های نقدی (دارایی‌های با نقدینگی بالا) که صورت کسر را تشکیل می‌دهند. (۲) نرخ مازادی که بین طبقه بدهی‌ها و دارایی‌ها شناسایی می‌شود. (۳) تقسیم سپرده‌های درخواستی به بلندمدت و کوتاه مدت و اعمال ضرایب مربوط به هر سپرده. پیچیدگی محاسبات و برآورد پارامترهای این نسبت، استفاده از آن را دشوار کرده است [۱۳].

۲-۲- استفاده از یادگیری ماشین و تحلیل احساسات برای ارزیابی ریسک نقدینگی

جدول ۱ مروری بر روش‌ها و مطالعات صورت گرفته در حوزه تحلیل ریسک نقدینگی با استفاده از روش‌های یادگیری ماشین و آماری دارد. این روش‌ها در شکل‌گیری روش پیشنهادی این مطالعه نقش مهمی داشته‌اند.

همچنین، تحقیقات دیگر در حوزه مدیریت ریسک بانکی، از جمله ریسک اعتباری، بازاری، کفایت سرمایه و سایر موارد، با استفاده از روش‌های تحلیل تمایل، متن‌کاوی، پردازش زبان طبیعی و دیگر روش‌های یادگیری ماشین، نتایج قابل قبولی با دقت بالا ارائه داده‌اند [۲، ۷، ۸، ۹، ۱۰، ۱۸، ۱۹، ۲۵].

جدول ۱. مروری بر مقالات حوزه تحلیل ریسک نقدینگی.

حوزه	موضوع مقاله	روش	مرجع
تحلیل ریسک نقدینگی	مدل شبکه عصبی مصنوعی و شبکه بی‌زی برای ارزیابی ریسک نقدینگی در بانک	پیش‌بینی ریسک نقدینگی مبتنی بر عوام مؤثر خرد و کلان در بانک	[۱۳]

حوزه	موضوع مقاله	روش	مرجع
	مطالعه برآورد مدل پیش‌بینی ریسک نقدینگی مالی با استفاده از تحلیل مالی	بررسی نسبت‌های مالی مؤثر در پیش‌بینی ریسک نقدینگی با استفاده از ANOVA و تحلیل رگرسیون	[۱۵]
	یادگیری ماشین برای مدل‌سازی ریسک نقدینگی: دیدگاه نظارتی	ارائه مدلی برای ارزیابی ریسک نقدینگی بانک با استفاده از روش‌های یادگیری ماشین در سناریوهای بحرانی	[۱۴]
	شاخص هشدار اولیه ریسک نقدینگی برای بانک‌های ایتالیایی: رویکرد یادگیری ماشینی	سیستم هشدار اولیه برای شناسایی ریسک نقدینگی قبل از بحران با استفاده از الگوریتم‌های مختلف پیش‌بینی LASSO، جنگل تصادفی، XGBOOST و ترکیب آن‌ها	[۲۰]
تحلیل ریسک مالی	تحلیل تصمیمات در زمان ریسک: نظریه مفهومی	مدل جایگزین به نام "نظری چشم‌انداز" ارائه شده است که توانایی توضیح تصمیم‌گیری در مواجهه با ریسک را بهبود می‌بخشد.	[۲۸]
	تأثیر احساس رسانه بر ریسک شرکت	ارتباط بین احساس رسانه‌ها و تصمیمات مدیران عامل شرکتی با تأثیر بر شاخص‌های مختلف شامل ریسک، سرمایه‌گذاری، و سیاست‌های مالی بررسی شده است.	[۳۱]
	ارتباط بین احساس و ریسک در بازارهای مالی	در این مطالعه، همبستگی بین شاخص‌های احساس بازار و ریسک در بازارهای آمریکا، آلمان و چین ارزیابی می‌شود و نتایج نشان می‌دهد که ارتباطات آماری معناداری بین این متغیرها وجود دارد.	[۲۹]
	کشف عوامل ریسک بانک از صورت مالی بر اساس یک الگوریتم متن‌کاوی نیمه-نظارتی جدید	از متون کیفی گزارش‌های مالی برای شناسایی و تحلیل ۲۱ عامل ریسک بانکی با استفاده از یک الگوریتم متن‌کاوی نیمه-نظارتی جدید استفاده شده است.	[۳۰]
تحلیل تمایل صورت مالی	تحلیل احساس مالی با مدل‌های زبان پیش‌آموزش دیده	آراکی و همکاران (۲۰۱۹) مدل زبان FinBERT را معرفی می‌کنند که بر اساس مدل BERT طراحی شده است و با موفقیت به تحلیل احساسات مالی پاسخ می‌دهد.	[۳۲]
	طبقه‌بندی احساس صورت‌های مالی مبتنی بر یادگیری عمیق در مدیریت تجاری	توسط دینگ و همکاران (۲۰۲۲)، یک روش تحلیل احساس صورت‌های مالی با استفاده از یادگیری عمیق و تطبیق دامنه معرفی شده است. نتایج نشان می‌دهد که این روش موفق به بهبود نرخ تشخیص از مجموعه	[۳۳]

حوزه	موضوع مقاله	روش	مرجع
		داده‌های منبع باز به مجموعه داده‌های متن مالی StockTwits می‌شود.	
	الگوریتم تحلیل احساس در سطح جنبه‌ها مبتنی بر BERT برای متن‌های چند منظوره	رادواج و همکاران (۲۰۲۲)، یک الگوریتم تحلیل احساس متون چند دامنه‌ای بر مبنای BERT ارائه شده است که از داده‌های توصیفی موجود در دامنه منبع برای کمک به دامنه مقصد استفاده می‌کند. این الگوریتم نسبت به الگوریتم‌های کلاسیک دیگر عملکرد بهتری دارد و برای انجام تحلیل احساس به سطح جمله ^۱ و جنبه ^۲ مناسب است.	[۳۴]


۳- روش‌شناسی پژوهش

DSR یک رویکرد حل مسئله است که به دنبال تقویت دانش انسان از طریق ایجاد مصنوعات نوآورانه می‌باشد. به عبارت ساده، DSR به دنبال ارتقاء پایه‌های دانش در حوزه فناوری و علمی از طریق ایجاد مصنوعات جدید و نوآورانه جهت حل مسائل و برآورد نیازهای محیط می‌باشد [۳].

شکل ۱ یک چارچوب مفهومی را برای درک، اجرا، و ارزیابی روش‌شناسی پژوهش علم طراحی به تصویر می‌کشد [۲۱]. در ادامه، مراحل پژوهش مبتنی بر DSR مورد بررسی و ارائه قرار خواهند گرفت.

^۱ Sentence Level

^۲ Aspect Level




شکل ۱. چارچوب روش‌شناسی پژوهش علم طراحی [۳]

۳-۱- شرح کلی پژوهش مبتنی بر DSR

همان‌طور که در شکل ۲ نمایش مدل فرآیند روش پژوهش علم طراحی (DSRPM)^۱ آمده، این فرآیند از شش مرحله تشکیل شده است: (۱) تعریف مقتضیات و انگیزه طراحی (۲) تعیین اهداف و راهکارهای طراحی (۳) انجام عملیات طراحی و توسعه راهکار (۴) ارائه و بررسی قابلیت پذیرش طراحی انجام شده (۵) ارزیابی طراحی انجام شده (۶) انتشار طراحی و نتایج آن. همچنین، در این مدل چهار نقطه شروع ممکن وجود دارد: (۱) شروع با تمرکز بر مقتضیات طراحی (۲) راهحل هدف‌گذاری شده (۳) شروع با تمرکز بر طراحی و توسعه (۴) شروع با تمرکز بر مشتری/زمینه.

^۱ Design Science Research Process Model



شکل ۲. شمای کلی مطالعه در مرحله طراحی [۳]

توضیح مختصری از هر یک از این فعالیت‌ها DSR در ادامه آمده است.

فعالیت ۱. شناسایی مقتضیات و انگیزه طراحی: این فعالیت مقتضیات طراحی را شناسایی کرده و ارزش راه‌حل را بیان می‌کند. در این مطالعه، مسئله پیش‌بینی ریسک نقدینگی بانک با استفاده از روشی نوآورانه برای تخمین و تحلیل سناریوهای ریسک نقدینگی بانک و انجام اقدامات متناسب با وضعیت ریسک بانک مورد بررسی قرار می‌گیرد.

فعالیت ۲. تعریف اهداف و راه‌حل طراحی: اهداف راه‌حل طراحی از تعریف مقتضیات طراحی و آگاهی از آنچه ممکن و امکان‌پذیر است استنباط می‌شود. هدف اصلی این مطالعه دستیابی به یک سیستم ساده، عملی و با دقت بالا برای کنترل ریسک و پیش‌بینی سناریوهای در حال وقوع در بانک است، به گونه‌ای که سیستم قادر به هشدار دادن احتمالی در مورد ریسک نقدینگی باشد.

فعالیت ۳. طراحی و توسعه راه‌حل طراحی: در این فعالیت، یک مصنوع ایجاد می‌شود. مفهوماً، مصنوع طراحی شده در این مطالعه می‌تواند هر جزء طراحی‌شده‌ای باشد که در آن نوآوری تحقیقاتی وجود دارد. در این مطالعه، خروجی یا مصنوع مورد نظر، پیش‌بینی وضعیت ریسک نقدینگی بانک در ماه‌های پیش‌رو است، به‌طوری‌که بتوان ریسک نقدینگی را با استفاده از روش‌هایی که زمان و پیچیدگی کمتری دارد، محاسبه کرد. نوآوری تحقیق در روش رسیدن به این وضعیت از طریق تحلیل تمایل و پردازش زبان طبیعی صورت می‌گیرد.

فعالیت ۴. نمایش و بررسی پذیرش طراحی انجام‌شده: این فعالیت نشان می‌دهد که چگونه راه‌حل برای حل یک یا چند نمونه از مسائل استفاده می‌شود. این ممکن است شامل استفاده از آن در آزمایش‌ها، شبیه‌سازی‌ها، مطالعات موردی، اثبات‌ها یا دیگر فعالیت‌های مناسب باشد. در این مرحله، سناریوهای

ریسک نقدینگی بر اساس دستورالعمل‌های کمیته بال و سازمان نظارت بانکی اروپا استخراج می‌شوند. همچنین بر اساس نتایج مرحله قبل، سناریوهای ریسک بانکی به صورت عملی پیش‌بینی شده و اقدامات مرتبط به ذینفعان حوزه ریسک بانکی گزارش می‌شود.

فعالیت ۵. ارزیابی طراحی انجام‌شده: در این مرحله، می‌خواهیم متوجه شویم که مصنوع تا چه حد موفق بوده و آیا پیش‌بینی ریسک نقدینگی با دقت مناسبی انجام شده است. این ارزیابی شامل مقایسه بین اهداف تعیین شده با نتایج واقعی از استفاده از مصنوع در محیط مطالعاتی می‌شود. بر اساس نتایج این مرحله، تصمیم‌گیری خواهیم کرد که آیا به مرحله بعدی پیش‌روی کنیم یا به بهبودهای بیشتر در تحقیقات آینده بسنده کنیم. این تحقیق در پی پاسخ به سؤالاتی از قبیل: "آیا مصنوع پیش‌بینی‌ها را به خوبی انجام می‌دهد؟" و "آیا بانک می‌تواند بر اساس پیش‌بینی‌ها اقدامات مناسبی انجام دهد؟" می‌باشد. بر اساس نتایج این مرحله، چرخه DSR ادامه یا تکمیل خواهد یافت.

فعالیت ۶. انتشار طراحی و نتایج آن: در این مرحله، ارتباط با مخاطبان حرفه‌ای توسط اشکال مناسب انجام می‌شود و نتایج در نشریات معتبر منتشر می‌شوند. نتایج پیش‌بینی سناریوهای ریسک نقدینگی به همراه گزارشات عملیاتی به ذینفعان ارائه می‌شود.

۳-۲- شناسایی و بیان مقتضیات طراحی و ارزیابی آن

مقتضیات طراحی با محدودیت‌های مرتبط با ریسک نقدینگی ارتباط دارند. نسبت‌های معمولاً مورد استفاده برای اندازه‌گیری ریسک نقدینگی، مانند NFSR، LCR و سایر معیارها، ریسک نقدینگی با پیچیدگی بالایی دارند. برآورد وزن‌های مرتبط با عناصر عددی و ضرایب این نسبت‌ها به همراه دشواری در طبقه‌بندی مفهوم "دارایی‌های با نقدشوندگی بالا" و دسترسی به داده‌ها و پارامترهای مورد نیاز، محاسبه آن‌ها را پیچیده می‌کند. به همین دلیل، روش‌های معمول محاسبه ریسک نقدینگی به سادگی قابل انجام نیستند. در عوض، نیاز به استفاده از رویکردهای جدید برای ارزیابی و پیش‌بینی ریسک نقدینگی بانک‌ها وجود دارد. بنابراین، در این پژوهش، هدف این است که به جای تخمین دقیق ریسک نقدینگی، وضعیت ریسک نقدینگی از طریق پیش‌بینی آن از سناریوهای محتمل ریسک نقدینگی در آینده نزدیک را به ذینفعان اطلاع‌رسانی کند.


ارزیابی مقتضیات مورد نیاز طراحی: در مرور ادبیات پژوهشی، به تحلیل شکاف‌های موجود در زمینه ریسک نقدینگی پرداخته شده است. موضوع پیچیدگی محاسباتی مربوط به ریسک نقدینگی که بر پایه روش‌های مختلف تحقیق شده است، در تعداد زیادی از تحقیقات بررسی شده است. توانا و همکاران (۲۰۱۸) تأکید داشتند که محاسبات مرتبط با شاخص LCR و سایر معیارهای ریسک نقدینگی

به دلیل پیچیدگی و همچنین در مواردی به علت نبود یا دسترسی محدود به اطلاعات، زمان‌بر و دشوار است [۵]. همچنین، این موضوع در یک مقاله مروری توسط سوانسکی و همکاران، شکاف‌های موجود در تحقیقات مرتبط با استفاده از هوش مصنوعی در پیش‌بینی ریسک نقدینگی مورد تأکید و بررسی قرار گرفته است [۸]. مرور ادبیات همچنین تأکید دارد که شناسایی صحیح مقتضیات طراحی و نیاز به نوآوری در این زمینه ضروری است.

۳-۳- بیان و ارزیابی راهکار طراحی

در این مرحله، یک راه‌حل پیشنهاد و طراحی می‌شود. از نظر مفهومی، یک مصنوع DSR می‌تواند هر نمونه طراحی‌شده‌ای باشد که در آن یک نوآوری تحقیقاتی وجود دارد. این شامل تعریف عملکرد مورد نظر، معماری آن، و سپس ایجاد یک مصنوع واقعی است.

در تحقیق انجام شده، مصنوع یا فرآورده مورد نظر مدلی برای پیش‌بینی سطح ریسک نقدینگی بانک برای ماه‌های آینده است. با توجه به ماهیت غیر قطعی مسئله و نوع تأثیر عوامل محیطی مانند اخبار بر ریسک نقدینگی و پیچیدگی در تحلیل اثرات آن، از روش‌های هوش مصنوعی شامل متن‌کاوی و تحلیل احساسات به گونه‌ای استفاده شده است که برای تقریب سطح نقدینگی ریسک، سناریوهای بالقوه برای مراحل بعدی را تسهیل می‌کند. در این بخش، مدل پیشنهادی خود را نشان می‌دهیم که می‌تواند سطح نقدینگی را برای ماه آینده پیش‌بینی نماید. همان‌طور که در شکل ۳ نمای کلی طراحی راهکار یا راه‌حل طراحی نمایش داده شده است، منابع یا داده‌های ورودی شامل اخبار و داده‌های محاسبه‌شده نسبت به پوشش نقدینگی بانکی هستند. سپس ویژگی‌ها از داده‌های متنی استخراج می‌شوند. در این مرحله، ویژگی‌های کیفی از داده‌های خبری متنی با استفاده از روش‌های استخراج ویژگی در متن‌کاوی^۱ استخراج می‌شوند و این ویژگی‌ها برای استفاده در مرحله بعدی مورد بررسی قرار می‌گیرند.



شکل ۳. شکل کلی طراحی راه حل بر اساس مقتضیات طراحی

^۱ Text Mining

در بخش بعدی، پس از پالایش و پاک‌سازی داده‌های ورودی، ویژگی‌های استخراج‌شده مورد بررسی قرار می‌گیرند و در صورت لزوم با استفاده از روش‌های مهندسی ویژگی^۱، ویژگی‌ها یا ابعاد آن‌ها برای ورود به مدل تغییر می‌کنند. همچنین، داده‌های کمی مرتبط با نسبت پوشش نقدینگی، که به صورت تاریخی از یک بانک استفاده می‌شوند، برای استفاده در مدل پیش‌بینی به تغییراتی نیاز دارند. از داده‌های کمی تاریخی برای شناسایی قطبیت یا تمایلات اخبار، که به نوعی به عنوان برچسب‌های اخبار ماهانه محسوب می‌شوند، استفاده می‌شود.

داده‌های این مطالعه به دو دسته متغیر وابسته و مستقل تقسیم شده‌اند. متغیر مستقل ویژگی‌های کیفی اخبار است و متغیر وابسته شاخص ریسک نقدینگی؛ در این خصوص، ابتدا به نحوه جمع‌آوری داده‌های کیفی و سپس شاخص ریسک نقدینگی پرداخته می‌شود. در جدول ۲ منابع داده‌های تحقیق آورده شده است. در خصوص داده‌های کمی، همان‌طور که در جدول ۲ هم اشاره شده است، شاخص نسبت پوشش نقدینگی به صورت ماهانه مورد توجه قرار می‌گیرد. شاخص ریسک بانکی یک شاخص تاریخی و رو به عقب است؛ به این معنی که وضعیت فعلی یا گذشته بانک را نمایش می‌دهد [۲].

جدول ۲. متغیرها و داده‌های مطالعه.

ردیف	عنوان متغیر	نوع متغیر	نوع داده	زمان داده	منبع داده
۱	نسبت پوشش نقدینگی	متغیر کمی	داده‌های ریسک نقدینگی بانک	فروردین ۱۳۸۸ – اسفند ۱۳۹۹	بانک بخش نیمه خصوصی ایران
۲	شاخص کیفی اخبار	متغیر کیفی	اخبار	فروردین ۱۳۸۸ – اسفند ۱۳۹۹	سایت خبرگزاری‌های معتبر فارس نیوز

داده‌های نسبت پوشش نقدینگی برای یکی از بانک‌های نیمه‌خصوصی ایران در دسترس قرار گرفت. این داده‌ها از فروردین ۱۳۸۸ تا بهمن ۱۳۹۹ به صورت ماهیانه جمع‌آوری شده‌اند. در تحقیقات پیشین در زمینه تحلیل تمایل ریسک بانکی، جهت محاسبه امتیاز تمایل^۲ یا شناسایی قطبیت داده‌های متنی از سه دسته مثبت، منفی و خنثی استفاده شده است [۲]. به همین منوال، در این مطالعه نیز برای شناسایی قطبیت یا برچسب‌گذاری داده‌های متنی از همین رویکرد استفاده شده است. برای محاسبه قطبیت (برچسب) از تحلیل روند شاخص نقدینگی ریسک نسبت به ماه گذشته استفاده شده است، به این ترتیب که دسته مثبت به افزایش این شاخص نسبت به ماه قبل اشاره دارد، دسته منفی به معنای کاهش نسبت به ماه قبل و دسته عدم تغییر به معنای عدم تغییر محسوس نسبت به ماه

^۱ Feature Engineering

^۲ Sentiment Score




قبل در نظر گرفته شده است.

ارزیابی راهکار طراحی: مروری بر تحقیقات انجام‌شده در زمینه پیش‌بینی ریسک نقدینگی نشان می‌دهد که از تکنیک‌های یادگیری ماشین و مدل‌های آماری با استفاده از پارامترهای کمی می‌توان برای تخمین ریسک نقدینگی استفاده کرد. به علاوه، سوانسکی و همکاران در یک پژوهش مروری تأیید کردند که روش‌های یادگیری ماشین و هوش مصنوعی نقش مهمی در پیش‌بینی و تحلیل ریسک نقدینگی ایفا می‌کنند. با این حال، عدم بررسی این مسئله در تحقیقات پیشین را به عنوان یک شکاف در ادبیات موجود تحقیقاتی تلقی کردند [۸]. همچنین، تحقیقات دیگر در حوزه مدیریت ریسک بانکی، از جمله ریسک اعتباری، بازاری، کفایت سرمایه و سایر موارد، با استفاده از روش‌های تحلیل تمایل، متن‌کاوی، پردازش زبان طبیعی و دیگر روش‌های یادگیری ماشین، نتایج قابل قبولی با دقت بالا ارائه داده‌اند [۲،۷،۸،۹،۱۰،۱۸،۱۹،۲۵].

بنابراین، راه‌حل پیشنهادی با تکیه بر نظریات علوم داده و مدیریت ریسک بانکی تفسیر پذیر و قابل بررسی است. استفاده از پارامترهای کیفی می‌تواند پیچیدگی‌های محاسباتی مدل را با توجه به محدودیت‌های اندازه‌گیری ریسک نقدینگی به حداقل برساند و یک راه‌حل قابل اجرا ارائه دهد. دانش و تئوری‌های نظری و همچنین منطق راه‌حل، اعتبارسنجی و پایداری آن را تصدیق می‌کنند. سادگی راه‌حل پیشنهادی، همچنان از نظر ارزیابی این مرحله تأیید شده است.

۳-۴- طراحی، توسعه و ارزیابی راهکار

در شکل ۴ مراحل طراحی و توسعه آن بر اساس روش پژوهش علم طراحی نمایش داده شده است.



شکل ۴. مراحل طراحی و توسعه راهکار طراحی



مراحل پژوهش به شرح زیر است:

مرحله اول: جمع‌آوری داده‌های کمی و کیفی از منابع مرتبط (بانک و خبرگزاری).
مرحله دوم: پیش‌پردازش و آماده‌سازی داده‌های متنی و همچنین آماده‌سازی داده‌های کمی مرتبط با ریسک نقدینگی.
مرحله سوم: شناسایی و استخراج ویژگی‌های کیفی و تشخیص روابط معنادار بین ریسک نقدینگی و متغیرهای کیفی.
مرحله چهارم: ایجاد مدل طبقه‌بندی یا تحلیل تمایل با استفاده از روش‌های مرسوم یادگیری ماشین.
هدف اصلی این بخش از پروژه است.
مرحله پنجم: این مرحله به پیش‌بینی ریسک نقدینگی و ارزیابی روش یا مدل انتخاب‌شده می‌پردازد. معیارهای ارزیابی شامل میزان دقت پیش‌بینی، نمودارها و مصورسازی خروجی‌ها در این بخش از تحقیق ارائه می‌شود.

تحلیل تمایل اخبار: در روش تحلیل تمایل با استفاده از یادگیری ماشین، تمرکز بر روی بررسی تمایلات و قطبیت در متون قرار دارد. این روش به مدل‌سازی متون اجازه می‌دهد تا نظرات و تمایلات پنهان موجود در متن را تشخیص داده و آن‌ها را در سه دسته «مثبت^۱»، «منفی^۲» یا «خنثی^۳» دسته‌بندی نماید. تحلیل تمایل در حوزه‌های مختلفی از جمله سازمان‌ها و شرکت‌های تجاری کاربرد دارد. به عنوان مثال، در مورد خدمات پشتیبانی مشتریان، شرکت‌ها می‌توانند از این تحلیل برای شناسایی سریع‌تر مشتریان ناراضی و اولویت‌بندی پاسخ‌گویی به نیازهای آن‌ها با درجه بالاتر اقدام نمایند.

ویژگی‌های مورد نظر نیز از کلمات کلیدی استخراج‌شده از این اخبار هستند. در این روش، مدل با یادگیری این ویژگی‌ها (کیفی) به برچسب‌های اخبار، ارتباط میان روند ریسک نقدینگی و اخبار را تحلیل می‌نماید. در خصوص پیش‌بینی ریسک، در مطالعات پیشین، روش‌های مختلفی نظیر رگرسیون لجستیک^۴ [۲۲]، ماشین بردار پشتیبان^۵ [۲۳] و شبکه‌های مصنوعی عصبی^۶ [۱۳] بررسی شده‌اند. علاوه بر روش‌های نامبرده، روش مرسوم دیگری که در مطالعه تحلیل تمایل مورد استفاده قرار می‌گیرد، شبکه‌های یادگیری عمیق هستند. انواع مختلفی از شبکه‌های عصبی عمیق وجود دارند، مانند شبکه‌های عصبی بازگشتی، شبکه‌های عصبی کانولوشنی، ماشین بولتزمن، خود رمزنگار^۱ و موارد دیگر که در این مطالعه از شبکه عصبی کانولوشنی استفاده شده است.

^۱ Positive

^۲ Negative

^۳ Natural

^۴ Logistic Regression


^۵ Support Vector Machine

^۶ Auto-Encoder

روش تحلیل تمایل بر پایه یادگیری عمیق با استفاده از شبکه‌های کانولوشنی: در شکل ۷. معماری شبکه یادگیری کانولوشنی ساختار کلی شبکه عمیق کانولوشنی نمایش داده شده است [۲۴]؛ معماری آن شامل نورون‌هایی است که در ابعاد عرض، ارتفاع و عمق مرتب شده‌اند. دارای یک لایه ورودی و لایه‌های پنهان که معمولاً دارای لایه کانولوشن، لایه جمع‌آوری^۱ و یک لایه کاملاً متصل^۲ و به دنبال آن یک لایه خروجی است. در اینجا، محاسبات ریاضی کانولوشنی، با آرگومان‌های ورودی و هسته^۳ برای ایجاد یک ماتریس ویژگی انجام می‌شود. سه ویژگی اصلی یک کانولوشن شامل تعامل کم بین لایه‌ها، به اشتراک‌گذاری پارامترها و نمایش‌های مشابه است. آن‌ها می‌توانند پیشرفت‌های عملکردی قابل توجهی نسبت به سایر روش‌های یادگیری ماشین داشته باشند. برای شناسایی خودکار ویژگی‌های اشتراکی از داده‌های سری زمانی، مدل‌های مختلف پیش‌بینی مبتنی بر CNN ساخته شده است. [۲۵] بعد از آماده‌سازی داده، با استفاده از رویکرد تحلیل تمایل و روش‌های یادگیری عمیق کانولوشنی، تلاش شده است تا بر اساس ویژگی‌های موجود در ماتریس برچسب‌ها، تمایلات مثبت، منفی و خنثی را پیش‌بینی کنیم که مرتبط با ریسک نقدینگی در آینده است. همان‌گونه که در شکل ۵ نشان داده شده است، شبکه‌های عمیق کانولوشنی دارای یک ساختار لایه‌ای هستند و ماتریس ویژگی‌ها جهت یادگیری برچسب‌ها به لایه ورودی شبکه داده می‌شود.

ساختار کلی شبکه عمیق کانولوشنی در شکل ۵ نمایش داده شده است [۲۴]. معماری این شبکه شامل نورون‌هایی است که در ابعاد عرض، ارتفاع و عمق به ترتیب مرتب شده‌اند. این شبکه شامل یک لایه ورودی و لایه‌های پنهان است که معمولاً شامل لایه‌های کانولوشن، لایه‌های جمع‌آوری^۱ و یک لایه کاملاً متصل^۲ است. در نهایت، یک لایه خروجی نیز وجود دارد. محاسبات ریاضی تابع کانولوشن با استفاده از آرگومان‌های گام^۴ و هسته^۳ روی ماتریس ویژگی انجام می‌شود. سه ویژگی اصلی کانولوشن شامل تعامل کم بین لایه‌ها، به اشتراک‌گذاری پارامترها و نمایش‌های مشابه می‌باشد. این ویژگی‌ها می‌توانند در عملکرد نسبت به روش‌های دیگر یادگیری ماشین بهبود ایجاد کنند [۲۵]. مدل کلی شبکه یادگیری توسعه یافته کانولوشنی به شرح در شکل ۵ نمایش داده شده است که شامل ماتریس ورودی، چند لایه کانولوشن به همراه، لایه *pooling*، یک لایه تسطیح و نهایتاً لایه کاملاً متصل است که برچسب‌ها را طبقه‌بندی می‌نماید.

^۱ Pooling Layer^۲ Fully Connected^۳ Kernel^۴ Pooling Layer^۵ Fully Connected^۶ Stride^۷ Kernel



شکل ۵. مدل طبقه بند یادگیری کانولوشنی

در شبکه‌های طراحی شده، از چند لایه مختلف استفاده شده است. این لایه‌ها عبارتند از لایه‌های کانولوشن یک‌بعدی، لایه‌های *Max Pooling* یک‌بعدی و لایه‌های چگال^۱. هسته اصلی شبکه کانولوشن، لایه کانولوشن است و درصد زیادی از محاسبات شبکه عصبی کانولوشن را انجام می‌دهد. هر لایه کانولوشن در شبکه شامل مجموعه‌ای از فیلترها است و خروجی‌هایی که از کانولوشن بین این فیلترها و لایه ورودی تولید می‌شود.


پارامتر *Filters* در لایه *ConvID* تعداد ویژگی‌های تشخیص داده‌شده (یا ابعاد فضای خروجی) را نشان می‌دهد و هدف اصلی لایه *Max Pooling* کاهش اندازه ماتریس ویژگی به دست آمده از لایه کانولوشن است. لایه *Max Pooling* پارامتر قابل آموزش ندارد و تنها یک نمونه برداری ساده و موثر انجام می‌دهد. پارامتر *Pool_size* در لایه *Max PoolingID* اندازه پنجره *Max Pooling* را مشخص می‌کند.

معمولاً لایه‌های آخر شبکه عصبی کانولوشن شامل لایه‌های چگال هستند. یکی از کاربردهای اصلی لایه چگال در شبکه کانولوشن، تبدیل مجموعه ویژگی‌های استخراج شده از لایه‌های کانولوشن به یک بردار است. سپس این بردار ویژگی به لایه کاملاً متصل داده می‌شود تا بتواند کلاس مربوطه را تشخیص دهد.

معماری لایه‌های شبکه کانولوشن در دو حالت (a) برای ۳ کلاس قطبیت و (b) برای ۵ کلاس طراحی شده است. برچسب سه کلاسه شامل روند مثبت، منفی و خنثی است، در حالی که برچسب پنج کلاسه شامل روند خیلی مثبت، مثبت، منفی، خیلی منفی و خنثی است.

^۱ Dense

همچنین، یکی از پارامترهای مورد نظر تعداد ادغام یا پارامتر m بوده که در دو حالت ۳۰۰ و ۵۰۰ تنظیم شده است. این به این معناست که ۴ مدل یادگیری عمیق برای مدل‌های ادغام ۳۰۰ و ۵۰۰ و همچنین ۳ کلاس و ۵ کلاس در نظر گرفته شده است. پارامتر $Kernel_size$ در لایه‌ی $Conv1D$ طول پنجره‌ی کانولوشن را مشخص می‌کند. شکل ۶ معماری کلی طراحی شده شبکه کانولوشنی را نمایش می‌دهد.



شکل ۷. معماری شبکه یادگیری کانولوشنی

ارزیابی مرحله طراحی و توسعه راهکار: در این مرحله از روش‌های تصادفی برای انتخاب داده‌های آموزش، تست و ارزیابی استفاده شده است. داده‌های تحقیق جهت ارزیابی نتایج به سه دسته، داده‌های آموزش، اعتبارسنجی و تست تقسیم می‌شوند. ۷۰٪ داده‌ها جهت آموزش اولیه، ۱۵٪ جهت تنظیم پارامترها در اعتبارسنجی و نهایتاً ۱۵٪ جهت تست استفاده گردید. مدل طبقه‌بند آموزش‌دیده برای پیش‌بینی برچسب‌های واقعی ۳ یا ۵ کلاس ابتدا با داده‌های اعتبارسنجی

و سپس توسط داده‌های تست ارزیابی می‌شود. برای آزمون نتایج پیش‌بینی، الگوریتم مورد استفاده نیز از معیارهای مرسوم و استاندارد ارزیابی طبقه‌بندها استفاده شد، از جمله (i) دقت (Precision)، (ii) بازخوانی (Recall)، (iii) دقت کلی (Accuracy)، (iii) اف اسکور (F-Score). نحوه محاسبه این نسبت‌ها در ادامه ارائه شده است [۱۹].

$$\begin{aligned} (۲) \quad Recall = SN &= \frac{TP}{TP+FN} \\ (۳) \quad Precision = SP &= \frac{TN}{TN+FP} \\ (۴) \quad Accuracy &= \frac{TP+TN}{TP+TN+FP+FN} \end{aligned}$$

۱. دقت: نشان می‌دهد که چقدر مدل یادگیری ماشین طبقه‌بندی به طور کلی درست عمل می‌کند.

۲. بازخوانی: نشان می‌دهد که چقدر مدل یادگیری ماشین در پیش‌بینی کلاس هدف به درستی عمل می‌کند.

۳. صحت: نشان می‌دهد که آیا مدل یادگیری ماشین توانایی شناسایی تمام اشیاء کلاس هدف را دارد یا خیر.

۴. امتیاز اف-اسکور (F-Score): یک اندازه‌گیری ترکیبی از دقت و بازخوانی است که بیان‌گر ترکیب کارایی مدل در تشخیص کلاس هدف می‌شود.

$$(۵) \quad F1 - Score = ۲ * \frac{Precision * Recall}{Precision + Recall}$$

نتایج مرحله طراحی و توسعه راه‌کار: همان‌طور که در بخش‌های قبلی نیز توضیح داده شد، داده‌های خبری با دو مدل ۳۰۰ تایی و ۵۰۰ تایی ادغام شده‌اند و مدل نهایی دارای ماتریس ویژگی‌هاست که روند ریسک نقدینگی بانک را نشان می‌دهد؛ برچسب‌ها نیز به دو صورت ۳ کلاسه و ۵ کلاسه ایجاد شده است. بنابراین، الگوریتم شبکه یادگیری کانولوشنی دارای ۴ حالت مختلف است و نتایج آن در این بخش ارزیابی می‌شود. جدول ۳ شامل حالات متنوع با استفاده از روش یادگیری شبکه کانولوشنی برای تحلیل تمایل است.

با توجه به جدول ۳، حالات متنوعی برای تنظیم و انتخاب فرا پارامترها با استفاده از داده‌های اعتبارسنجی (۱۵٪ داده) مورد بررسی قرار می‌گیرند که در پارامترهای مورد بررسی برای شبکه یادگیری کانولوشنی اشاره شده است. سرانجام، بعد از بررسی فرا پارامترهای زیادی، دقت داده‌های اعتبارسنجی^۱ به عنوان ملاک اصلی برای انتخاب این پارامترها در الگوریتم مورد استفاده قرار گرفت.

^۱ Validation Accuracy

جدول ۳. حالات مختلف در تحلیل شبکه عمیق – تحلیل تمایل.

ردیف	تعداد نمونه‌ها	نوع ادغام	تعداد کلاس‌ها
۱	۱۶۵۷	$m=300$	$l=3$
۲	۱۰۰۰	$m=300$	$l=5$
۳	۱۶۵۷	$m=500$	$l=3$
۴	۱۰۰۰	$m=500$	$l=5$

جدول ۴. جدول مقایسه و تنظیم پارامترهای مرتبط با الگوریتم شبکه یادگیری کانولوشنی.

ردیف	تعداد ادغام	تعداد پرچسب	Filters	Dense Units	Activation	Optimizer	val_acc
۱	۳۰۰	۳	۳۲-۶۴-۶۴	۶۴	relu	rms	۸۹.۱۱
۲	۳۰۰	۵	۳۲-۶۴	۶۴	relu	rms	۸۵.۸۹
۳	۵۰۰	۳	۱۶-۳۲	۳۲	relu	adam	۸۸
۴	۵۰۰	۵	۱۶-۳۲	۳۲	relu	rms	۸۴

در جدول ۴، مجموعه‌ای از پارامترهای متنوع که در شبکه یادگیری کانولوشنی مورد استفاده قرار گرفته است، نمایش داده شده است. الگوریتم طراحی شده دقتی حدود ۸۹٪ برای داده‌های اعتبارسنجی دارد. معیارهای مربوط به سایز هسته (*Kernel Size*) و سایز پولینگ (*Pool Size*) به صورت ثابت برای تمامی حالات در نظر گرفته شده است. در حالت سه کلاس و با نوع ادغام $m=300$ و سایر پارامترهای انتخاب‌شده، شبکه توانست با دقت حدود ۸۹٪ عملکرد مناسبی ارائه دهد، اما در نوع ادغام $m=500$ ، این دقت به حدود ۸۶٪ کاهش یافت. با انتخاب بهترین پارامترها، در حالت ۵ کلاسه برای نوع ادغام $m=300$ ، دقت حدود ۸۸٪ و در $m=500$ حدود ۸۴٪ حاصل شد. بهترین دقت به‌دست‌آمده در الگوریتم طراحی شده (حدود ۸۹٪) برای داده‌های اعتبارسنجی ایجاد شد.

در جدول ۵، ارزیابی نتایج کلی روش پیشنهادی برای هر یک از معیارها ارائه شده است. بهترین نتایج مدل یادگیری کانولوشنی در حالت پنج کلاسه و مدل ادغام ۳۰۰ تایی دقت تست حدود ۸۵٪ دارد، و در حالت سه کلاسه و ۳۰۰ تایی دقت تست حدود ۸۳٪ را به‌همراه دارد. همچنین، معیار *F1-Score* در این حالت نسبت به سایر حالت‌ها بهتر عمل کرده است. در پایان، معیار *ROC-AUC* نیز برای حالت ۵۰۰ با ۵ کلاس بهترین نتایج را نشان داده که حدود ۹۷٪ است.

جدول ۵. نتایج معیارهای ارزیابی حاصل‌شده از روش شبکه یادگیری کانولوشنی.

تعداد ادغام	تعداد برچسب	دقت تست	Precision	Recall	F1-Score	ROC-AUC
۳۰۰	۳	۸۳.۱۳	۸۳.۱۳	۸۴.۰۷	۸۲.۹۵	۹۴.۰۶
۳۰۰	۵	۸۵.۳۳	۸۵.۱۳	۸۵.۳۳	۸۵.۲۵	۹۵.۰۵
۵۰۰	۳	۷۹.۱۲	۷۹.۱۶	۷۹.۱۲	۷۹.۰۵	۹۵.۷۸
۵۰۰	۵	۸۱.۳۳	۸۲.۶۷	۸۱.۳۳	۸۱.۰۴	۹۶.۵۴

نهایتاً با در نظر گرفتن خروجی تمامی معیارها، می‌توان روش مدل ادغام ۳۰۰ تایی با ۵ کلاسه را به عنوان بهترین روش برای پیش‌بینی ریسک نقدینگی بانک بر اساس داده‌های کیفی خبری این مطالعه معرفی نمود. البته حالت‌هایی با مدل ادغام ۵۰۰ تایی با ۵ برچسب و مدل ادغام ۳۰۰ تایی با ۳ کلاس در رتبه‌های بعدی قرار دارند.

۳-۵- پذیرش راهکار طراحی و ارزیابی نتایج کاربردی

در این مرحله به توضیح نحوه پذیرش طراحی انجام‌شده و روش‌های کاربردی نمودن مطالعه می‌پردازیم. ابتدا، نتایج مرحله قبل را برای استفاده در این مرحله آماده‌سازی می‌کنیم. در ادامه، سناریوهای ممکن بر اساس محدوده‌های تعریف‌شده و استخراج شده از وضعیت ریسک نقدینگی بانک‌ها ارائه می‌شوند. در نهایت، سناریوهای رخ‌داده بر اساس نتایج مرحله قبل نمایش داده می‌شوند تا بتوان تحلیلی از ارتباط بین نتایج و سناریوها ارائه نمود. سناریوهای رخ‌داده بر اساس نتایج سناریوهای بدست‌آمده از مرحله قبل که مرتبط با پیش‌بینی سناریوهای پیش‌رو است، مورد مقایسه قرار می‌گیرند تا دقت پیش‌بینی سناریوها تعیین گردد.

همان‌طور که در شکل زیر نمایش داده شده است، داده‌های آزمون در مرحله قبل به‌صورت اخبار ماهانه دسته‌بندی شده‌اند. با توجه به روش‌های ادغام ۳۰۰ تایی یا ۵۰۰ تایی (که در مرحله نمونه‌سازی توضیح داده شده است) اخبار هر ماه به چند نمونه (که هر نمونه شامل m خبر است) تقسیم می‌شوند. بنابراین، با وارد کردن هر نمونه به مدل پیش‌بینی، یک وضعیت مشخص یا تمایل تخمین زده می‌شود. به منظور جمع‌بندی برچسب هر ماه پس از تخمین وضعیت ریسک هر نمونه، بین نمونه‌ها از روش رأی‌گیری یا فرکانس تکرار استفاده می‌شود تا نتیجه ماهانه یا وضعیت ماهانه ریسک برآورد شود. به عبارت دیگر، اگر ماه اول دارای ۲۵ نمونه باشد و به ترتیب برچسب اول ۱۰ بار، برچسب دوم ۸ بار و

برچسب سوم ۷ بار پیش‌بینی شود، روش رأی‌گیری بیشترین تکرار یا برچسب اول را به عنوان برچسب انتخابی برای آن ماه در نظر می‌گیرد. به همین ترتیب می‌توان برچسب‌ها (وضعیت ریسک) ماه‌های آزمون را نیز پیش‌بینی کرد. با داشتن اخبار ماه‌هایی که هنوز ریسک نقدینگی آن‌ها محاسبه نشده یا ماه پیش‌رو است، می‌توان وضعیت ریسک ماه مورد نظر را پیش‌بینی نمود. در ادامه، سناریوهای محتمل بر اساس چارچوب بازل در ریسک نقدینگی نیز توضیح داده می‌شود.

بازل رهنمودهایی در زمینه مدیریت ریسک نقدینگی ارائه داده است که محدوده‌های مورد استفاده در این تحقیق از این چارچوب الهام گرفته و تاثیرپذیری این محدوده‌ها در مورد بانک‌ها نیز مورد بررسی و تایید قرار گرفت. بر اساس رویکرد معرفی شده در بازل، می‌توان دو محدوده (محدوده امن و محدوده ناامن) را در نظر گرفت:

(۱) محدوده امن: محدوده‌ای است که بالای حد مجاز LCR باشد

(۲) محدوده ناامن: محدوده است که پایین‌تر از حد مجاز LCR باشد.

علاوه بر این، در این تحقیق، مرجع بانکی اتحادیه اروپا محدوده‌های بیشتری که توسط متخصصان بانکی نیز تایید شده، معرفی کرده که برای تشخیص سناریوها در این مطالعه به کار گرفته شد. در جدول ۶، حالات مختلف محدوده LCR بر اساس چارچوب کمیته بال و مرجع بانکی اتحادیه اروپا که با اداره مدیریت ریسک بانک نیز بررسی شد، ارائه شده‌اند [۲۶].

جدول ۶. محدوده مشتق شده از LCR بانک‌ها بر اساس دستورالعمل کمیته بال و اداره ریسک بانک.

محدوده ریسک	سال ۲۰۱۶ به قبل	سال ۲۰۱۶ تا ۲۰۱۷	سال ۲۰۱۷ تا ۲۰۱۸	سال ۲۰۱۸ تا ۲۰۱۹	سال ۲۰۱۹ به بعد
کاملاً امن	>۶۰	>۷۰	>۸۰	>۹۰	>۱۰۰
امن	۶۰	۷۰	۸۰	۹۰	۱۰۰
احتیاطی	۲۰-۶۰	۳۰-۷۰	۴۰-۸۰	۵۰-۹۰	۶۰-۱۰۰
بحرانی	<۲۰	<۳۰	<۴۰	<۵۰	<۶۰

ارزیابی نتایج مرحله پذیرش طراحی راهکار و کاربردپذیری: در این زمینه، سناریوهای ممکن برای شاخص LCR در بانک‌ها بر اساس مرجع بانکی اتحادیه اروپا در ۱۲ سناریو توضیح داده می‌شود، هر کدام از این سناریوها اهمیت خاصی برای بانک دارند و باید اقدامات مناسبی با توجه به هر سناریو در بانک انجام شود. بنابراین، شناسایی و پیش‌بینی سناریوهای ممکن بر اساس وضعیت فعلی بانک در ماه بعد بسیار مهم است، زیرا بانک می‌تواند با پیش‌بینی این سناریوها و اقدامات پیش‌رو، ریسک‌ها

را کاهش یا پوشش ریسک را قبل از وقوع آن انجام دهد.

در جدول ۷، سناریوهای امکان‌پذیری از جدول ۶ استخراج شده و در ۱۲ سناریو مختلف دسته‌بندی شده‌اند، توضیح داده شده است؛ به‌طوری‌که هر کدام از این سناریوها اهمیت خاصی برای بانک دارند و باید با توجه به هر سناریو اقدامات مناسبی در بانک صورت گیرد. همچنین اقدامات مناسب برای هر یک از این سناریوها بر اساس نظر کارشناسان بانکی و همچنین با توجه به گزارش اتحادیه بانکی اروپا در زمینه اقدامات و برنامه‌های بهبود، تنظیم شده است [۲۷].


برای ارزیابی سناریوهای وقوع یافته و مقایسه آن‌ها با پیش‌بینی‌های ماهانه، ابتدا سناریوهای واقعی که در بانک اتفاق می‌افتد بر اساس نتایج موجود شناسایی می‌شوند. سپس این سناریوها با پیش‌بینی‌های انجام شده مقایسه و ارتباط آن با روند ریسک که در مرحله قبل به‌صورت ماهانه برای سه کلاس و پنج کلاس محاسبه شده است، بررسی می‌شود.

جدول ۷. جدول سناریوهای مستخرج از محدوده کمیته بال.

شماره سناریو	محدوده مبدا سناریو	محدوده مقصد سناریو	نوع تغییر سناریو	جذابیت از منظر نهاد ناظر/ نوع اقدام
۱	محدوده امن	محدوده کاملاً امن	کاهش ریسک	اهمیت ندارد - اقدامی انجام نمی‌شود
۲	محدوده کاملاً امن	محدوده امن	افزایش ریسک	جذابیت ندارد - اقدامی انجام نمی‌شود
۳	محدوده امن	محدوده امن	عدم‌تغییر	جذابیت ندارد - اقدامی انجام نمی‌شود
۴	محدوده امن	محدوده احتیاطی	افزایش ریسک	جذابیت دارد- اقدام : سرمایه‌گذاری در مواردی با نقدشوندگی بیشتر
۵	محدوده احتیاطی	محدوده امن	کاهش ریسک	جذابیت دارد - اقدامی انجام نمی‌شود
۶	محدوده احتیاطی	محدوده احتیاطی	عدم‌تغییر	جذابیت دارد- اقدام : سرمایه‌گذاری در مواردی با نقدشوندگی بیشتر
۷	محدوده احتیاطی	محدوده بحرانی	افزایش ریسک	جذابیت دارد- اقدام : دارائی‌های نقد شونده‌ی پایین فروخته شود
۸	محدوده بحرانی	محدوده احتیاطی	کاهش ریسک	جذابیت دارد - سرمایه‌گذاری در مواردی با نقدشوندگی بیشتر
۹	محدوده بحرانی	محدوده بحرانی	عدم‌تغییر	جذابیت دارد- اقدام : دارائی‌های نقد شونده‌ی پایین فروخته شود

شماره سناریو	محدوده مبدا سناریو	محدوده مقصد سناریو	نوع تغییر سناریو	جذابیت از منظر نهاد ناظر/ نوع اقدام
۱۰	محدوده بحرانی	محدوده امن محدوده کاملاً امن	کاهش ریسک	جذابیت دارد- اقدامی انجام نمی شود
۱۱	محدوده امن یا کاملاً امن	محدوده بحرانی	افزایش زیاد ریسک	جذابیت دارد- اقدام: دارائی های نقد شوندگی پایین فروخته شود
۱۲	محدوده کاملاً امن	محدوده کاملاً امن	عدم تغییر	اهمیت ندارد-

شکل ۸ سناریو رخ داده در سال ۲۰۱۸ را نمایش می‌دهد. ریسک نقدینگی در محدوده کاملاً امن و بحرانی قرار دارد. در مجموع سناریوهای رخ داده ۹، ۱۰ و ۱۲ است.




شکل ۸. سناریوهای رخ داده در سال ۲۰۱۸ در محدوده‌های ریسک نقدینگی


شکل ۹ نیز روند ریسک نقدینگی و پیش‌بینی ریسک نقدینگی با استفاده از الگوریتم شبکه یادگیری کانولوشنی را با رنگ‌های سبز (افزایش)، قرمز (کاهش) و خاکستری (عدم تغییر) نمایش داده شده است. روند تمایلات پیش‌بینی شده در ماه‌های مختلف با تغییرات مقدار LCR کاملاً انطباق دارد. شکل ۱۰ نیز نمایش‌دهنده روند ۵ کلاسه ریسک نقدینگی با استفاده از روش یادگیری کانولوشنی است. روند افزایش، کاهش و عدم تغییر در این نمودار نیز به‌درستی با تغییرات LCR هماهنگی دارد. همچنین

در نمودارهای فوق تغییرات بین محدوده امن و ناامن را که مورد نظر دستورالعمل کمیته بال است، به درستی پیش‌بینی شده است.

همانگونه که در جدول ۸ مشاهده می‌شود، مقایسه بین وضعیت ریسک نقدینگی بر اساس سناریوهای رخ داده و پیش‌بینی شده برای سال ۲۰۱۸ برای برچسب‌های سه و پنج کلاسه ارائه شده است. نتایج در هر دو حالت در اکثر ماه‌ها دقت بالایی دارند و درصد پیش‌بینی‌های صحیح تقریباً ۸۱٪ است.



شکل ۹. پیش‌بینی تمایل با شبکه یادگیری کانولوشنی، ادغام ۳۰۰ و سه لیبل در ماه‌های سال ۲۰۱۹ و ۲۰۲۰ و روند تغییرات (+ افزایش، ۰ عدم تغییر و - کاهش به نسبت ماه قبل)



شکل ۱۰. پیش‌بینی تمایل با شبکه یادگیری کانولوشنی، ادغام ۳۰۰ و پنج برچسب در ماه‌های سال ۲۰۱۸ و روند تغییرات (+ افزایش زیاد، + افزایش، ۰ عدم تغییر و - کاهش کم و - کاهش زیاد به نسبت ماه قبل)

جدول ۸. مقایسه بین روند ریسک در سناریوهای رخ داده و پیش‌بینی تمایل ریسک هر ماه در سال ۲۰۱۸

تاریخ (ماه)	نوع سناریو	روند ریسک بر اساس سناریوی رخ داده	پیش‌بینی تمایل ریسک (۳ کلاس)	پیش‌بینی تمایل ریسک (۵ کلاس)
۲	سناریوی ۹	عدم تغییر ریسک	عدم تغییر	افزایش ریسک (کم) - عدم تغییر
۳	سناریوی ۱۰	کاهش ریسک (زیاد)	کاهش ریسک	کاهش ریسک (زیاد)
۴	سناریوی ۱۲	عدم تغییر ریسک	کاهش ریسک - عدم تغییر ریسک	کاهش ریسک (زیاد) - عدم تغییر ریسک
۵	سناریوی ۱۲	عدم تغییر ریسک	کاهش ریسک - عدم تغییر ریسک	کاهش ریسک (زیاد) - عدم تغییر ریسک
۶	سناریوی ۱۲	عدم تغییر ریسک	کاهش ریسک - عدم تغییر ریسک	کاهش ریسک (زیاد) - عدم تغییر ریسک
۷	سناریوی ۱۲	عدم تغییر ریسک	کاهش ریسک - عدم تغییر ریسک	کاهش ریسک - عدم تغییر
۸	سناریوی ۱۲	عدم تغییر ریسک	عدم تغییر ریسک	کاهش کم ریسک - عدم تغییر
۹	سناریوی ۱۲	عدم تغییر ریسک	عدم تغییر ریسک	عدم تغییر ریسک
۱۰	سناریوی ۱۲	عدم تغییر ریسک	افزایش ریسک	افزایش کم ریسک

جدول ۹ به طور کلی صحت پیش‌بینی مدل را بر اساس سناریوهای واقع شده در سال ۲۰۱۸ و در محدوده دوگانه کمیته بال و همچنین محدوده‌های ۴ گانه اتحادیه بانکی اروپا بررسی و ارزیابی می‌کند.

جدول ۹. ارزیابی نتایج در روش تحلیل سناریو - تحلیل تمایل.

روش تحلیل سناریو	نوع کلاس	۲۰۱۸	میانگین دقت کلی
دقت پیش‌بینی‌های محدوده امن و غیر امن	سه کلاسه	۸۲٪	۸۶.۵٪
	پنج کلاسه	۹۱٪	
دقت پیش‌بینی‌های محدوده ۴ گانه (خبرگان)	سه کلاسه	۸۲٪	۸۲٪
	پنج کلاسه	۸۲٪	

همان‌طور که نتایج در جدول ۹ نشان می‌دهد، دقت پیش‌بینی‌های سه‌کلاسه و پنج‌کلاسه در محدوده مورد انتظار بازل به ترتیب ۸۲٪ و ۹۱٪ است. در محدوده ۴ گانه مورد نظر خبرگان بانکی، حدوداً ۸۱٪ برای حالت ۳ کلاسه و همچنین حدود ۸۱٪ برای حالت ۵ کلاسه می‌باشد. بهترین نتیجه با دقت ۹۱٪ در محدوده ۲ گانه بازل با برچسب ۵ کلاس به دست آمده است. میانگین دقت برای محدوده ۲ گانه بازل ۸۶.۵٪ و برای محدوده ۴ گانه اتحادیه بانکی اروپا ۸۲٪ است.


در انتها، نتایج این مرحله از چرخه DSR را به پایان می‌رساند. اگرچه نتایج بدست آمده برای این مطالعه قابل قبول هستند، اما در صورت نیاز، می‌توان برای افزایش دقت مدل چرخه را مجدداً تکرار کرد. با این حال، در این مطالعه نتایج قابل قبول بوده و چرخه به پایان می‌رسد.

۴- بحث

به دلیل نوآوری و شیوه‌ی جدید مطالعه، تاکنون هیچ تحقیقی در زمینه بررسی تأثیر عوامل کیفی بر مدل پیش‌بینی ریسک نقدینگی انجام نشده است و دیگر تحقیقات مشابه تمرکز خود را بر روی متغیرهای کمی داشته‌اند. به همین دلیل مقایسه با روش‌های مشابه در تحقیقات گذشته امکان‌پذیر نمی‌باشد. در مقاله مروری که توسط شارما (۲۰۱۹) منتشر شد، تنها یک مطالعه توسط آقای توانا (۲۰۱۸) با رویکرد متفاوتی در پیش‌بینی ریسک نقدینگی انجام شده است که به بررسی و تحلیل پارامترهای کمی می‌پردازد و نتایج پیش‌بینی از طریق تحلیل شبکه‌های عصبی و بیز ارائه شده است [۲۸].

در یک تحقیق دیگر، با استفاده از روش‌های ANOVA و مدل‌های لجیت و پروبیت، دقت مدل پیش‌بینی به میزان ۸۵٪ برآورد شده است [۱۵]. علاوه بر این، مطالعه توانا و همکاران با استفاده از شبکه‌های عصبی به میزان حدود ۷۰٪ دقت در پیش‌بینی ریسک نقدینگی داشتند، در حالی که روش پیشنهادی این مطالعه از شبکه‌های یادگیری کانولوشنی استفاده کرده و دقتی حدود ۸۵.۳۳٪ ارائه داده است. روش پیشنهادی (CNN) با روش Logit/Probit نتایج مشابهی ارائه داده و نسبت به روش ANN عملکرد بهتری داشت. این تحقیق از متغیرهای کیفی برای پیش‌بینی ریسک نقدینگی استفاده می‌کند، در حالی که تحقیقات دیگر فقط از متغیرهای کمی بهره برده‌اند و تأثیر متغیرهای کیفی بر مدل ریسک نقدینگی را بررسی نکرده‌اند. این تحقیق یک رویکرد جدید در مطالعات مطرح نموده است و می‌تواند با تحقیقات قبلی مقایسه شود. البته این مقایسه صرفاً به منظور قیاس است و رویکرد جدید روش پیشنهادی به دلیل ماهیت داده‌ها و نوع متغیرهای پیش‌بینی (گسسته) از منظر اعتبارسنجی با روش‌های دیگر مقایسه نشده است. اعتبارسنجی نتایج و تعمیم‌پذیری آن بر اساس داده‌های آموزش و آزمون انجام شده است. همچنین با استفاده از داده‌های تحقیق، مقایسه‌ای بین نتایج الگوریتم مورد استفاده (CNN) و

الگوریتم‌های کلاسیک دیگر انجام شده است؛ شرایط آزمایش در این مقایسه برای تمامی روش‌ها با داده‌های کاملاً یکسان، محدودیت‌ها و فرضیات مشابه در نظر گرفته شده‌اند. نتایج نشان می‌دهد که روش CNN دقت بالاتری نسبت به هر دو روش دیگر دارد؛ دقت مدل ANN حدود ۸۰٪ و دقت مدل LRC حدود ۷۰٪ است.



شکل ۱۱. مقایسه نتایج حاصل روش‌های مختلف در پیش‌بینی ریسک نقدینگی

۵- نتیجه‌گیری و پیشنهادها

به‌صورت خلاصه، این مطالعه با استفاده از روش علم طراحی تأثیر عوامل کیفی را در مدل پیش‌بینی ریسک نقدینگی بررسی کرده است. نتایج نشان می‌دهد که دقت مدل در مرتبه‌ای قابل قبول تا حدود ۸۶٪ و مورد انتظار در صنعت بانکداری و نظارتی قرار دارد. در این شرایط، بانک‌ها می‌توانند اقدامات مؤثری جهت کاهش یا افزایش ریسک‌های خود بر اساس محدوده ریسک انجام دهند. این در حالی است که تأثیر متغیرهای کمی در مدل پیش‌بینی در نظر گرفته نشده است. افزون بر این، متغیرهای کمی نیز می‌توانند دقت مدل را تا حدودی افزایش دهند. نکته نوآورانه اصلی این مطالعه در استفاده از رویکردها و پارامترهای کیفی به جای محاسبات پیچیده و غیرقابل دسترس نیز بیان می‌شود. علاوه بر این، از نگرش الگوریتمی جدیدی برای تولید نمونه‌های بیشتر استفاده شده که توانایی بهبود آموزش الگوریتم را دارد. از منظر کاربردی نیز روش‌های مورد استفاده به‌خوبی توانسته‌اند نتایج قابل قبولی را در زمینه ریسک نقدینگی ارائه دهند، به طوری که نیاز به استفاده از رویکردهای پیچیده‌تر را کاهش داده‌اند. این مطالعه نشان می‌دهد که رویکرد پژوهش علم طراحی، به‌عنوان چارچوبی برای هر مرحله از پیشبرد مراحل تحقیق عمل کرده و نهایتاً در مرحله پذیرش، تأیید کرده است که نتایج در دنیای واقع

نیز کاربردی خواهند بود. در این شرایط بانک‌ها می‌توانند اقدامات مؤثری جهت کاهش یا افزایش ریسک‌های خود بر اساس محدوده ریسک قرارگرفته صورت دهند.

چرخه روش علم طراحی با توجه به پیش‌بینی‌های انجام‌شده محدوده ریسک نقدینگی بانک در سناریوهای واقعی با دقت بالا حدود ۸۷٪، پایان می‌پذیرد. با این حال در تحقیقات آتی می‌توان این چرخه را به منظور بهبود نتایج مجدداً تکرار نمود.

در این تحقیق، از روش‌های تحلیل سری‌زمانی برای بررسی تأثیر تاریخی ریسک استفاده نشده و به‌جای آن از تأثیر وقایع مشابه در طول دوره آزمایش برای پیش‌بینی ریسک نقدینگی بهره‌برده شده است. از منظر کاربردی، در تحقیقات آتی، می‌توان از رویکردهای یادگیری عمیق بازگشتی^۱ و تحلیل سری‌زمانی که تأثیر زمان را نیز مد نظر دارد، استفاده کرد. همچنین جهت بهبود مدل، از انواع ترانسفورمرها یا مدل‌های زبانی طولانی^۲ نیز می‌توان در تحقیقات آتی بهره برد تا دقت پیش‌بینی را افزایش دهد. از روش پیشنهادی نیز می‌توان در زمینه‌های کاربردی دیگر مانند پیش‌بینی ریسک اعتباری، پیش‌بینی ریسک بازار، پیش‌بینی قیمت سهام، پیش‌بینی قیمت رمز ارزها، و دیگر زمینه‌های بانکی و مالی بهره‌برد.

۶- منابع

- [۱] Bayer, C. (۲۰۱۹). Recent Advancements in Sentiment Analysis in Finance. doi:۱۰,۱۸۴۵۲/۲۰۸۶۶
- [۲] Nopp, C., & Hanbury, A. (۲۰۱۵). Detecting Risks in the Banking System by Sentiment Analysis. In L. Màrquez, C. Callison-Burch, & J. Su (Eds.), Proceedings of the ۲۰۱۵ Conference on Empirical Methods in Natural Language Processing (pp. ۵۹۱-۶۰۰). Lisbon, Portugal: Association for Computational Linguistics. doi:۱۰,۱۸۶۵۳/۷۱/D۱۵-۱۰۷۱
- [۳] A. Hevner, & A. Maedche (Eds.), Design Science Research. Cases. Progress in IS. Springer, Cham. doi:۱۰,۱۰۰۷/۹۷۸-۳-۰۳۰-۴۶۷۸۱-۴_۴
- [۴] Gomes, T., & Khan, N. (۲۰۱۱). Strengthening Bank management of Liquidity Risk: The Basel III Liquidity Standards, Financial System Review, pp. ۳۵-۴۲, ۲۰۱۱
<https://api.semanticscholar.org/CorpusID:۱۴۲۰۷۶۷۰>
- [۵] Tavana, M., Abtahi, A. R., Di Caprio, D., & Poortarigh, M. (۲۰۱۸). An Artificial Neural Network and Bayesian Network model for liquidity risk assessment in banking. Neurocomputing, ۲۷۵, ۲۵۲۵-۲۵۵۴. doi:۱۰,۱۰۱۶/j.neucom.۲۰۱۷,۱۱,۰۳۴
- [۶] Abensur, E., & de Carvalho, W. (۲۰۲۲). Improving Portfolio Selection by Balancing Liquidity-Risk-Return: Evidence from Stock Markets. Theoretical Economics Letters, ۱۲, ۴۷۹-۴۹۷. doi:۱۰,۴۲۳۶/tel.۲۰۲۲,۱۲۲۰۲۷

^۱ Recurrent Neural Network

^۲ Long Language Model

- [۷] Solangi, Y. A., Solangi, Z. A., Aarain, S., Abro, A., Mallah, G. A., & Shah, A. (۲۰۱۸). Review on Natural Language Processing (NLP) and Its Toolkits for Opinion Mining and Sentiment Analysis. In ۲۰۱۸ IEEE ۳۰th International Conference on Engineering Technologies and Applied Sciences (ICETAS) (pp. ۱-۴). doi:۱۰.۱۱۰۹/ICETAS.۲۰۱۸.۸۶۲۹۱۹۸
- [۸] Swankie, G., & Broby, D. (۲۰۱۹). Examining the Impact of Artificial Intelligence on the Evaluation of Banking Risk. *Review of Financial Studies*, ۳۵(۱۰), ۴۴۲۵-۴۴۷۳. doi:۱۰.۲۱۳۹/ssrn.۳۱۱۲۲۱۳
- [۹] Calabrese, R., & Giudici, P. (۲۰۱۵). Estimating bank default with generalised extreme value regression models. *The Journal of the Operational Research Society*, ۶۶(۱۱), ۱۷۸۳-۱۷۹۲. doi:۱۰.۱۰۵۷/jors.۲۰۱۴.۶۱
- [۱۰] Piccolo, A., & Shapiro, J. (۲۰۲۲). Credit Ratings and Market Information. *Review of Financial Studies*, ۳۵(۱۰), ۴۴۲۵-۴۴۷۳. doi:۱۰.۱۰۹۳/rfs/hhab.۰۹۳
- [۱۱] Boguth, O., Carlson, M., Fisher, A., & Simutin, M. (۲۰۱۶). Horizon Effects in Average Returns: The Role of Slow Information Diffusion. *Review of Financial Studies*, ۲۹(۸), ۲۲۴۱-۲۲۸۱. doi:۱۰.۱۰۹۳/rfs/hhw.۰۲۴
- [۱۲] Nam, K., & Seong, N. (۲۰۱۹). Financial news-based stock movement prediction using causality analysis of influence in the Korean stock market. *Decision Support Systems*, ۱۱۷, ۱۰۰-۱۱۲. doi:۱۰.۱۰۱۶/j.dss.۲۰۱۸.۱۱.۰۰۴
- [۱۳] Guerra, P., Castelli, M., & Côte-Real, N. (۲۰۲۲). Machine learning for liquidity risk modelling: A supervisory perspective. *Economic Analysis and Policy*, ۷۴, ۱۷۵-۱۸۷. doi:۱۰.۱۰۱۶/j.eap.۲۰۲۲.۰۲.۰۰۱
- [۱۴] Guerra, P., Castelli, M., & Côte-Real, N. (۲۰۲۲). Machine learning for liquidity risk modeling: A supervisory perspective. *Economic Analysis and Policy*, ۷۴, ۱۷۵-۱۸۷. doi:۱۰.۱۰۱۶/j.eap.۲۰۲۲.۰۲.۰۰۱
- [۱۵] An, C.-H. (۲۰۱۷). A Study on Estimation of Financial Liquidity Risk Prediction Model Using Financial Analysis. *International Journal of Applied Engineering Research*, vol. ۱۲, no. ۲۰, pp. ۹۹۱۹-۹۹۲۳.
- [۱۶] Effiong, D. A., & Enya, E. F. (۲۰۲۰). Liquidity Risk Management and Financial Performance: Are Consumer Goods Companies Involved? *International Journal of Recent Technology and Engineering (IJRTE)*. <https://doi.org/۱۰.۳۵۹۴۰/ijrte.A۱۶۹۲.۰۵۹۱۲۰>
- [۱۷] Arias, J. A. E., Serna, M. A. A., Gómez, J. G. M., Kleine, C., & Arbelaez, L. C. F. (۲۰۱۵). Design of information system for the Liquidity Risk Management in financial institutions. *Iberian Conference on Information Systems and Technologies*. doi:۱۰.۱۱۰۹/cisti.۲۰۱۵.۷۱۷۰۳۶۰
- [۱۷] Montenegro, C., Murillo, M., Gallegos, F., & Albuja, J. (۲۰۱۶). DSR Approach to Assessment and Reduction of Information Security Risk in TELCO. *IEEE Latin America Transactions*, ۱۴(۵), ۲۴۰۲-۲۴۱۰. doi:۱۰.۱۱۰۹/TLA.۲۰۱۶.۷۵۳۰۴۳۸
- [۱۸] Montenegro, C., Murillo, M., Gallegos, F., & Albuja, J. (۲۰۱۶). DSR Approach to Assessment and Reduction of Information Security Risk in TELCO. *IEEE Latin America Transactions*, ۱۴(۵), ۲۴۰۲-۲۴۱۰. doi:۱۰.۱۱۰۹/TLA.۲۰۱۶.۷۵۳۰۴۳۸
- [۱۹] Cedergren, A., & Hassel, H. (۲۰۲۲). Using Action Design Research for Developing and Implementing a Method for Risk Assessment and Continuity Management. *Safety Science*, ۱۵۱, ۱۰۵۷۲۷. doi:۱۰.۱۰۱۶/j.ssci.۲۰۲۲.۱۰۵۷۲۷

- [۲۰] Drudi, M. L., & Nobili, S. (۲۰۲۱). A liquidity risk early warning indicator for Italian banks: a machine learning approach. Bank of Italy, Economic Research and International Relations Area, (۱۳۳۷). doi:۱۰,۲۱۳۹/ssrn.۳۸۹۱۵۶۶
- [۲۱] Hevner, A. R., March, S. T., Park, J., & Ram, S. (۲۰۰۴). Design Science in Information Systems Research. MIS Quarterly, ۲۸(۱), ۷۵-۱۰۵. doi:۱۰,۲۳۰۷/۲۵۱۴۸۶۲۵
- [۲۲] Lanine, G., & Vander Vennet, R. (۲۰۰۶). Failure prediction in the Russian bank sector with logit and trait recognition models. Expert Systems with Applications, ۳۰(۳), ۴۶۳-۴۷۸. doi:۱۰,۱۰۱۶/j.eswa.۲۰۰۵,۱۰,۰۱۴
- [۲۳] Feki, A., Ben Ishak, A., & Feki, S. (۲۰۱۲). Feature selection using Bayesian and multiclass Support Vector Machines approaches: Application to bank risk prediction. Expert Systems with Applications, ۳۹(۳), ۳۰۸۷-۳۰۹۹. doi:۱۰,۱۰۱۶/j.eswa.۲۰۱۱,۰۸,۱۷۲
- [۲۴] LeCun, Y., Bengio, Y., & Hinton, G. (۲۰۱۵). Deep Learning. Nature, ۵۲۱, ۴۳۶-۴۴۴. doi:۱۰,۱۰۳۸/nature۱۴۵۳۹
- [۲۵] Thakkar, A., & Chaudhari, K. (۲۰۲۱). A comprehensive survey on deep neural networks for stock market: The need, challenges, and future directions. Expert Systems with Applications, ۱۷۷, ۱۱۴۸۰۰. doi:۱۰,۱۰۱۶/j.eswa.۲۰۲۱,۱۱۴۸۰۰
- [۲۶] Ferreira, C., Jenkinson, N., & Wilson, C. (۲۰۱۹). From Basel I to Basel III: Sequencing Implementation in Developing Economies. IMF Working Papers, (۱۲۷). doi:۱۰,۵۰۸۹/۹۷۸۱۴۹۸۳۱۵۲۲۷,۰۰۱
- [۲۷] E. B. Authority. (۲۰۲۱). Guidelines on recovery plan indicators under Article ۹ of Directive. European Banking Authority.
- [۲۸] Kahneman, D., & Tversky, A. (۱۹۷۹). Prospect Theory: An Analysis of Decision under Risk. Econometrica, ۴۷(۲), ۲۶۳-۲۹۱. doi:۱۰,۲۳۰۷/۱۹۱۴۱۸۵
- [۲۹] Paraboni, A. L., Righi, M. B., Vieira, K. M., & Silveira, V. G. da. (۲۰۱۸). The relationship between sentiment and risk in financial markets. Brazilian Administration Review, ۱۵(۱), e۱۷۰۰۵۵. <https://doi.org/۱۰,۱۵۹۰/۱۸۰۷-۷۶۹۲bar۲۰۱۸۱۷۰۰۵۵>.
- [۳۰] Lu, W., Li, G., Zhu, X., & Li, J. (۲۰۱۹). Discovering bank risk factors from financial statements based on a new semi-supervised text mining algorithm. Accounting & Finance, ۵۹(۳), ۱۵۱۹-۱۵۵۲. doi:۱۰,۱۱۱۱/acfi.۱۲۴۵۳.
- [۳۱] Huang, J., Roberts, H., & Tan, E. (۲۰۱۸). The Impact of Media Sentiment on Firm Risk, Corporate Investment, and Financial Policies. SSRN Electronic Journal. doi:۱۰,۲۱۳۹/ssrn.۳۰۹۹۳۰۷
- [۳۲] Araci, D. (۲۰۱۹). FinBERT: Financial Sentiment Analysis with Pre-trained Language Models. Retrieved from arXiv:۱۹۰۸,۱۰۰۶۳
- [۳۳] Shao, C., & Chen, X. (۲۰۲۲). Deep-Learning-Based Financial Message Sentiment Classification in Business Management. Computational Intelligence and Neuroscience, ۲۰۲۲. doi:۱۰,۱۱۵۵/۲۰۲۲/۳۸۸۸۶۷۵
- [۳۴] Liu, N., & Zhao, J. (۲۰۲۲). A BERT-Based Aspect-Level Sentiment Analysis Algorithm for Cross-Domain Text. Computational Intelligence and Neuroscience, ۲۰۲۲, ۸۷۲۶۶۲۱. doi:۱۰,۱۱۵۵/۲۰۲۲/۸۷۲۶۶۲۱