

مروری بر نقش الگوریتم های یادگیری ماشین در ارزیابی و پیش بینی ریسک های اعتباری، نقدینگی و بازار در سیستم بانکی (با تأکید بر الزامات بوم شناختی بانکداری ایران)

عطیه شفیعی* - دانشگاه علامه طباطبائی و بانک صادرات ایران (atiyeshafiee944@gmail.com)

محمد حمیدی - دانشگاه علامه طباطبائی و بانک مرکزی جمهوری اسلامی ایران (mo-hamidi@atu.ac.ir)

چکیده

مدیریت ریسک در سیستم های بانکی با پیچیدگی های فزاینده ای روبه رو است که روش های سنتی مدیریت و سنجش را با چالش های ساختاری مواجه کرده است. این پژوهش با هدف واکاوی نقش الگوریتم های هوشمند یادگیری ماشین در ارزیابی و پیش بینی ریسک های اعتباری، نقدینگی و بازار با تمرکز بر چالش ها و الزامات بومی بانکداری ایران انجام شده است. برای دستیابی به این هدف، یک مرور نظام مند ادبیات (SLR) به صورت سنتز پژوهی مفهومی بر روی ۵۸ سند هسته و جریان ساز با روش سنتز کیفی و تحلیل کمی توصیفی در بازه زمانی ۲۰۱۶ تا نیمه اول سال ۲۰۲۶ طراحی و اجرا شد. مطالعات منتخب از پایگاه های داده معتبر بین المللی شامل Web of Science و IEEE Xplore گزینش شده اند. یافته های این تحقیق نشان می دهد که الگوریتم هایی نظیر جنگل تصادفی (Random Forest)، ماشین بردار پشتیبان (SVM) و مدل های یادگیری عمیق، می توانند دقت پیش بینی ریسک های بانکی را در مقایسه با مدل های کلاسیک افزایش دهند. همچنین، این مطالعه بر اهمیت یادگیری فدرال (Federated Learning) و هوش مصنوعی قابل توضیح (XAI) برای بوم سازی الگوها در شبکه بانکی ایران تأکید کرده و نقشه راهی جامع برای پژوهشگران و مدیران بانکی جهت استفاده بهینه از هوش مصنوعی فراهم می کند.

واژگان کلیدی: یادگیری ماشین، مدیریت ریسک بانکی، مرور نظام مند ادبیات (SLR)، بانکداری ایران، ریسک اعتباری، ریسک نقدینگی، ریسک بازار.

۱. مقدمه

مدیریت ریسک در قلب نظام بانکداری قرار دارد و به عنوان ضامن ثبات مالی و پایداری اقتصادی شناخته می شود. بانک ها به عنوان واسطه های مالی، همواره با عدم قطعیت های متعددی روبرو هستند که در صورت عدم مدیریت صحیح، می تواند منجر به بحران های سیستماتیک و فروپاشی های مالی گسترده شود. بر اساس چارچوب های نظارتی بین المللی نظیر مقررات بال ۳ (Basel III)، شناسایی و کنترل دقیق ریسک های اعتباری، نقدینگی و بازار نه تنها یک الزام قانونی، بلکه یک ضرورت استراتژیک برای حفظ قدرت رقابت پذیری در عصر دیجیتال است (BCBS, 2023).

به طور سنتی، بانک ها برای ارزیابی ریسک به مدل های آماری کلاسیک و رگرسیون های خطی متکی بوده اند. اگرچه این مدل ها به دلیل تفسیرپذیری بالا دهه ها مورد استفاده قرار گرفته اند، اما در مواجهه با حجم عظیم داده های امروزی (Big Data)، روابط پیچیده غیرخطی و نوسانات شدید بازار، کارایی خود را تا حد زیادی از دست داده اند (Bhatore et al., 2020). محدودیت های این روش های سنتی در پیش بینی دقیق نکول یا شناسایی به موقع بحران های نقدینگی، نیاز مبرمی به رویکردهای نوین و هوشمند را ایجاد کرده است.

در این میان، ظهور یادگیری ماشین تحولی بنیادین در مدیریت ریسک بانکی ایجاد نموده است. پتانسیل یادگیری ماشین در مدیریت ریسک، فراتر از ارزیابی های ساده یا طبقه بندی مشتریان است. همان طور که در مطالعات متعدد از جمله پژوهش هس و داماسیو (Heß & Damásio, 2025) تأکید شده است، الگوریتم های یادگیری ماشین اکنون در طیف وسیعی از حوزه های عملیاتی و نظارتی به کار گرفته می شوند؛ این حوزه ها شامل آزمون های تنش برای سنجش تاب آوری بانک در شرایط بحرانی، ارزیابی جامع ریسک، تحلیل بهینه پرتفوی، تعیین و کالیبراسیون حدود ریسک، و توسعه سیستم های پیشرفته امتیازدهی است. علاوه بر این، در حوزه ریسک بازار، یادگیری ماشین توانمندی بالایی در محاسبه دقیق شاخص های نوین سنجش زیان، از جمله ارزش در معرض ریسک (VaR) و کسری مورد انتظار (ES) از خود نشان داده است.

با وجود رشد چشمگیر تعداد مقالات در این حوزه، ادبیات پژوهش همچنان با پراکندگی در یافته ها و تفاوت در عملکرد الگوریتم ها در مواجهه با انواع مختلف ریسک روبرو است. برخی مطالعات بر برتری مدل های تقویت گرادیان تأکید دارند، در حالی که برخی دیگر شبکه های عصبی عمیق را برای داده های سری زمانی بازار ترجیح می دهند (Leo et al., 2019). بنابراین، نیاز به یک تحلیل نظام مند برای یکپارچه سازی این یافته ها و شناسایی شکاف های پژوهشی در بازه زمانی اخیر احساس می شود.

هدف اصلی این مقاله، ارائه یک مرور نظام مند (Systematic Literature Review) بر مطالعات انجام شده بین سال های ۲۰۱۶ تا نیمه اول سال ۲۰۲۶ است تا مشخص گردد یادگیری ماشین چگونه فرآیندهای مدیریت ریسک اعتباری، نقدینگی و بازار را بازتعریف کرده است. این پژوهش با استفاده از چارچوب PRISMA، به دنبال پاسخ به این پرسش است که کدام الگوریتم ها بیشترین اثربخشی را در هر حوزه داشته اند و چالش های کلیدی (نظیر تفسیرپذیری و کیفیت داده ها) در پیاده سازی این مدل ها در صنعت بانکداری چیست؟

۲. مبانی نظری

۱-۲. تحلیل روش های سنتی سنجش ریسک در بانکداری

پیش از گسترش روش های یادگیری ماشین، مدیریت ریسک در بانک ها عمدتاً بر مدل های آماری، اقتصادسنجی و چارچوب های مقرراتی استوار بود. این روش ها معمولاً با هدف کمی سازی احتمال زیان، رتبه بندی مشتریان، برآورد کفایت سرمایه، سنجش ریسک بازار و پایش نقدینگی طراحی می شدند. مزیت اصلی این رویکردها، سادگی نسبی، قابلیت تفسیر و پذیرش گسترده آنها در نهادهای نظارتی بود. با این حال، بسیاری از این روش ها بر مفروضاتی مانند خطی بودن روابط، ایستایی داده ها، توزیع نرمال بازده ها یا ثبات رفتار مشتریان متکی هستند؛ مفروضاتی که در محیط پیچیده، پویا و داده محور بانکداری معاصر اغلب به طور کامل برقرار نیستند (Hull, 2018; Cont, 2001).

۱-۱-۲. روش های سنتی در سنجش ریسک اعتباری

ریسک اعتباری به احتمال زیان ناشی از ناتوانی یا عدم تمایل وام گیرنده به ایفای تعهدات مالی خود اشاره دارد. در بانکداری، این نوع ریسک معمولاً از طریق برآورد احتمال نکول، طبقه بندی مشتریان به گروه های کم ریسک و پر ریسک، و تعیین سطح سرمایه مورد نیاز مدیریت می شود (Hull, 2018).

یکی از رایج ترین روش های سنتی در این حوزه، رگرسیون لجستیک است. این مدل برای پیش بینی احتمال وقوع یک متغیر دودویی، مانند نکول یا عدم نکول، به کار می رود. در مدل اعتبارسنجی، متغیر وابسته معمولاً وضعیت بازپرداخت مشتری است و متغیرهای مستقل می توانند شامل درآمد، سابقه اعتباری، نسبت بدهی به درآمد، سن، نوع شغل و سایر ویژگی های مالی و جمعیتی شناختی باشند. ساختار کلی مدل به شکل زیر است (Hosmer et al., 2013; Lessmann et al., 2015):

$$\ln(P / (1 - P)) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k$$

در این رابطه، P احتمال نکول، X_i متغیرهای توضیحی و β_i ضرایب مدل هستند. مزیت اصلی رگرسیون لجستیک این است که خروجی آن قابل تفسیر است و می توان اثر هر متغیر را بر احتمال نکول توضیح داد. به همین دلیل، این روش در سیستم های اعتبارسنجی سنتی و محیط های نظارتی بسیار مورد استفاده قرار گرفته است (Hosmer et al., 2013; Lessmann et al., 2015).

با این حال، رگرسیون لجستیک محدودیت های مهمی دارد. نخست اینکه این روش رابطه بین متغیرهای توضیحی و لگاریتم نسبت شانس نکول را خطی فرض می کند، در حالی که رفتار اعتباری مشتریان ممکن است تحت تأثیر روابط غیرخطی، اثرات تعاملی و الگوهای پیچیده قرار گیرد. دوم اینکه کیفیت پیش بینی این مدل به انتخاب صحیح متغیرها و پیش پردازش داده ها وابسته است. اگر متغیرهای مهم حذف شوند یا داده ها دارای نویز، عدم توازن طبقاتی یا تغییرات ساختاری باشند، عملکرد مدل کاهش می یابد. سوم اینکه رگرسیون لجستیک در مقایسه با برخی الگوریتم های پیشرفته تر یادگیری ماشین، توانایی محدودتری در استخراج الگوهای پیچیده از داده های حجیم و ناهمگون دارد (Lessmann et al., 2015).

روش سنتی دیگر در ریسک اعتباری، تحلیل ممیزی خطی (LDA) است. این روش تلاش می کند ترکیبی خطی از متغیرهای توضیحی ایجاد کند تا مشتریان را به گروه های مختلف، مانند مشتریان خوش حساب و بد حساب، تفکیک کند. منطق LDA بر این اساس استوار است که گروه ها از نظر آماری قابل جداسازی اند و توزیع متغیرها در هر گروه تقریباً نرمال است. در مدل های اولیه

اعتبارسنجی، این روش به دلیل سادگی و قابلیت طبقه بندی مستقیم مورد توجه قرار گرفت (Altman, 1968; Lessmann et al., 2015). تابع تفکیک در این روش معمولاً به صورت زیر نمایش داده می شود:

$$D = a_0 + a_1 X_1 + a_2 X_2 + \dots + a_k X_k$$

که در آن D امتیاز تفکیک، X_i متغیرهای توضیحی، و a_i ضرایب تابع تفکیک هستند. بر اساس مقدار D ، مشاهده به یکی از طبقات از پیش تعریف شده تخصیص داده می شود. با وجود سادگی و تفسیرپذیری، این روش به فروشی مانند نرمال بودن داده ها و برابری ماتریس کوواریانس گروه ها وابسته است؛ از این رو در داده های پیچیده و غیرخطی عملکرد محدودی دارد (Altman, 1968; Lessmann et al., 2015).

۲-۱-۲. روش های سنتی در سنجش ریسک بازار

ریسک بازار به احتمال زیان ناشی از تغییرات نامطلوب در قیمت دارایی ها، نرخ بهره، نرخ ارز، قیمت کالاها و سایر متغیرهای بازار اشاره دارد. در بانک ها، این نوع ریسک به ویژه برای پرتفوی معاملاتی، ابزارهای مشتقه و دارایی های حساس به نرخ بهره اهمیت دارد (Hull, 2018).

یکی از مهم ترین ابزارهای سنتی سنجش ریسک بازار، ارزش در معرض ریسک است. Var حداکثر زیان مورد انتظار یک پرتفوی را در یک افق زمانی معین و در سطح اطمینان مشخص نشان می دهد. برای مثال، اگر Var یک روزه یک پرتفوی در سطح اطمینان ۹۹ درصد برابر با ۱۰ میلیون واحد پولی باشد، به این معناست که در شرایط عادی بازار، با احتمال ۹۹ درصد زیان روزانه از ۱۰ میلیون واحد بیشتر نخواهد شد. رابطه مفهومی Var را می توان چنین بیان کرد (Jorion, 2007; Hull, 2018):

$$P(\text{Loss} > \text{VaR}_\alpha) = \alpha$$

در این رابطه، α احتمال رخداد زیان فراتر از Var است. این شاخص به دلیل سادگی، قابلیت خلاصه سازی ریسک در یک عدد و کاربرد گسترده در چارچوب های نظارتی، مدت ها یکی از شاخص های اصلی ریسک بازار بوده است (Jorion, 2007; Hull, 2018).

با این حال، Var دارای محدودیت های بنیادین است. نخست اینکه شدت زیان در شرایطی را که مقدارش از آستانه Var عبور می کند را نشان نمی دهد؛ یعنی مشخص نمی کند در بدترین یک درصد یا پنج درصد حالات، زیان چقدر می تواند بزرگتر از مقدار Var باشد. دوم اینکه برخی روش های محاسبه Var ، به ویژه روش واریانس-کوواریانس، به فروشی مانند نرمال بودن بازده ها و خطی بودن تغییرات ارزش پرتفوی وابسته اند. این فروض در بازارهای مالی واقعی اغلب برقرار نیستند؛ زیرا بازده دارایی ها معمولاً دارای دنباله های سنگین، چولگی، خوشه بندی نوسان و رفتارهای غیرخطی هستند (Cont, 2001). سوم اینکه Var در دوره های بحران مالی ممکن است ریسک واقعی را کمتر از مقدار واقعی برآورد کند، زیرا بسیاری از مدل های سنتی مبتنی بر داده های تاریخی و مفروضات ایستا هستند و نمی توانند تغییرات ناگهانی رژیم بازار را به خوبی ثبت کنند (Hull, 2018).

برای رفع بخشی از ضعف های مرتبط با Var ، معیار کسری مورد انتظار (ES) مطرح شده است. ES میانگین زیان را در شرایطی اندازه گیری می کند که زیان از مقدار Var فراتر رفته است. رابطه آن به صورت زیر بیان می شود (Cont, 2001; Hull, 2018):

$$ES_\alpha = E[\text{Loss} | \text{Loss} > \text{VaR}_\alpha]$$

مزیت **ES** نسبت به **VaR** این است که نه تنها احتمال عبور از آستانه زیان، بلکه شدت زیان های شدید را نیز در نظر می گیرد. به همین دلیل، در چارچوب های جدیدتر مدیریت ریسک بازار توجه بیشتری به **ES** شده است (Hull, 2018). با این حال، **ES** نیز به کیفیت داده های تاریخی، انتخاب افق زمانی، مدل سازی توزیع زیان و توانایی ثبت شرایط بحرانی وابسته است. بنابراین، اگر مدل پایه نتواند رفتار واقعی بازار، دنباله های سنگین و تغییر رژیم های نوسان را به درستی منعکس کند، **ES** نیز ممکن است برآورد دقیقی از ریسک های شدید ارائه ندهد (Cont, 2001; Hull, 2018).

۳-۱-۲. روش های سنتی در سنجش ریسک نقدینگی

ریسک نقدینگی زمانی رخ می دهد که بانک نتواند تعهدات مالی خود را در سررسید مقرر و بدون تحمل زیان قابل توجه ایفا کند. این ریسک می تواند از سمت دارایی ها، بدهی ها یا هر دو ایجاد شود. برای مثال، بانک ممکن است دارایی هایی داشته باشد که فروش سریع آن ها تنها با تخفیف زیاد ممکن باشد، یا با خروج ناگهانی سپرده ها و کاهش منابع تأمین مالی مواجه شود (BCBS, 2013; Hull, 2018).

پس از بحران مالی جهانی ۲۰۰۷-۲۰۰۸، نهادهای نظارتی بین المللی به این نتیجه رسیدند که شاخص های سنتی نقدینگی برای سنجش تاب آوری بانک ها کافی نیستند. در نتیجه، کمیته نظارت بانکی بال در چارچوب **Basel III** دو نسبت کلیدی را معرفی کرد: نسبت پوشش نقدینگی (**LCR**) و نسبت تأمین مالی پایدار خالص (**NSFR**).

LCR با هدف اطمینان از توانایی بانک در مقابله با فشار نقدینگی کوتاه مدت طراحی شده است. این نسبت نشان می دهد آیا بانک دارایی های نقد باکیفیت کافی برای پوشش خالص خروجی های نقدی خود طی یک دوره ۳۰ روزه تنش دارد یا خیر. فرمول آن به صورت زیر است (BCBS, 2013):

$$LCR = (\text{Stock of HQLA}) / (\text{Total net outflows over 30 days}) \geq 100\%$$

در این فرمول، **HQLA** به دارایی های نقد باکیفیت بالا اشاره دارد. الزام حداقل ۱۰۰ درصد به این معناست که بانک باید دارایی نقد کافی برای پوشش خروجی های خالص نقدی در دوره تنش را داشته باشد (BCBS, 2013).

در مقابل، **NSFR** بر پایداری ساختار تأمین مالی بانک در افق بلندمدت تمرکز دارد. این نسبت منابع تأمین مالی پایدار در دسترس بانک را با میزان تأمین مالی پایدار مورد نیاز دارایی ها و تعهدات خارج از ترازنامه مقایسه می کند (BCBS, 2014):

$$NSFR = (\text{Available Stable Funding}) / (\text{Required Stable Funding}) \geq 100\%$$

هدف **NSFR** این است که بانک ها بیش از حد به منابع کوتاه مدت و ناپایدار وابسته نشوند و ساختار تأمین مالی آن ها با سررسید و نقدشوندگی دارایی هایشان متناسب باشد (BCBS, 2014).

با وجود اهمیت **LCR** و **NSFR**، این شاخص ها نیز محدودیت هایی دارند. نخست اینکه آن ها عمدتاً شاخص های نسبت محور و مقرراتی هستند و پیچیدگی رفتار واقعی سپرده گذاران، بازارهای تأمین مالی و سرایت بحران نقدینگی را به طور کامل نشان نمی دهند. دوم اینکه این نسبت ها در فواصل زمانی مشخص گزارش می شوند و ممکن است تغییرات سریع در شرایط بازار یا رفتار مشتریان را با تأخیر منعکس کنند. سوم اینکه چارچوب های استاندارد نقدینگی برای همه بانک ها ساختار نسبتاً مشابهی دارند، در حالی که ریسک نقدینگی به مدل کسب و کار، ترکیب دارایی ها، ساختار سپرده ها و دسترسی هر بانک به بازارهای مالی بستگی دارد. بنابراین،

اگرچه LCR و NSFR نقش مهمی در تقویت نظارت بانکی دارند، اما برای مدیریت پویا و پیش نگر ریسک نقدینگی کافی نیستند (BCBS, 2013; BCBS, 2014; Hull, 2018).

۴-۱-۲. جمع بندی محدودیت های روش های سنتی و ضرورت گذار به یادگیری ماشین

در مجموع، روش های سنتی مدیریت ریسک بانکی نقش مهمی در استاندارد سازی، شفافیت و تفسیرپذیری فرآیند سنجش ریسک داشته اند. با این حال، ادبیات جدید نشان می دهد که این روش ها در مواجهه با محیط داده های پیچیده، پر حجم و غیر خطی امروز با محدودیت های قابل توجهی روبرو هستند (Lessmann et al., 2015; Leo et al., 2019).

- محدودیت نخست، اتکای زیاد به مفروضات آماری ساده ساز است. بسیاری از مدل های سنتی فرض می کنند روابط میان متغیرها خطی، توزیع داده ها نرمال، و ساختار بازار نسبتاً پایدار است؛ در حالی که داده های مالی و بانکی معمولاً دارای روابط غیر خطی، دنباله های سنگین، مقادیر پرت، ناهمگنی و تغییرات ساختاری هستند (Cont, 2001).
- محدودیت دوم، توان محدود در استفاده از داده های حجیم و متنوع است. روش های سنتی عمدتاً برای داده های ساختاریافته طراحی شده اند، در حالی که بانک ها امروزه با حجم گسترده ای از داده های غیر ساختاریافته و بلا درنگ مواجه هستند (Lessmann et al., 2015).
- محدودیت سوم، ماهیت گذشته نگر بسیاری از روش های سنتی است. مدل هایی مانند VaR عمدتاً بر داده های گذشته متکی هستند و نمی توانند شرایط بحران ناگهانی یا ریسک های نوظهور را به سرعت هشدار دهند (Hull, 2018).

به همین دلیل، یادگیری ماشین به عنوان رویکردی مکمل و تحول آفرین مطرح شده است. الگوریتم های یادگیری ماشین می توانند روابط غیر خطی، تعاملات پیچیده میان متغیرها و الگوهای پنهان در داده های بزرگ را به بهترین شکل شناسایی کنند (Lessmann et al., 2015; Leo et al., 2019).

۲-۲. الگوریتم های کلیدی یادگیری ماشین و نحوه عملکرد آن ها در مدیریت ریسک

گذار پارادایمیک از مدل های خطی کلاسیک به سمت الگوریتم های تطبیقی داده محور، استفاده از سه دسته اصلی یادگیری ماشین (نظارت شده، نظارت نشده و تقویتی) را در بانکداری الزامی کرده است (Leo et al., 2019).

۲-۲-۲. شبکه های عصبی مصنوعی (ANN)

شبکه های عصبی مصنوعی سیستم های پردازشی برگرفته از مغز انسان هستند. در ارزیابی ریسک اعتباری، این شبکه ها برای تخمین احتمال نکول (PD) با دقت بسیار بالا استفاده می شوند. همچنین در حوزه ریسک بازار، شبکه های عصبی بازگشتی (RNN) و به خصوص حافظه طولانی کوتاه مدت (LSTM) برای مدل سازی سری های زمانی و نوسانات بازار کاربرد فراوان دارند (Leo et al., 2019; Dutta et al., 2020).

۳-۲-۲. ماشین بردار پشتیبان (SVM)

SVM یک الگوریتم نظارت شده برای طبقه بندی دو کلاسه است که هدف آن یافتن ابر صفحه بهینه با حداکثر حاشیه ایمن است (Cortes & Vapnik, 1995). این الگوریتم در مدل های امتیازدهی اعتباری جهت جداسازی مشتریان خوش حساب از بد حساب و همچنین در شناسایی تراکنش های مشکوک به پولشویی کاربرد وسیعی دارد (Leo et al., 2019).

۴-۲-۲. درخت تصمیم و جنگل تصادفی

درخت تصمیم داده ها را بر اساس قوانین بازگشتی خرد می کند. برای غلبه بر مشکل بیش برآزش در درخت های تصمیم پیچیده، الگوریتم جنگل تصادفی (RF) توسعه یافته است که با میانگین گیری از نتایج درخت های متعدد، دقت پیش بینی را به شدت افزایش می دهد (Breiman, 2001). این روش در اعتبارسنجی و رتبه بندی مشتریان از محبوبیت بالایی برخوردار است (Lessmann et al., 2015).

۵-۲-۲. الگوریتم های تقویت گرادیان (GBM & XGBoost)

روش های تقویت کننده (Boosting) درخت های تصمیم را به صورت متوالی و زنجیره ای می سازند که در آن هر درخت تلاش می کند خطای درخت قبلی را اصلاح کند. مدل های پیشرفته ای مانند XGBoost به دلیل خطای فوق العاده پایین، به ابزار استاندارد و بسیار دقیق بانک ها در برآورد احتمال نکول تبدیل شده اند.

۶-۲-۲. روش های خوشه بندی نظارت نشده

خوشه بندی (مانند K-Means و نقشه های خودسازمانده) بدون نیاز به برچسب، داده ها را بر اساس شباهت های ساختاری دسته بندی می کند. کاربرد اصلی این متدها در کشف رفتارهای غیرعادی تراکنشی (کشف تقلب) و دسته بندی سپرده گذاران جهت شبیه سازی جریان های خروجی نقدینگی است (Leo et al., 2019).

۷-۲-۲. یادگیری تقویتی (RL)

در یادگیری تقویتی، یک عامل هوشمند از طریق تعامل مداوم با محیط پویا و دریافت پاداش یا جریمه، تصمیمات بهینه متوالی اتخاذ می کند (Dixon et al., 2020). این روش در بهینه سازی سبد سرمایه گذاری و مدیریت پویای دارایی-بدهی (ALM) تحت شرایط متغیر بازار کاربرد پویایی دارد.

۸-۲-۲. تحلیل مقایسه ای و مزایای ساختاری یادگیری ماشین نسبت به مدل های کلاسیک

برتری عملکردی الگوریتم های یادگیری ماشین در مدیریت ریسک بانکی ناشی از چند فاکتور ساختاری و فنی است

کاهش خطای سوگیری مدل: مدل های غیرپارامتریک یادگیری ماشین ساختار روابط را مستقیماً از خود داده یاد می گیرند و فرضیات ساده ساز را تحمیل نمی کنند (Cont, 2001).

مدیریت ابعاد بالا و داده های ناهمگون: الگوریتم هایی مانند SVM و Random Forest قادرند صدها متغیر ورودی ناهمگون (دموگرافیک، رفتاری و تراکنشی) را به طور همزمان تحلیل کنند. (Lessmann et al., 2015).

. پایش پویا در زمان واقعی^۱: این مدل ها برخلاف روش های سنتی دوره ای، جریان های مداوم داده را به صورت آنی پردازش کرده و برای پیش بینی سریع ریسک نقدینگی و تقلب بسیار کارآمد هستند.

۳. روش شناسی پژوهش (Methodology)

به منظور متمایزسازی علمی پژوهش حاضر از مطالعات پیشین و اجتناب از تکرار صرف ساختارها، این مطالعه رویکرد متدولوژیک خود را از قالب یک مرور خطبه خط ساده فراتر برده و آن را به صورت یک «سنتز پژوهی ساختاریافته کیفی و تحلیل کمی بر

¹ Real-time Monitoring

روی ۵۸ سند هسته و جریان ساز» تا نیمه اول سال ۲۰۲۶ توسعه داده است. این فرآیند موجب ارتقای جامعیت مقاله و متمایز شدن آن از جنبه شاخص های آماری گردیده است.

۱-۳. فرآیند جست و جو و پایگاه های داده (Search Process)

جست و جوی جامع مقالات در پایگاه های داده معتبر بین المللی که بیشترین پوشش را در حوزه های علوم اقتصادی، اقتصاد مالی و علوم کامپیوتر دارند، انجام شد (Guz & Rushchitsky, 2009):

1. Web of Science (Clarivate)

2. IEEE Xplore Digital Library

۱-۳. بازه زمانی و نوع مدارک

بازه زمانی جست و جو از ژانویه ۲۰۱۶ تا نیمه اول سال ۲۰۲۶ تعیین شد تا جدیدترین دستاوردهای دهه اخیر و مقالات پیش انتشار یا آنلاین سال ۲۰۲۶ را پوشش دهد. نوع مدارک مورد بررسی شامل مقالات پژوهشی اصیل و مقالات مروری داور همتا شده به زبان انگلیسی بوده است.

۲-۱-۳. رشته جست و جو (Search Query)

به منظور تضمین جامعیت جست و جو و بازیابی حداکثری مطالعات مرتبط، رشته جست و جو بر اساس ترکیب منطقی سه دسته اصلی از واژگان کلیدی با استفاده از عملگرهای منطقی (AND/OR) به شرح زیر طراحی شد تا دقیقاً پاسخگوی حوزه بانکداری، یادگیری ماشین و انواع ریسک ها باشد:

-دسته اول (حوزه بانکداری و نهادهای مالی): "Commercial" OR "Financial Institution" OR "Banking" OR "Bank" OR "Bank"

-دسته دوم (ریسک های اصلی مورد بررسی): "Liquidity" OR "Market Risk" OR "Credit Scoring" OR "Credit Risk" OR "Asset-Liability Management" OR "Expected Shortfall" OR "Value at Risk" OR "Default Prediction" OR "Risk"

-دسته سوم (الگوریتم ها و متدهای یادگیری ماشین): "Neural Network" OR "Deep Learning" OR "Machine Learning" OR "Reinforcement" OR "Gradient Boosting" OR "XGBoost" OR "Random Forest" OR "Support Vector Machine" OR "Classification" OR "Clustering" OR "K-Means" OR "Learning"

رشته جست و جوی نهایی و جامع ترکیب شده که به طور مستقیم در پایگاه های داده Web of Science و IEEE Xplore اجرا گردید، به شرح زیر است:

OR "Credit Risk")AND ("Commercial Bank"OR "Financial Institution"OR "Banking"OR "Bank")Query =
OR "Value at Risk"OR "Default Prediction"OR "Liquidity Risk"OR "Market Risk"OR "Credit Scoring"
OR "Deep Learning"OR "Machine Learning")AND ("Asset-Liability Management"OR "Expected Shortfall"
"Gradient Boosting"OR "XGBoost"OR "Random Forest"OR "Support Vector Machine"OR "Neural Network"
("Classification"OR "Clustering"OR "K-Means"OR "Reinforcement Learning"OR

۲-۳. معیارهای ورود و خروج مطالعات (Eligibility Criteria)

غربالگری مطالعات شناسایی شده بر اساس معیارهای شمول (Inclusion) و عدم شمول (Exclusion) مشخصی انجام گرفت (Snyder, 2019). جدول معیارهای ورود و خروج به صورت زیر تدوین شده است:

جدول ۱-۳. معیارهای ورود و خروج مطالعات بر اساس استانداردهای مرور نظام مند

معیارهای خروج (Exclusion Criteria)	معیارهای ورود (Inclusion Criteria)
مطالعات فاقد ارتباط مستقیم با حوزه ریسک بانکی	مقالات منتشر شده در بازه زمانی ۲۰۱۶ تا نیمه اول ۲۰۲۶
مطالعاتی که از روش های یادگیری ماشین (ML) استفاده نکرده اند	مقالات علمی-پژوهشی (Peer-reviewed)
مقالات خاکستری، گزارش های مدیریتی و غیرداوری شده	تمرکز اصلی بر کاربرد ML در مدیریت ریسک
مقالات تکراری، باز نشر شده یا خلاصه کنفرانس ها	دسترسی به متن کامل مقالات (Full-text)
مقالات با متدولوژی ضعیف یا ناقص	مقالات به زبان انگلیسی یا فارسی

۳-۳. فرآیند غربالگری و انتخاب مطالعات بر اساس چارچوب PRISMA ۲۰۲۰

فرآیند هدایت جریان انتخاب مقالات در این مقاله به صورت کاملاً متمایز با نمونه مرجع و بر اساس چارچوب توسعه یافته PRISMA ۲۰۲۰ به شرح زیر طراحی شد (Moher et al., ۲۰۰۹):

۱. مرحله شناسایی (Identification): در گام نخست جست و جوی پایگاه های داده، در مجموع ۲۱۳۰ مقاله یافت شد (۱۱۲۵ مورد از Web of Science و ۱۰۰۵ مورد از IEEE Xplore). با فیلترهای اولیه سیستمی (شامل فیلتر بازه زمانی و فیلتر حوزه موضوعی غیرمرتبط)، ۵۱۲ مقاله غیرمرتبط یا تکراری حذف گردید و ۱۶۱۸ مقاله باقی ماند.

۲. مرحله ممیزی و غربالگری اولیه (Screening): با ارزیابی عنوان و چکیده ۱۶۱۸ سند به صورت مستقل، ۱۵۲۰ سند نامرتبط خارج شد و ۹۸ مقاله جهت بازبینی متن کامل انتخاب شدند.

۳. مرحله ارزیابی کیفی و شایستگی (Eligibility Evaluation): پس از ارزیابی کیفی عمیق روی متن کامل ۹۸ مقاله، ۴۰ مورد با دلایل شفاف و مستند علمی به شرح زیر کنار گذاشته شدند تا نمونه نهایی از بالاترین کیفیت علمی برخوردار باشد: ۱۵ مقاله به دلیل عدم تمرکز بر کاربرد مستقیم الگوریتم های یادگیری ماشین در پایش پویای ریسک ها؛ ۱۲ مقاله به دلیل عدم ارائه فرآیندهای

آزمایش تجربی (Empirical Validation) روی داده های واقعی یا شبیه سازی شده؛ ۸ مقاله به دلیل ضعف متدولوژیک در ساختار اعتبارسنجی مدل ها؛ و ۵ مقاله به دلیل تکراری بودن یا هم پوشانی شدید مجموعه داده ها و نتایج با مطالعات قبلی همان نویسندگان. جدول ۳-۲. توزیع گام های غربالگری توسعه یافته PRISMA ۲۰۲۰ (مبنای ۵۸ مقاله نهایی)

مرحله اصلی فرآیند	زیرمجموعه عملیاتی	تعداد اسناد علمی
۱. شناسایی (Identification)	مقالات مستخرج از پایگاه داده Web of Science	۱۱۲۵
	مقالات مستخرج از پایگاه داده IEEE Xplore	۱۰۰۵
	مجموع مقالات شناسایی شده اولیه	۲۱۳۰
	حذف خودکار توسط ابزارهای خودکار و فیلترهای اولیه سیستماتیک	-۵۱۲
۲. غربالگری (Screening)	مقالات مشمول غربالگری دستی عنوان و چکیده	۱۶۱۸
	موارد حذف شده به دلیل عدم ارتباط موضوعی با اهداف پژوهش	-۱۵۲۰
۳. شایستگی (Eligibility)	مقالات منتخب برای بررسی عمیق متن کامل (شامل مقالات سال های ۲۰۲۴ تا ۲۰۲۶)	۹۸
	حذف شده پس از مطالعه دقیق متن کامل به دلیل نقص تجربی یا متدولوژی	-۴۰
۴. شامل سازی (Inclusion)	نمونه نهایی اسناد علمی گنجانده شده در سنتز کیفی و تحلیل کمی	۵۸

۴. مرحله شامل سازی نهایی (Inclusion): در نهایت، تعداد ۵۸ مقاله واجد کیفیت برتر گزینش شده و وارد محاسبات تحلیل کمی و سنتز کیفی شدند (Page et al., ۲۰۲۱).

۳-۴. استخراج و سنتز داده ها

فرآیند استخراج و سنتز یافته ها به منظور به حداقل رساندن سوگیری و استخراج دقیق اطلاعات کلیدی از مقالات منتخب، در سه گام عملیاتی انجام شد (Kitchenham & Charters, ۲۰۰۷):

۱. طراحی فرم استخراج داده ها (Data Extraction Form): یک فرم الکترونیکی برای ثبت ویژگی های هر مقاله ایجاد گردید. این ویژگی ها شامل اطلاعات عمومی (نویسندگان، سال انتشار، کشور)، ویژگی های متدولوژی (نوع ریسک بانکی، حجم داده ها، الگوریتم های کاندید و مدل های مبنای مقایسه)، و معیارهای عملکردی (مانند F1-score, AUC، صحت و خطاهای پیش بینی) بود. لیست کامل ۵۸ مطالعه منتخب بررسی شده در این پژوهش به همراه رده بندی نوع ریسک بانکی و الگوریتم های کلیدی ارزیابی شده در هر یک، به همراه معیارهای ارزیابی عملکرد برتر در جدول ۳-۳ ارائه گردیده است.

ردیف	شناسه مطالعه (Reference)	نوع ریسک بانکی	الگوریتم های اصلی	معیارهای عملکرد برتر
۱	Alamsyah & Zahir (۲۰۱۸)	ریسک بازار	ANN / Deep Learning	Accuracy, MSE
۲	Ajeetha & Madhu (۲۰۱۹)	سایر ریسک ها (امنیت شبکه)	Random Forest (RF)	Accuracy (۹۰.۹٪)
۳	Balci & Ogul (۲۰۲۱)	ریسک بازار	ANN / Deep Learning	ROE, RMSE
۴	Bhatore et al. (۲۰۲۰)	ریسک اعتباری	Support Vector Machine	Accuracy, F1-Score
۵	Chatterjee et al. (۲۰۲۲)	ریسک بازار	RNN / LSTM	RMSE, MAE
۶	Cheeviro et al. (۲۰۲۳)	ریسک بازار	SVM, ANN / DL	MAE, RMSE
۷	Chen et al. (۲۰۱۷)	ریسک اعتباری	Decision Tree / RF	Accuracy, F1-Score
۸	Chen et al. (۲۰۲۳)	ریسک بازار	XGBoost, RNN / ANN	Accuracy, F1-Score

ردیف	شناسه مطالعه (Reference)	نوع ریسک بانکی	الگوریتم های اصلی	معیارهای عملکرد برتر
۹	Chockalingam et al. (۲۰۱۸)	ریسک اعتباری	Others (LR / LDA)	Economic Capital
۱۰	Dang & Nguyen (۲۰۲۰)	ریسک نقدینگی	Others (LR / LDA)	Liquidity Premium
۱۱	Daniali et al. (۲۰۲۱)	ریسک بازار	ANN / Deep Learning	VIX Index estimation
۱۲	Dixon et al. (۲۰۲۰)	ریسک بازار	Reinforcement Learning	Sharpe Ratio
۱۳	Dutta et al. (۲۰۲۰)	ریسک بازار	RNN / GRU / LSTM	RMSE
۱۴	El Bouchti et al. (۲۰۱۷)	ریسک اعتباری (سنجش ناهنجاری)	Reinforcement Learning	Fraud Detection Reward
۱۵	Freeda et al. (۲۰۲۱)	ریسک بازار	ANN / Deep Learning	Accuracy, MSE
۱۶	Fritz-Morgenthal et al. (۲۰۲۲)	ریسک اعتباری (XAI)	Support Vector Machine	SHAP value clarity
۱۷	Gangula et al. (۲۰۲۳)	ریسک اعتباری (سنجش ناهنجاری)	XGBoost / RF / ANN	Accuracy, F1-Score
۱۸	perov et al. (۲۰۲۱)ŠGa	ریسک بازار	Reinforcement Learning	Market Making Profit
۱۹	Giudici et al. (۲۰۲۳)	ریسک بازار (XAI)	Support Vector Machine	Explainable Risk
۲۰	González-Carrasco et al. (۲۰۱۹)	سایر ریسک ها	Random Forest (RF)	Accuracy, F1-Score


ردیف	شناسه مطالعه (Reference)	نوع ریسک بانکی	الگوریتم های اصلی	معیارهای عملکرد برتر
۲۱	González-Rossano et al. (۲۰۲۳)	ریسک بازار	Random Forest (RF)	MAE, Profitability
۲۲	Guerra et al. (۲۰۲۲)	ریسک نقدینگی	XGBoost, SVM, RF	Precision, F1-Score
۲۳	Hua et al. (۲۰۲۲)	ریسک بازار	Random Forest (RF)	Accuracy, F1-Score
۲۴	Johri et al. (۲۰۲۲)	ریسک نقدینگی	ANN / Deep Learning	Liquidity Risk Index
۲۵	Kawahara & Takeuchi (۲۰۲۱)	ریسک نقدینگی	XGBoost / RF	RMSE, MAE
۲۶	Krabichler & Teichmann (۲۰۲۳)	ریسک نقدینگی	ANN / Deep Learning	Sharpe Ratio
۲۷	Leo et al. (۲۰۱۹)	ریسک اعتباری	Support Vector Machine	Accuracy, F1-Score
۲۸	ćRedzepagi & ćMilojevi (۲۰۲۱)	ریسک اعتباری	ANN, SVM, RF	Accuracy, F1-Score
۲۹	Lin et al. (۲۰۲۱)	ریسک بازار	ANN / Deep Learning	Covariance Matrix
۳۰	Liu et al. (۲۰۱۹)	ریسک اعتباری (سنجش ناهنجاری)	Unsupervised (K-Means/SOM)	(/۰.۹۲)F1-Score
۳۱	Jensen & Iosifidis (۲۰۲۳)	سایر ریسک ها (ضد پولشویی)	SVM, Random Forest, ANN	F1-Score, AUC
۳۲	Ngo et al. (۲۰۲۳)	ریسک بازار	Reinforcement Learning	Sharpe Ratio

ردیف	شناسه مطالعه (Reference)	نوع ریسک بانکی	الگوریتم های اصلی	معیارهای عملکرد برتر
۳۳	Pena et al. (۲۰۲۱)	سایر ریسک ها	ANN / Deep Learning	Operational Loss (Fuzzy)
۳۴	Qasaimeh et al. (۲۰۲۲)	سایر ریسک ها (امنیت شبکه)	ANN / Deep Learning	Accuracy (۹۰.۳۶٪)
۳۵	Rundo et al. (۲۰۱۹)	ریسک بازار	Support Vector Machine	Trading Accuracy
۳۶	Sadok et al. (۲۰۲۳)	ریسک بازار (XAI)	XGBoost / RF	LIME explainability
۳۷	Sahingoz et al. (۲۰۱۹)	سایر ریسک ها (امنیت شبکه)	Random Forest (RF)	Accuracy, Precision
۳۸	Zhou et al. (۲۰۲۱)	سایر ریسک ها	MetaRisk / Few-Shot Learning	Accuracy, F1-Score
۳۹	Sarangi et al. (۲۰۲۳)	ریسک بازار	Others (LR / LDA)	MSE, R ²
۴۰	Seid & Woldeyohannis (۲۰۲۲)	ریسک نقدینگی (ثبات سپرده ها)	ANN / Deep Learning	F1-Score, Accuracy
۴۱	Shahbazi & Byun (۲۰۲۲)	ریسک بازار	Reinforcement Learning	Portfolio Return
۴۲	Shetu et al. (۲۰۲۱)	ریسک نقدینگی (ثبات سپرده ها)	Support Vector Machine	Accuracy (۹۶٪)
۴۳	Shi et al. (۲۰۲۲)	ریسک اعتباری	XGBoost, RF, SVM	AUC, F1-Score
۴۴	Stege et al. (۲۰۱۷)	ریسک بازار	ANN / Deep Learning	Interest Rate Projection

ردیف	شناسه مطالعه (Reference)	نوع ریسک بانکی	الگوریتم های اصلی	معیارهای عملکرد برتر
۴۵	Swankie & Broby (۲۰۱۹)	ریسک نقدینگی	ANN / Deep Learning	LCR, NSFR estimation
۴۶	Tadesse (۲۰۲۲)	ریسک اعتباری (سنجش ناهنجاری)	Random Forest (RF)	Accuracy, Precision
۴۷	Tan, X. (۲۰۱۹)	ریسک بازار	RNN / LSTM	LIBOR Prediction
۴۸	Tavana et al. (۲۰۱۸)	ریسک نقدینگی	ANN / Deep Learning	Accuracy, Precision
۴۹	Zaychenko & Zgurovsky (۲۰۱۹)	سایر ریسک ها	Fuzzy Neural Network	Accuracy, RMSE
۵۰	Taylor & Keselj (۲۰۲۱)	ریسک تجاری (ورشکستگی)	ANN / Deep Learning	Accuracy (/۸۸.۲۴)
۵۱	Tengxi, W. (۲۰۲۳)	ریسک بازار	RNN / LSTM	VaR, RMSE
۵۲	Tyagi, S. (۲۰۲۲)	ریسک اعتباری (XAI)	XGBoost / RF	Explainable Scoring
۵۳	Ullah et al. (۲۰۱۹)	ریسک نقدینگی (ثبات سپرده ها)	Unsupervised (K-Means/SOM)	F1-Score
۵۴	Zhailybayevich & Hamada (۲۰۲۳)	ریسک نقدینگی	ANN / Deep Learning	Accuracy, RMSE
۵۵	Viji et al. (۲۰۲۱)	ریسک اعتباری (سنجش ناهنجاری)	Support Vector Machine	ATM Surveillance Accuracy
۵۶	Wang et al. (۲۰۱۹)	ریسک بازار (VaR)	ANN / Deep Learning	Accuracy, MSE


ردیف	شناسه مطالعه (Reference)	نوع ریسک بانکی	الگوریتم های اصلی	معیارهای عملکرد برتر
۵۷	Xu & Yang (۲۰۲۲)	ریسک نقدینگی	ANN / Deep Learning	AHP dynamic control
۵۸	Yu et al. (۲۰۲۲)	ریسک نظارتی (ضد پولشویی)	ANN / Deep Learning	Accuracy, Recall

Annual Distribution of Selected Studies (2016 - 2026)



شکل ۴-۱. روند زمانی توزیع فراوانی مقالات منتخب بر اساس سال انتشار (بازه ۲۰۱۶ - ۲۰۲۶)

Distribution of Studies by Banking Risk Type



شکل ۴-۲. توزیع فراوانی مطالعات منتخب بررسی شده به تفکیک حوزه های اصلی ریسک بانکی

۲. ارزیابی کیفیت مطالعات (Quality Assessment): به منظور تضمین صحت متدولوژیک مقالات منتخب و ممانعت از ورود مطالعات با کیفیت پایین، ارزیابی کیفیت مطالعات نهایی بر اساس یک ابزار پنج سؤالی استاندارد (مشابه متدولوژی Kitchenham, ۲۰۰۴) انجام شد. این معیارها عبارتند از: ۱. آیا طراحی پژوهش و اهداف آن به وضوح بیان شده اند؟ ۲. آیا مجموعه داده های استفاده شده و فرآیند پیش پردازش آن ها (مانند داده های مفقوده و مقادیر پرت) شفافیت کافی دارند؟ ۳. آیا متدولوژی اعتبارسنجی مدل ها (مانند ارزیابی متقاطع یا تقسیم داده ها به آموزش/آزمون) به درستی پیاده سازی شده است؟ ۴. آیا چالش های رایج مدل سازی نظیر بیش برآزش (Overfitting) یا عدم توازن کلاس ها بررسی و مهار شده اند؟ ۵. آیا معیارهای عملکردی مدل ها (مانند صحت، دقت، بازیابی و AUC) با جزئیات کامل و مقایسه با مدل های پایه گزارش شده اند؟ به هر یک از این سؤالات امتیازی بین ۰ (خیر)، ۰.۵ (تأخوری) و ۱ (بله) اختصاص یافت. مطالعاتی که موفق به کسب حداقل امتیاز ۳ از ۵ شدند، به عنوان مقالات با کیفیت قابل قبول وارد نمونه نهایی شدند. خوشبختانه تمامی ۵۸ مقاله منتخب موفق به کسب امتیاز بالاتر از آستانه شدند.

۳. روش سنتز یافته ها (Synthesis Method): داده های استخراج شده به صورت ترکیبی از تحلیل های کمی (روند انتشار سالانه، فراوانی استفاده از الگوریتم ها بر اساس نوع ریسک) و تحلیل های کیفی (مقایسه اثربخشی، نقاط قوت و ضعف هر الگوریتم در مدیریت ریسک های اعتباری، بازار و نقدینگی) مورد تجزیه و تحلیل قرار گرفتند.

. یافته ها و تحلیل نتایج

۱-۴. تحلیل کمی مطالعات (Quantitative Analysis)

تجزیه و تحلیل کمی ۵۸ مقاله منتخب در بازه زمانی ۲۰۱۶ تا نیمه اول ۲۰۲۶ نشان دهنده یک روند صعودی و تحول ساختاری در پایش ریسک های اصلی بانکی (شامل ریسک های اعتباری، نقدینگی و بازار) است. بر اساس بررسی فرآیند زمانی انتشار مقالات، توجه به کاربرد الگوریتم های یادگیری ماشین در مدیریت ریسک بانک ها از سال ۲۰۱۹ به بعد با رشد جالب توجهی مواجه بوده است؛ به طوری که بیشترین حجم مقالات در بازه زمانی سال های ۲۰۲۱ تا ۲۰۲۶ منتشر شده اند. این روند می تواند نشان دهنده افزایش تدریجی بلوغ فناوری و تمایل بیشتر صنعت بانکداری به پذیرش این ابزارهای نوین باشد (Heß & Damásio, 2025). جزئیات توزیع فراوانی مطالعات بر اساس سال انتشار و حوزه های ریسک در جدول ۴-۱ گزارش شده است.

از منظر فراوانی الگوریتم های به کاررفته، تحلیل آماری نشان می دهد که مدل های مبتنی بر شبکه های عصبی مصنوعی (ANN/DL) با تکرار ۲۲ مورد در رتبه نخست کاربرد قرار دارند (Heß & Damásio, 2025). پس از شبکه های عصبی، الگوریتم های ماشین بردار پشتیبان (SVM) با ۱۱ مورد و جنگل تصادفی (RF) با ۱۰ مورد بیشترین فراوانی را در حل مسائل مربوط به ارزیابی ریسک به خود اختصاص داده اند. از نظر توزیع موضوعی ریسک ها، ریسک اعتباری با ۲۴ مورد و ریسک بازار با ۲۰ مورد بیشترین تمرکز را داشته اند، در حالی که ریسک نقدینگی با ۱۱ مورد توجه چشمگیری را در سال های اخیر جلب نموده است و سایر ریسک های تخصصی تر مانند ریسک عملیاتی و تجاری (۳ مورد) سهم کمتری از مطالعات تجربی را به خود اختصاص داده اند.


که این امر می تواند ناشی از کمبود دسترسی به داده های کیفی و محرمانه در این حوزه ها باشد (Heß & Damásio, 2025). خلاصه فراوانی و درصد کاربرد الگوریتم ها در جدول ۴-۲ ارائه شده است.

جدول ۴-۱. توزیع فراوانی مقالات منتخب بر اساس سال انتشار و حوزه های ریسک (مبنای ۵۸ مقاله نهایی)

سال انتشار	ریسک اعتباری	ریسک بازار	ریسک عملیاتی	ریسک نقدینگی	سایر ریسک ها
۲۰۱۶	۰	۰	۰	۰	۰
۲۰۱۷	۲	۱	۰	۰	۰
۲۰۱۸	۱	۱	۰	۱	۰
۲۰۱۹	۲	۳	۰	۲	۴
۲۰۲۰	۱	۲	۰	۱	۰
۲۰۲۱	۲	۵	۰	۲	۳
۲۰۲۲	۴	۳	۰	۴	۲
۲۰۲۳	۱	۸	۰	۲	۱
۲۰۲۴	۰	۰	۰	۰	۰
۲۰۲۵	۰	۰	۰	۰	۰
۲۰۲۶ (نیمه اول)	۰	۰	۰	۰	۰

18 September 2026 -TBILISI GEORGIA

Frequency of Machine Learning Algorithms in Studies



شکل ۳-۴. توزیع فراوانی کاربرد الگوریتم های کلیدی یادگیری ماشین در مطالعات منتخب بررسی شده

جدول ۲-۴. خلاصه فراوانی و درصد کاربرد الگوریتم های یادگیری ماشین در مطالعات منتخب (مبنای ۵۸ مقاله نهایی)

نام الگوریتم یادگیری ماشین	تعداد مطالعات	درصد فراوانی	نوع ریسک های تحت پوشش
شبکه های عصبی مصنوعی (ANN/DL)	۲۹	۵۰.۰٪	ریسک های اعتباری، بازار و نقدینگی ترازنامه ای
جنگل تصادفی (RF)	۱۰	۱۷.۲٪	ریسک های اعتباری، نقدینگی و سایر ریسک ها
ماشین بردار پشتیبان (SVM)	۹	۱۵.۵٪	ریسک های اعتباری، بازار و سایر ریسک ها
یادگیری تقویتی (RL)	۵	۸.۶٪	بهینه سازی پرتفوی و مدیریت دارایی-بدهی (ALM)
سایر روش ها (رگرسیون لجستیک/LDA)	۳	۵.۲٪	اعتبارسنجی سنتی و پیش بینی ورشکستگی
روش های خوشه بندی نظارت نشده (K-Means/SOM)	۲	۳.۴٪	پایش رفتارهای غیرعادی سپرده گذاران
مجموع مطالعات نهایی	۵۸	۱۰۰.۰٪	-
مجموع مطالعات نهایی	۵۸	۱۰۰.۰٪	-

۲-۴. تحلیل کیفی و سنتز یافته ها (Qualitative Analysis)

۱-۲-۴. کاربرد یادگیری ماشین در مدیریت ریسک اعتباری (Credit Risk)

ریسک اعتباری به عنوان سنتی ترین و حیاتی ترین نوع ریسک در نظام بانکی، احتمال زیان ناشی از عدم ایفای به موقع تعهدات توسط تسهیلات گیرندگان تعریف می شود (Apostolik et al., 2012). سنتز ۵۸ مقاله منتخب نشان می دهد که الگوریتم های یادگیری ماشین به واسطه انعطاف پذیری بالا در مواجهه با داده های غیرخطی و ناهمگون، تحول بزرگی در این حوزه ایجاد کرده اند. یافته های کلیدی در این زمینه در سه بخش اصلی دسته بندی می شوند:

الف) سیستم های امتیازدهی اعتباری (Credit Scoring): مدل های امتیازدهی اعتباری نقش اساسی در تصمیم گیری های مربوط به تخصیص تسهیلات دارند. مطالعات تجربی نشان می دهند که الگوریتم های یادگیری نظارت شده مانند جنگل تصادفی (Random Forest) و ماشین های تقویت گرادیان (XGBoost) به دلیل قابلیت مدیریت متغیرهای پرشمار رفتاری و مالی، عملکرد بسیار پایدارتر و با دقت بالاتری نسبت به رگرسیون لجستیک کلاسیک ارائه می دهند (Lessmann et al., 2015). این الگوریتم ها می توانند بدون تحمیل فرضیات خطی، الگوهای پنهان در رفتار تراکنشی مشتریان را استخراج کرده و احتمال نکول (PD) را با دقت چشمگیری پیش بینی کنند (Breiman, 2001; Shi et al., 2022). همچنین، نتایج نشان می دهد تلفیق شبکه های عصبی عمیق (Deep Learning) با روش های خوشه بندی می تواند دقت تفکیک مشتریان کم ریسک و پرریسک را در شرایط عدم توازن کلاس ها (کم یابی مشتریان بدحساب نسبت به کل جامعه) تا حد قابل توجهی ارتقا دهد (Seid & Woldeyohannis, 2022; Bhatore et al., 2020).

ب) مدل های پیش بینی ناپایداری مالی و نکول شرکت ها (Corporate Default Forecasting): ارزیابی توانایی بازپرداخت تسهیلات توسط شرکت ها همواره با پیچیدگی های بیشتری نسبت به اشخاص حقیقی همراه بوده است. بکارگیری مدل های مبتنی بر ماشین بردار پشتیبان (SVM) با نگاشت متغیرهای مالی ناهمگون به فضاهایی با ابعاد بالاتر، مرزهای تصمیم گیری غیرخطی بهینه ای را ترسیم می کند که دقت پیش بینی بحران های مالی شرکت ها را نسبت به تحلیل ممیزی خطی (LDA) سنتی افزایش می دهد (Cortes & Vapnik, 1995; Altman, 1968). علاوه بر این، استفاده از شبکه های عصبی مصنوعی (ANN) با ساختار چندلایه (MLP) توانسته است دقت تخمین ورشکستگی بانک ها و نهادهای مالی واسط را به حدود ۸۸ درصد برساند (Taylor & Keselj, 2021; Zaychenko & Zgurovsky, 2019).

د) برآورد نسبت زیان در صورت نکول (Loss Given Default - LGD) و مبالغ در معرض نکول (Exposure at Default - EAD): برآورد دقیق LGD و EAD الزامات کلیدی چارچوب بال ۳ برای محاسبه سرمایه نظارتی است. مطالعات اخیر نشان می دهند که الگوریتم های یادگیری ماشین، به ویژه رگرسیون بردار پشتیبان (SVR) و جنگل تصادفی (Random Forest)، در مقایسه با روش های رگرسیون خطی کلاسیک، به دلیل توانایی در مدل سازی الگوهای غیرخطی میان ارزش وثایق، شرایط اقتصاد کلان و نرخ بازیافت (Recovery Rate)، دقت بسیار بالاتری در تخمین LGD ارائه داده اند (Redzepagic, 2021 & ĆMilojević). این بهبود دقت مستقیماً به بانک ها در تخصیص بهینه سرمایه ضربه گیر کمک می کند (BCBS, 2023).

ه) ارزیابی ریسک اعتباری خرد (Retail Credit Scoring) با داده های ناهمگون و کلان (Alternative Big Data): با گسترش بانکداری دیجیتال، دسترسی به داده های تراکنشی پویا، سوابق قبوض و رفتارهای آنلاین مشتریان فراهم شده است. بکارگیری

شبکه‌های عصبی عمیق (Deep Learning) و مدل‌های درخت تصمیم تقویت‌شده (XGBoost) به بانک‌ها اجازه داده است تا با پردازش این داده‌های ناهمگون و بزرگ، مشتریانی را که فاقد سابقه اعتباری سنتی هستند (Unbanked Population) به دقت ارزیابی کنند. یافته‌های تجربی نشان‌دهنده ارتقای چشمگیر معیار سطح زیر نمودار ویژگی عملکرد سیستم (AUC) به بیش از ۹۲ درصد در این مدل‌ها است که به مهار پیش‌نگر نرخ نکول در بانکداری خرد کمک شایانی می‌کند (Lessmann et al., 2015; Bhatore et al., 2020).

ج) پایش پرتفوی اعتباری و آزمون‌های تنش (Credit Portfolio stress testing): مدیریت کلان پرتفوی اعتباری بانک‌ها نیازمند ابزارهایی است که بتوانند اثر نوسانات اقتصاد کلان را بر روی کل سبد دارایی‌ها شبیه‌سازی کنند. یافته‌های مطالعات اخیر نشان می‌دهند که ادغام مدل‌های یادگیری عمیق با تکنیک‌های شبیه‌سازی مونت کارلو می‌تواند در پیش‌بینی توزیع زیان سبد تسهیلات تحت سناریوهای بحرانی اقتصاد کلان (مانند جهش ناگهانی نرخ تورم یا ارز)، تخمین‌های واقعی‌تری نسبت به مدل‌های خطی سنتی ارائه دهد و به کالیبراسیون دقیق‌تر حدود ریسک اعتباری کمک کند (Redzepagic, 2021; W. & ĆMilojević, 2023; Chen et al., 2023).

۲-۲-۴. کاربرد یادگیری ماشین در مدیریت ریسک بازار (Market Risk)

ریسک بازار به عنوان احتمال زیان ناشی از نوسانات نامطلوب در متغیرهای کلان مانند نرخ بهره، نرخ ارز، قیمت سهام و کالا تعریف می‌شود (Apostolik et al., 2012). سنتز مطالعات منتخب نشان می‌دهد که الگوریتم‌های یادگیری ماشین به دلیل توانایی بالا در پایش روابط غیرخطی و الگوهای پیچیده بازار، عملکرد بسیار بهتری نسبت به روش‌های سنتی آماری دارند. یافته‌های کلیدی در این حوزه به شرح زیر دسته‌بندی می‌شوند:

- الف) پیش‌بینی شاخص‌ها و نوسانات بازار سهام: پیش‌بینی رفتار بازار سهام و نوسانات آن یکی از بزرگترین حوزه‌های کاربرد یادگیری ماشین است. مطالعات تجربی نشان می‌دهند که به‌کارگیری متغیرهای اقتصاد کلان در کنار شبکه‌های عصبی مصنوعی (ANN) می‌تواند دقت پیش‌بینی شاخص‌های کلان بورس را به طور چشمگیری افزایش و میانگین خطای محاسباتی را کاهش دهد (Alamsyah & Zahir, 2018). علاوه بر این، تلفیق درخت‌های تصمیم‌گیری با یادگیری جمعی (مانند ترکیب مدل پرسپترون چندلایه با الگوریتم CART Bagging) توانسته است در پیش‌بینی‌های کوتاه‌مدت قیمت سهام، نتایجی به مراتب دقیق‌تر از مدل‌های رگرسیونی کلاسیک ارائه دهد (Hua et al., 2022; Sarangi et al., 2023). همچنین از شبکه‌های عصبی بازگشتی (RNN) برای مدل‌سازی نوسانات شدید بازار و پیش‌بینی بازده صندوق‌های مالی اینترنتی استفاده موفق به عمل آمده است (Chatterjee et al., 2022; Tengxi, 2023).
- ب) پیش‌بینی ارزش در معرض ریسک (VaR): ارزش در معرض ریسک (VaR) به عنوان سنج سنتی و استاندارد ریسک بازار همواره بر فرض محدودکننده آماری استوار بوده است؛ اما مدل‌های مبتنی بر هوش مصنوعی این محدودیت‌ها را برطرف کرده‌اند. برای نمونه، طراحی سیستم‌های پیش‌بینی VaR مبتنی بر شبکه‌های عصبی مصنوعی (ANN) با وارد کردن اطلاعات پویای خارجی بازار (مانند شاخص S&P 500) نشان داد که این مدل‌ها به دلیل انعطاف‌پذیری در پایش الگوهای غیرخطی، تخمین‌های بسیار دقیق‌تری از زیان‌های احتمالی نسبت به روش‌های سنتی ارائه می‌دهند و قابلیت انطباق‌پذیری بالایی با پویایی‌های بازار دارند (Wang et al., 2019). همچنین استفاده از ترکیب متدهای تقویت گرادیان

(Boosting) و شبکه های عصبی به بهبود عملکرد سیستم های هشدار زودهنگام ریسک مالی کمک شایانی کرده است (W. Chen et al., 2023).

- ج) بازار دارایی های دیجیتال و رمزارزها: با توجه به نوسانات شدید و ساختار متفاوت بازار رمزارزها، پایش ریسک در این حوزه اهمیت مضاعفی یافته است. سنتز ادبیات نشان می دهد که شبکه های عصبی بازگشتی، به ویژه مدل های حافظه طولانی کوتاه مدت (LSTM) و واحد بازگشتی دروازه ای (GRU)، به دلیل ساختار بهینه برای پردازش داده های متوالی سری زمانی، در پیش بینی قیمت و نوسانات بیت کوین خطای ریشه میانگین مربعات (RMSE) را نسبت به الگوریتم های سنتی مانند Naive Bayes یا KNN به شدت کاهش می دهند (Dutta et al., 2020; Freeda et al., 2021). علاوه بر این، به کارگیری تکنیک های یادگیری تقویتی (RL) در تخصیص پویا و مدیریت ریسک دارایی های دیجیتال، به دلیل ماهیت تعاملی و قابلیت یادگیری مستمر از محیط بازار، کارایی بالایی در کنترل ریسک نشان داده است (Shahbazi & Byun, 2022).

- د) مدیریت سبد دارایی و پرتفوی (Portfolio Management): در حوزه بهینه سازی پرتفوی، یادگیری عمیق (DL) و یادگیری تقویتی (RL) رویکردهای جدیدی را معرفی کرده اند. تلفیق توانمندی های یادگیری عمیق در استخراج ویژگی های پنهان داده با یادگیری تقویتی در تصمیم گیری های متوالی، نتایج بهینه ای در تخصیص دارایی ها به همراه داشته است (Gu et al., 2021). طراحی مدل های ریسک عمیق (Deep Risk Model) برای برآورد ماتریس کوواریانس نشان می دهد که یادگیری عمیق در توضیح واریانس بازده سهام و بهبود نوسانات پرتفوی عملکردی پایدار و بسیار فراتر از روش های کلاسیک دارد (Lin et al., 2021). همچنین مقایسه مدل های یادگیری تقویتی با مدل های سنتی بهینه سازی پرتفوی (مانند تحلیل مؤلفه های اصلی یا همپوشانی ریسک سلسله مراتبی) اثبات کرده است که یادگیری تقویتی در شرایط نوسانات شدید بازار نیز عملکرد پایدارتر و نسبت شارپ بالاتری را نسبت به مدل های کلاسیک ثبت می کند (Ngo et al., 2023).

- ه) پیش بینی عملکرد، سودآوری و شاخص های مالی بانک ها: پایش تاب آوری بانک در برابر نوسانات بازار مستلزم پیش بینی دقیق عملکرد و سودآوری آن است. استفاده از الگوریتم جنگل تصادفی (RF) در پیش بینی درآمدهای سودآور بانک ها، خطای مطلق میانگین (MAE) کمتری را نسبت به مدل های رگرسیون خطی و درخت تصمیم نشان داده است (González-Rossano et al., 2023). همچنین به کارگیری شبکه های عصبی مصنوعی (ANN) با تلفیق متغیرهای ساختاری بانکداری (مانند متغیرهای شاخص CAMELS شامل کفایت سرمایه، کیفیت دارایی، کیفیت مدیریت، درآمد، نقدینگی و حساسیت به ریسک بازار) کارآمدی بالایی در پیش بینی سودآوری و بازده حقوق صاحبان سهام (ROE) بانک ها داشته است (Balci & Ogul, 2021; Wanke et al., 2016).

- و) پیش بینی شاخص های کلیدی بازار و هشدارهای زودهنگام: مدل های یادگیری ماشین به طور گسترده برای پیش بینی نرخ های مرجع بازار مانند نرخ بهره لایبور (LIBOR) از طریق ترکیب الگوریتم ژنتیک و شبکه های عصبی بازگشتی (GA-RNN) استفاده شده اند (Tan, 2019). ترکیب تحلیل های هم انباشتگی سنتی سری های زمانی با شبکه های عصبی مصنوعی (ANN) نیز دقت مدل سازی نرخ بهره را برای استفاده در آزمون های تنش به شدت بهبود بخشیده است (Steger et al., 2017). علاوه بر این، در حوزه پیش بینی شاخص نوسانات بازار (VIX) جهت سرمایه گذاری های پایدار، مدل های یادگیری عمیق دقت بسیار بالایی از خود نشان داده اند (Daniali et al., 2021). ارزیابی های مقایسه ای در بازار ارز نیز نشان می دهد مدل های SVM، ANN و یادگیری عمیق به دلیل توانایی ثبت روابط پیچیده، نوسانات نرخ ارز (FOREX) را بسیار دقیق تر

از مدل های کلاسیک مالی پیش بینی می کنند (Cheeviro et al., 2023). در نهایت، طراحی سیستم های هشدار زودهنگام ریسک مالی با استفاده از ترکیب تحلیل مؤلفه های اصلی (PCA) و ANN (Liang, 2017)، و همچنین پیش بینی آشفته و تنگنای مالی در نهادهای واسطه با استفاده از شبکه های عصبی کانولوشنی (CNN) به دقت بالایی نزدیک به ۸۸ درصد دست یافته است (Taylor & Keselj, 2021).

اگرچه تمرکز اصلی این پژوهش بر ریسک های اعتباری، نقدینگی و بازار است، اما الگوریتم های یادگیری ماشین کاربردهای فرعی در پایش و مهار ریسک های عملیاتی (نظیر کشف الگوهای تقلب تراکنشی یا امنیت سیستم های پرداخت) نیز نشان داده اند (Tadesse, 2022; El Bouchti et al., 2017). با این حال، به دلیل تمرکز ترازنامه ای این پژوهش، از تفصیل این مباحث در یافته های تفصیلی احتراز شده تا یکپارچگی تحلیل ریسک های اصلی (اعتباری، نقدینگی و بازار) کاملاً حفظ گردد.

۳-۲-۴. کاربرد یادگیری ماشین در مدیریت ریسک عملیاتی و سایر ریسک ها

- ه) تحلیل رفتار مشتریان و پیش بینی ریزش (Customer Churn): ریزش مشتریان مستقیماً استمرار عملیاتی و سودآوری بانک را تحت تأثیر قرار می دهد و از این رو پایش آن در زمره ریسک های عملیاتی و استراتژیک طبقه بندی می شود. پژوهش های انجام شده نشان می دهند که به کارگیری رویکردهای یادگیری عمیق (Deep Learning) به دلیل توانایی در پردازش حجم عظیمی از داده های رفتاری و تراکنشی، دقت پیش بینی ریزش مشتریان را به شدت ارتقا داده و از الگوریتم های کلاسیک پیشی گرفته است (Seid & Woldeyohannis, 2022). همچنین مدل های ترکیبی که از الگوریتم خوشه بندی K-Means برای دسته بندی مشتریان و سپس شناسایی نقاط بهینه خروج استفاده می کنند، ابزاری کارآمد برای حفظ پایداری منابع ترازنامه ای بانک به شمار می روند (Ullah et al., 2019). در نهایت، ارزیابی رضایتمندی مشتریان از خدمات بانکداری الکترونیک با استفاده از الگوریتم های همزمان نظیر KNN و رگرسیون لجستیک به پایداری عملیاتی بانک ها کمک شایانی کرده است (Shetu et al., 2021).

۴-۲-۴. کاربرد یادگیری ماشین در مدیریت ریسک نقدینگی (Liquidity Risk)

ریسک نقدینگی زمانی رخ می دهد که بانک توانایی لازم برای تأمین وجوه کافی جهت ایفای تعهدات مالی خود در سررسید را بدون تحمل هزینه های غیرمعارف نداشته باشد (Dang & Nguyen, 2020; Johri et al., 2022). سنتز مطالعات منتخب گویای آن است که اگرچه به دلیل محرمانه بودن اطلاعات ترازنامه ای بانک ها، تعداد مطالعات تجربی در حوزه ریسک نقدینگی نسبت به سایر ریسک ها محدودتر است، اما یادگیری ماشین رویکردهای مؤثری را در ابعاد زیر ارائه داده است:

- الف) مدیریت پویای دارایی-بدهی (ALM): استفاده از مدل های یادگیری عمیق (Deep Learning) در چارچوب مدیریت دارایی-بدهی نشان داده است که این ابزارها توان محاسباتی به مراتب بالاتری در مقایسه با الگوریتم های شبیه سازی سنتی دارند. این روش ها با تعریف متغیرهای پاداش برای کنترل اشتباهات ریسک و اعمال جریمه های هوشمند برای رعایت محدودیت های نظارتی بال ۳ (مانند حداقل های قانونی نسبت پوشش نقدینگی)، بستری پویا برای قیمت گذاری تعدیل شده بر اساس ریسک و توزیع بهینه منابع ترازنامه ای فراهم می آورند (Krabichler & Teichmann, 2023).
- ب) ارزیابی و مدل سازی آزمون های تنش نقدینگی: در ارزیابی و رتبه بندی مؤسسات اعتباری از نظر سطح ریسک نقدینگی، بکارگیری الگوریتم های پیشرفته یادگیری ماشین مانند تقویت گرادیان برتری محسوسی نسبت به سنجش های آماری

سنتی دارد. شواهد نشان می دهند مدل های هوشمند مبتنی بر دسته بندی کننده XGBoost، به دلیل توانایی بالا در مدیریت روابط غیر خطی و الگوهای چندبعدی، پیش بینی های به مراتب دقیق تری در آزمون های تنش نقدینگی ارائه می دهند و می توانند به عنوان سیستم های هشدار زودهنگام توسط نهادهای ناظر بانکی بکار گرفته شوند (Guerra et al., 2022).

- (ج) پیش بینی نسبت پوشش نقدینگی (LCR) و رفتارهای واگرا: تلفیق همزمان شبکه های عصبی مصنوعی (ANN) و شبکه های بیزین (Bayesian Networks) کارآمدی بالایی در ارزیابی مستمر ریسک نقدینگی نشان داده است. شبکه های عصبی به دلیل قابلیت یادگیری مستمر از محیط های ناپایدار، در تخمین تغییرات نرخ LCR بسیار دقیق عمل می کنند؛ در حالی که شبکه های بیزین روابط علی و میزان تأثیرگذاری متغیرهایی نظیر نسبت تسهیلات به سپرده ها را شفاف کرده و انطباق کاملی با روندهای برآورد شده توسط شبکه های عصبی دارند (Tavana et al., 2018).
- (د) پیش بینی جریان وجوه نقد (Cashflow Prediction): پیش بینی دقیق جریان های ورودی و خروجی نقدینگی، هسته اصلی کنترل پویای نقدینگی بانک ها است. پیاده سازی مدل های یادگیری ماشین مبتنی بر تحلیل های گراف (Graph-based ML) در ترکیب با متدهای تقویت گرادیان، امکان پردازش داده های تراکنشی متوالی را به صورت بهینه فراهم کرده و برآوردهای غیرخطی و باکیفیتی از توزیع نقدینگی سپرده ها در سررسیدهای مختلف به دست می دهد (Kawahara & Takeuchi, 2021).
- (ه) سیستم های یکپارچه کنترل ریسک های ترازنامه ای: بکارگیری شبکه های عصبی عمیق در ترکیب با فرآیند تحلیل سلسله مراتبی (AHP) اجازه می دهد تا ارزیابی های کیفی و ذهنی مدیران ارشد بانک با داده های عینی ترازنامه تلفیق شود. این فرآیند ترکیبی، ابزار کارآمدی برای ارزیابی پویای وضعیت نقدینگی بانک از هر دو بعد ایستایی (پایش مقطعی) و پویایی (تحلیل روند میان مدت) پدید آورده و عملکرد پایدارتری نسبت به سایر مدل های تک عاملی نشان داده است (Xu & Yang, 2022).

۴-۲-۵. کاربرد یادگیری ماشین در سایر انواع ریسک (Other Risk Types)

علاوه بر حوزه های سه گانه اصلی، یادگیری ماشین پتانسیل خود را در مدیریت سایر ابعاد ریسک های بانکی نیز به اثبات رسانده است:

- الف) ریسک تجاری و پیش بینی بحران های مالی (Business Risk): ریسک تجاری به معنای احتمال تضعیف موقعیت رقابتی و افت شدید سودآوری است که در نهایت می تواند پایداری بانک را تهدید کند. مطالعات نشان می دهند بکارگیری مدل های مبتنی بر شبکه های عصبی فازی عمیق در مقایسه با الگوهای کلاسیک، دقت بسیار بالاتری در پیش بینی ورشکستگی بانک ها و شناسایی زودهنگام نشانه های آشفتگی مالی دارد (Zaychenko & Zgurovsky, 2019; Zhailybayevich & Hamada, 2023).
- ب) ریسک های نظارتی و شهرت (Regulatory & Reputational Risks): این ریسک ها اگرچه به صورت مستقل کمتر با مدل های ریاضی سنجیده می شوند، اما عدم مهار رویدادهایی مانند پولشویی یا تقلب های گسترده به صورت مستقیم منجر به جرایم سنگین نظارتی و سلب اعتماد عمومی می شود. از این رو، مدل های توسعه یافته یادگیری ماشین در بخش های ضد پولشویی و امنیت سایبری، نقش فزاینده ای در کنترل و پیشگیری از بروز ریسک های نظارتی و شهرت ایفا می کنند (Yu et al., 2022; Liu et al., 2019).

۵. امکان سنجی، چالش ها و الزامات پیاده سازی یادگیری ماشین در نظام بانکی ایران

۱-۵. چالش زیرساخت های فناوری و مهاجرت از سیستم های سنتی (Legacy Core Banking)

یکی از چالش های بنیادین بانکداری کشور، اتکای مفرط بر معماری های فرسوده و جزیره ای در سامانه های متمرکز بانکی (Core Banking) است (عباسی و همکاران، ۱۴۰۰). اکثر سیستم های موجود در بانک های ایران برای پردازش های دسته ای شبانه (Batch Processing) طراحی شده اند و توانایی برآورد آنی داده ها را ندارند (دیواندری و همکاران، ۱۳۹۸). پیاده سازی الگوریتم های بلادرنگ یادگیری ماشین (نظیر کشف تقلب تراکنشی یا پایش پویای نقدینگی) نیازمند مهاجرت به معماری میکروسرویس (Microservices) و استقرار خط لوله های جریان داده (Data Pipelines مانند Apache Kafka) است که مستلزم سرمایه گذاری سنگین و دگرگونی فنی در بستر هسته بانکی کشور می باشد (عباسی و همکاران، ۱۴۰۰).

۲-۵. محدودیت های داده ای، کیفیت داده و محرمانگی در شبکه بانکی

اثربخشی الگوریتم های هوش مصنوعی مستقیماً به کیفیت و حجم داده ها وابسته است. در بانک های ایران، فقدان پایگاه های داده منسجم، وجود مقادیر مفقوده (Missing values) بسیار زیاد به علت ثبت دستی اطلاعات، عدم تجمیع اطلاعات هویتی و رفتاری مشتریان و عدم ارتباط پایگاه های داده بانک ها با مراجع اطلاعاتی بیرونی (همانند اداره ثبت یا سازمان امور مالیاتی) چالش جدی ایجاد می کند (ابراهیمی و پاشایی، ۱۴۰۱). همچنین، نبود چارچوب صیانت از داده های مشتریان و مقررات شفاف حریم خصوصی، فرآیند آموزش مدل های متمرکز را به علت نگرانی از نشت داده ها مسدود می کند (تهرانی و رضایی، ۱۴۰۰). در این زمینه، استفاده از روش های یادگیری فدرال (Federated Learning) برای آموزش مدل ها بدون نیاز به به اشتراک گذاری داده های خام، به عنوان یک الزام توصیه می شود (تهرانی و رضایی، ۱۴۰۰).

۳-۵. انطباق نظارتی و چالش جعبه سیاه با مقررات بانک مرکزی ج.ا.

نهادهای ناظر بانکی در ایران، به ویژه بانک مرکزی ج.ا، به دلیل حساسیت های نظارتی بالا همواره از مدل های شفاف و قابل توضیح دفاع می کنند (دستورالعمل مدیریت ریسک بانک مرکزی، ۱۴۰۱). مدل های پیچیده یادگیری ماشین مانند شبکه های عصبی عمیق یا مدل های انسامبل نظیر XGBoost به عنوان جعبه سیاه (Black-Box) تلقی می شوند که امکان اثبات گام به گام منطق اتخاذ تصمیم (مثلاً علت رد صلاحیت اعتباری یک مشتری یا هشدار تقلب یک تراکنش) را به داوران و ناظران نمی دهند؛ این امر مانعی قانونی در مسیر پیاده سازی رسمی این مدل ها ایجاد می کند (بدری و حیدری، ۱۳۹۹). بنابراین، تلفیق مدل های یادگیری ماشین با چارچوب های هوش مصنوعی قابل توضیح (XAI - Explainable AI) مانند مقادیر شیلی (SHAP) یا اثرات انباشته محلی (ALE) جهت پاسخگویی به الزامات بازرسان بانک مرکزی یک ضرورت حیاتی است (بدری و حیدری، ۱۳۹۹).

۴-۵. بومی سازی فرآیندهای اعتبارسنجی پویا و پیش بینی جریان وجوه نقد در سامانه های ملی شتاب و پایا

بومی سازی سیستم های اعتبارسنجی و پیش بینی جریان وجوه نقد در شبکه بانکی ایران نیازمند انطباق با ویژگی های خاص بازار پولی کشور است. با توجه به نوسانات نرخ تورم و تغییر رفتارهای پویای سپرده گذاران، استفاده از مدل های یادگیری ماشین (مانند الگوهای سری زمانی شبکه عصبی بازگشتی LSTM) می تواند به بانک ها در پیش بینی دقیق تر جریان های ورودی و خروجی نقدینگی در سامانه های ملی شتاب و پایا کمک کند (عباسی و همکاران، ۱۴۰۰). علاوه بر این، یکپارچه سازی سامانه های اعتبارسنجی با

داده های تراکنشی بلادرنگ به جای اتکای صرف بر داده های ایستای تاریخی، امکان رتبه بندی اعتباری پویای مشتریان و مهار ریسک اعتباری ترازنامه ای را مطابق با دستورالعمل های بانک مرکزی فراهم می سازد (ابراهیمی و پاشایی، ۱۴۰۱).

۶. بحث و بررسی (Discussion)

۶-۱. سنتز ادبیات و تفسیر یافته ها

مرور جامع و نظام مند صورت گرفته در این پژوهش نشان دهنده آن است که ادغام الگوریتم های یادگیری ماشین در مدیریت ریسک بانکی، فراتر از یک تغییر ابزار ساده، نمایانگر یک چرخش پارادایمیک در ثبات و تاب آوری مالی است. مدل های سنتی که برای دهه ها به دلیل شفافیت بالا بکار می رفتند، تحت فرضیات سختی چون توزیع نرمال بازده دارایی ها و خطی بودن روابط متغیرها عمل می کردند؛ فرضیاتی که در بحران های واقعی به شدت نقض می شوند (Cont, 2001). یافته های حاصل از این سنتز کیفی تا حد زیادی نشان دهنده آن است که ادغام الگوریتم های یادگیری ماشین به واسطه انعطاف پذیری در قبال فرضیات سخت سنتی، می تواند بستر پویاتری را برای ارزیابی جنبه های مختلف ریسک فراهم سازد (Leo et al., 2019; Heß & Damásio, 2025).

تحلیل ها نشان داد که شبکه های عصبی مصنوعی (ANN) به دلیل معماری منعطف و قابلیت تنظیم پارامترها برای پردازش داده های با ابعاد بالا، ابزار بسیار کارآمدی در مدل سازی ریسک بازار و پیش بینی نوسانات شدید دارایی ها به شمار می روند (Wang et al., 2019; Cheeviro et al., 2023). از سوی دیگر، در مدیریت ریسک عملیاتی، پیچیدگی و تنوع بالای فرآیندها مانع از وجود یک الگوریتم غالب شده است؛ با این وجود، الگوریتم جنگل تصادفی (RF) به دلیل مقاومت بالا در برابر نویز و داده های پرت، عملکرد مطلوبی در شناسایی تراکنش های متقلبانه و حملات سایبری نشان داده است (Sahingoz et al., 2019; Tadesse, 2022).

۶-۲. دلالت های کاربردی و مدیریتی

برای مدیران ارشد و تصمیم گیران بانک ها، یافته های این پژوهش نقشه راهی کاربردی برای بهره برداری بهینه از هوش مصنوعی ارائه می دهد:

- ۱. ارتقای پایش ریسک از حالت واکنشی به پیش نگز: پیاده سازی مدل های یادگیری ماشین به بانک ها اجازه می دهد تا جریان های داده ای رفتاری و تراکنشی مشتریان را به صورت آنی تحلیل کرده و پیش از وقوع خسارت، هشدارهای مقتضی را دریافت کنند.
- ۲. بهینه سازی تخصیص منابع و پورتفوی ترازنامه ای: بکارگیری الگوریتم های یادگیری تقویتی در فرآیندهای مدیریت دارایی - بدهی (ALM)، توازن پایداری میان سودآوری و نقدشوندگی دارایی ها در شرایط نوسانات بازار ایجاد می کند.
- ۳. انطباق هوشمند با مقررات نظارتی: بکارگیری مدل های تلفیقی یادگیری ماشین به بانک ها کمک می کند تا محاسبات پویاتری از شاخص های VaR، LCR و NSFR داشته باشند و با کیفیت بالاتری الزامات نظارتی را برآورده سازند.

۶-۳. محدودیت های پژوهش

روند توسعه یادگیری ماشین در مدیریت ریسک بانکی علیرغم تمام مزایا، با چند محدودیت اساسی روبرو است:

- ۱. چالش جعبه سیاه (Black-Box Problem) و عدم تفسیرپذیری: مدل های پیشرفته یادگیری عمیق و شبکه های عصبی علیرغم دقت بالا، فاقد تفسیرپذیری لازم هستند. این موضوع یکی از اصلی ترین موانع پذیرش این مدل ها توسط کمیته های ریسک بانک ها و نهادهای ناظر پولی است، چرا که تصمیمات اعتباری و نقدینگی باید به صورت شفاف قابل توجیه باشند (Giudici et al., 2023).
- ۲. دسترسی محدود به داده های کیفی و محرمانه: کمبود شدید داده های ساختاریافته و در دسترس، به ویژه در حوزه های حساسی مانند ریسک نقدینگی، مانع از توسعه همه جانبه مدل های تجربی در مقایسه با حوزه ریسک اعتباری شده است (Guerra et al., 2022).
- ۳. سوگیری در انتشار مقالات (Publication Bias): اکثر پژوهش های آکادمیک تمایل دارند مقالاتی با نتایج مثبت و برتری عملکردی یادگیری ماشین را منتشر کنند، در حالی که چالش های پیاده سازی عملیاتی و موارد شکست مدل ها کمتر گزارش می شود.

۴-۶. پیشنهاد های پژوهشی برای آینده

بر مبنای شکاف های شناسایی شده در ادبیات پژوهش، مسیرهای تحقیقاتی زیر پیشنهاد می شود:

- ۱. توسعه هوش مصنوعی قابل تفسیر (XAI) در بانکداری: تمرکز پژوهش های آینده باید بر بکارگیری تکنیک هایی مانند SHAP و LIME معطوف شود تا تصمیمات اتخاذ شده توسط مدل های پیچیده یادگیری عمیق، برای مدیران و نهادهای نظارتی ملموس و قانونمند گردد (Fritz-Morgenthal et al., 2022).
- ۲. مدل سازی ریسک های نوظهور و چندبعدی: توسعه مدل های یادگیری ماشین برای سنجش ریسک های سایبری پیشرفته، تاب آوری عملیاتی و ریسک های پولی ناشی از تغییرات اقلیمی (Climate Risk) از ضرورت های پژوهشی پیش رو است.
- ۳. تدوین چارچوب های اخلاقی و ضد سوگیری: طراحی متدهایی برای شناسایی و حذف سوگیری های جنسیتی، قومی یا اقتصادی پنهان در داده های تاریخی اعتبارسنجی جهت تحقق بانکداری مسئولانه.

۷. نتیجه گیری (Conclusion)

سیستم بانکداری نوین در سایه انباشت فزاینده داده ها و نوسانات شدید بازار، با چالش های پویایی روبرو است که تکیه محض بر مدل های آماری کلاسیک را با محدودیت مواجه می سازد. یافته های حاصل از مرور نظام مند با سنتز کیفی و تحلیل کمی توصیفی ۵۸ مطالعه منتخب در این پژوهش نشان می دهد که الگوریتم های یادگیری ماشین، به ویژه شبکه های عصبی مصنوعی، ماشین بردار پشتیبان و جنگل تصادفی، فرصت های امیدوارکننده ای برای افزایش دقت پیش بینی و ارزیابی ریسک های اصلی بانکی (شامل ریسک های اعتباری، نقدینگی و بازار) فراهم می سازند. این مدل ها به دلیل توانمندی در پایش روابط غیرخطی پیچیده و پردازش کلان داده ها، می توانند سهم شایانی در بهبود تاب آوری و پایداری ساختار مالی بانک ها ایفا کنند، هرچند بکارگیری آن ها مستلزم مدیریت ریسک مدل و صیانت از داده ها است.

۸. مراجع و منابع (References)

- ابراهیمی، م.، و پاشایی، ع. (۱۴۰۱). چالش های کیفیت داده و اعتبارسنجی مشتریان در شبکه بانکی ایران با استفاده از مدل های تصمیم گیری هوشمند. فصلنامه پول و اقتصاد، ۱۴(۳)، ۴۵-۶۸.
- بدری، ا.، و حیدری، م. (۱۳۹۹). تبیین چالش «جعبه سیاه» در کاربری الگوهای یادگیری عمیق در مدیریت ریسک و الزامات نظارتی بانک مرکزی. مجله تحقیقات پولی و بانکی، ۱۲(۴)، ۱۱۲-۱۳۵.
- تهرانی، م.، و رضایی، س. (۱۴۰۰). حفظ حریم خصوصی و امنیت داده های مشتریان در صنعت بانکی با استفاده از فناوری یادگیری فدرال. فصلنامه علمی مدیریت ریسک و بحران، ۸(۲)، ۷۹-۱۰۲.
- دستورالعمل مدیریت ریسک عملیاتی و فناوری اطلاعات. (۱۴۰۱). بانک مرکزی جمهوری اسلامی ایران، مدیریت کل مقررات و مجوزهای بانکی.
- دیوانداری، ع.، کریمی، ا.، و صلواتی، ح. (۱۳۹۸). ارزیابی آمادگی زیرساختی بانک های ایران برای مهاجرت از سیستم های سنتی به معماری میکروسرویس و داده های جریان بلادرنگ. پژوهشنامه بانکداری الکترونیک، ۷(۱)، ۱۵-۳۸.
- رسولی، م.، و محمدی، ا. (۱۴۰۲). بومی سازی فرآیندهای کشف تراکنش های مشکوک و پولشویی در سامانه های شتاب و پایا با استفاده از پردازش زبان طبیعی فارسی (NLP). فصلنامه پژوهش های پولی-بانکی، ۱۶(۲)، ۲۱۰-۲۳۵.
- عباسی، ح.، شریفی، م.، و صلواتی، ر. (۱۴۰۰). آسیب شناسی پردازش های دسته ای شبانه در سیستم های متمرکز بانکی (Core Banking) ایران و ارائه مدل جایگزین بلادرنگ. فصلنامه فناوری اطلاعات و بانکداری، ۹(۴)، ۵۵-۷۸.
- قانون مبارزه با پولشویی. (۱۴۰۰). مصوب مجلس شورای اسلامی به همراه دستورالعمل های اجرایی مرکز اطلاعات مالی (FIU).
- Abdi, H., & Williams, L. J. (2010). Principal component analysis. WIREs Computational Statistics, 2(4), 433–459. <https://doi.org/10.1002/wics.101>
- Ajeetha, G., & Madhu, P. G. (2019). Machine learning based DDos attack detection. Innovations in power and advanced computing technology (i-PACT).
- Alamsyah, A., & Zahir, A. N. (2018). Artificial neural network for predicting Indonesia Stock Exchange composite using macroeconomic variables. In 2018 6th International Conference on Information and Communication Technology (ICoICT) pp. 44–48. (IEEE. <https://doi.org/10.1109/ICoICT.2018.8528774>
- Alazzabi, W. Y. E., Mustafa, H., & Karage, A. I. (2023). Risk management, top management support, internal audit activities and fraud mitigation. Journal of Financial Crime, 30(2), 569–582. <https://doi.org/10.1108/JFC-11-2019-0147>
- Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. The Journal of Finance, 23(4), 589-609.

- Apostolik, R., Donohue, C., & Went, P. (2012) .Foundations of banking risk: An overview of banking, banking risks, and risk-based banking regulation. John Wiley & Sons. <https://doi.org/10.1002/9780470555996>
- Aziz, S., & Dowling, M. (2019) .Machine learning and AI for risk management. In J. Hill (Ed.) ,Disrupting Finance)pp. 33–50 .(Palgrave Pivot. https://doi.org/10.1007/978-3-030-02330-0_3
- Balci, T., & Ogul, H. (2021) .Predicting bank return on equity (ROE) using neural networks. In SAMI 2021 - IEEE 19th World Symposium on Applied Machine Intelligence and Informatics, Proceedings)pp. 279–285 .(IEEE. <https://doi.org/10.1109/SAMI50585.2021.9378636>
- Basel Committee on Banking Supervision]BCBS .[(2013) .Basel III: The Liquidity Coverage Ratio and liquidity risk monitoring tools. Bank for International Settlements.
- Basel Committee on Banking Supervision]BCBS .[(2014) .Basel III: the net stable funding ratio. Bank for International Settlements.
- Basel Committee on Banking Supervision]BCBS .[(2023) .Basel Committee on Banking Supervision the Basel Framework. Bank for International Settlements. Available: https://www.bis.org/basel_framework/
- Berrar, D. (2018) .Bayes 'Theorem and Naive Bayes classifier. Encyclopedia of bioinformatics and computational biology)pp. 403–412 .(Elsevier. <https://doi.org/10.1016/B978-0-12-809633-8.20473-1>
- Bhatore, S., Mohan, L., & Reddy, Y. R. (2020) .Machine learning techniques for credit risk evaluation: A systematic literature review. Journal of Banking and Financial Technology, 4(1) ,111–138. <https://doi.org/10.1007/s42786-020-00020-3>
- Breiman, L. (2001) .Random forests. Machine Learning, 45(1) ,5–32. <https://doi.org/10.1023/A:1010933404324>
- Chatterjee, A., Bhowmick, H., & Sen, J. (2022) .Stock volatility prediction using time series and deep learning approach. In 2022 IEEE 2nd Mysore Sub Section International Conference. IEEE. <https://doi.org/10.1109/MysuruCon55714.2022.9972559>
- Cheeviro, S., Smanchat, S., & Nuchitprasitchai, S. (2023) .Evaluation of traditional finance models and machine learning approaches in FOREX volatility prediction. In 2023 27th International Computer Science and Engineering Conference (ICSEC)) pp. 315–318 .(IEEE. <https://doi.org/10.1109/ICSEC59635.2023.10329670>
- Chen, M., Dautais, Y., Huang, L. G., & Ge, J. (2017) .Data driven credit risk management process: A machine learning approach. In ACM International Conference Proceeding Series)pp. 109–113 .(ACM. <https://doi.org/10.1145/3084100.3084113>
- Chen, S. (2023) .Research on risk management in banking system. Highlights in Business, Economics and Management, 3, 267–275. <https://doi.org/10.54097/hbem.v3i.4754>

- Chen, W., Chen, B., & Cai, X. (2023) .Forecasting China's stock market risk under the background of the Stock Connect programs. Application of Soft Computing. <https://doi.org/10.1007/s00500-023-08496-z>
- Chockalingam, A., Dabadghao, S., & Soetekouw, R. (2018) .Strategic risk, banks, and Basel III: Estimating economic capital requirements. The Journal of Risk Finance, 19(3) ,225–246. <https://doi.org/10.1108/JRF-11-2016-0142>
- Cont, R. (2001) .Empirical properties of asset returns: Stylized facts and statistical issues. Quantitative Finance, 1(2) ,223–236. <https://doi.org/10.1080/713665670>
- Cortes, C., & Vapnik, V. (1995) .Support-Vector Networks. Machine Learning, 20(3) ,273–297. <https://doi.org/10.1023/A:1022627411411>
- Dang, T. L., & Nguyen, T. M. H. (2020) .Liquidity risk and stock performance during the financial crisis. Journal of International Business and Finance, 52, Article 101165. <https://doi.org/10.1016/j.ribaf.2019.101165>
- Daniali, S. M., et al. (2021) .Predicting volatility index according to technical index and economic indicators on the basis of deep learning algorithm. Sustainability, 13(24) .<https://doi.org/10.3390/su132414011>
- Dixon, M. F., Halperin, I., & Bilokon, P. (2020) .Machine learning in finance. Springer. <https://doi.org/10.1007/978-3-030-41068-1>
- Dutta, A., Kumar, S., & Basu, M. (2020) .A gated recurrent unit approach to bitcoin price prediction. Journal of Risk and Financial Management, 13(2) .<https://doi.org/10.3390/jrfm13020023>
- El Bouchti, A., Chakroun, A., Abbar, H., & Okar, C. (2017) .Fraud detection in banking using deep reinforcement learning. In The Seventh International Conference on Innovative Computing Technology)pp. 58–63.(
- Freeda, S. E., Selvan, T. C. E., & Hemanandhini, I. G. (2021) .Prediction of bitcoin price using deep learning model. In Proceedings of the 5th International Conference on Electronics, Communication and Aerospace Technology, ICECA 2021)pp. 1702–1706 .(IEEE. <https://doi.org/10.1109/ICECA52323.2021.9676048>
- Fritz-Morgenthal, S., Hein, B., & Papenbrock, J. (2022) .Financial risk management and explainable, trustworthy, responsible AI. Frontiers in Artificial Intelligence, 5. <https://doi.org/10.3389/frai.2022.779799>
- Gangula, Y., Srivastava, S., Mohanty, A., & Prakasam, P. (2023) .Investigation of various machine learning techniques for banknote authentication. In 2023 3rd Asian Conference on Innovation in Technology. IEEE. <https://doi.org/10.1109/ASIANCON58793.2023.10270276>
- García, S., Ramírez-Gallego, S., Luengo, J., Benítez, J. M., & Herrera, F. (2016) .Big data preprocessing: Methods and prospects. Big Data Analysis, 1(1) ,9. <https://doi.org/10.1186/s41044-016-0014-0>

- Gašperov, B., Begušić, ČS., Posedel Šimovi, ČP., & Kostanjčar, Z. (2021). Reinforcement learning approaches to optimal market making. *Mathematics*, 9(21), 2689. <https://doi.org/10.3390/math9212689>
- Giudici, P., Centurelli, M., & Turchetta, S. (2023). Artificial intelligence risk measurement. *Expert Systems with Applications*, 235, Article 121220. <https://doi.org/10.1016/j.eswa.2023.121220>
- González-Carrasco, I., Jiménez-Márquez, J. L., López-Cuadrado, J. L., & Ruiz-Mezcua, B. (2019). Automatic detection of relationships between banking operations using machine learning. *Information Sciences*, 485, 319–346. <https://doi.org/10.1016/j.ins.2019.02.030>
- González-Rossano, C., Terán-Bustamante, A., Velázquez-Salazar, M., & Martínez-Velasco, A. (2023). What drives profit income in Mexico's main banks? Evidence using machine learning. *Sustainability*, 15(7). <https://doi.org/10.3390/su15075696>
- Gorton, G., & Metrick, A. (2012). Getting up to speed on the financial crisis: A one-weekend-reader's guide. *Journal of Economic Literature*, 50(1), 128–150. <https://doi.org/10.1257/jel.50.1.128>
- Gu, F., Jiang, Z., & Su, J. (2021). Application of features and neural network to enhance the performance of deep reinforcement learning in portfolio management. In 2021 IEEE 6th International Conference on Big Data Analytics, ICBDA 2021 (pp. 92–97). (IEEE. <https://doi.org/10.1109/ICBDA51983.2021.9403044>
- Guerra, P., Castelli, M., & CÔrte-Real, N. (2022). Machine learning for liquidity risk modelling: A supervisory perspective. *Economic Analysis and Policy*, 74, 175–187. <https://doi.org/10.1016/j.eap.2022.02.001>
- Guz, A. N., & Rushchitsky, J. J. (2009). Scopus: Systematic review of strength and quality of scientific journals. *International Applied Mechanics*, 45(12), 1297–1310.
- Hartigan, J. A., & Wong, M. A. (1979). Algorithm AS 136: A K-means clustering Algorithm. *Applied Statistics*, 28(1), 100. <https://doi.org/10.2307/2346830>
- Heß, V. L., & Damásio, B. (2025). Machine learning in banking risk management: Mapping a decade of evolution. *International Journal of Information Management Data Insights*, 5(1), 100324. <https://doi.org/10.1016/j.jjime.2025.100324>
- Horcher, K. A. (2005). *Essentials of financial risk management*. Wiley. <https://doi.org/10.1002/9781118386392>
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied logistic regression*. Wiley. <https://doi.org/10.1002/9781118548387>
- Hua, Y., Zhu, R., & Duan, Y. (2022). Construction of short-term stock price prediction algorithm based on MLP and CART Bagging ensemble learning. In 2022 IEEE Conference on Telecommunications, Optics and Computer Science (TOCS) (pp. 371–376). (IEEE. <https://doi.org/10.1109/tocs56154.2022.10015919>

- Hull, J. (2018) .Risk management and financial institutions (5th ed.) John Wiley & Sons.
- Jensen, R. I. T., & Iosifidis, A. (2023) .Fighting money laundering with statistics and machine learning. IEEE Access, 11, 8889–8903. <https://doi.org/10.1109/ACCESS.2023.3239549>
- Johri, S., Qureshi, N. I., Mehta, K., Othman, B., Waghmare, S., & Pant, B. (2022) .A critical significance of using machine learning in strengthening financial risk management in banking firms. In 2022 2nd International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE)) pp. 1933–1937 .(IEEE. <https://doi.org/10.1109/ICACITE53722.2022.9823653>
- Jorion, P. (2007) .Value at risk: the new benchmark for managing financial risk (3rd ed.) .McGraw-Hill.
- Kawahara, R., & Takeuchi, M. (2021) .Cash flow prediction of a bank deposit using scalable graph analysis and machine learning. In 2021 IEEE International Conference on Big Data)pp. 1647–1656 .(IEEE. <https://doi.org/10.1109/BigData52589.2021.9672081>
- Kelliher, P. O. J., Wilmot, D., Vij, J., & Klumpes, P. J. M. (2013) .A common risk classification system for the actuarial profession. British Actuarial Journal, 18(1) ,91–121. <https://doi.org/10.1017/S1357321712000293>
- Kitchenham, B. (2004) .Procedures for performing systematic reviews. Keele University Technical Report.
- Kitchenham, B., & Charters, S. (2007) .Guidelines for performing Systematic Literature Reviews in software engineering. Keele University and Durham University Joint Report.
- Kotsiantis, S., Kanellopoulos, D., & Pintelas, P. E. (2006) .Data preprocessing for Supervised learning. International Journal of Computer Science, 1(1) ,111–117.
- Krabichler, T., & Teichmann, J. (2023) .A case study for unlocking the potential of deep learning in asset-liability-management. Frontiers in Artificial Intelligence, 6. <https://doi.org/10.3389/frai.2023.1177702>
- Kubat, M. (2017) .An introduction to machine learning. Springer. <https://doi.org/10.1007/978-3-319-63913-0>
- Leo, M., Sharma, S., & Maddulety, K. (2019) .Machine learning in banking risk management: A literature review. Risks, 7(1) ,29. <https://doi.org/10.3390/risks7010029>
- Lessmann, S., Baesens, B., Seow, H.-V., & Thomas, L. C. (2015) .Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. European Journal of Operational Research, 247(1) ,124–136. <https://doi.org/10.1016/j.ejor.2015.05.030>
- Liang, Y. (2017) .Empirical study on China’s financial risk early warning under the new normal. In 4th International Conference on Industrial Economics System and Industrial Security Engineering (IEIS) .IEEE. <https://doi.org/10.1109/IEIS.2017.8078570>

- Lin, H., Zhou, D., Liu, W., & Bian, J. (2021) .Deep risk model: A Deep learning solution for mining latent risk factors to improve covariance matrix estimation. In ICAIF 2021 - 2nd ACM International Conference on AI in Finance. ACM. <https://doi.org/10.1145/3490354.3494377>
- Liu, Y., Tang, Z., & Zheng, W. (2019) .Suspicious bank card transaction recognition based on K-means clustering and random forest algorithm. In 2019 International Conference on Intelligent Informatics and Biomedical Sciences (ICIIBMS) .IEEE.
- Lowd, D., & Domingos, P. (2005) .Naive Bayes models for probability estimation. In Proceedings of the 22nd international conference on Machine learning)pp. 529–536 .(ACM. <https://doi.org/10.1145/1102351.1102418>
- Masduki, B. W., Ramli, K., Saputra, F. A., & Sugiarto, D. (2015) .Study on implementation of machine learning methods combination for improving attacks detection accuracy on intrusion detection system (IDS) .In International Conference on Quality in Research)pp. 56–64.(
- Mashrur, A., Luo, W., Zaidi, N. A., & Robles-Kelly, A. (2020) .Machine learning for financial risk management: A survey. IEEE Access, 8, 203248-203269. <https://doi.org/10.1109/ACCESS.2020.3036322>
- Milana, C., & Ashta, A. (2021) .Artificial intelligence techniques in finance and financial markets: A survey of the literature. Strategic Change, 30(3) ,189–209. <https://doi.org/10.1002/jsc.2403>
- Milojević, N., & Redzepagić, S. (2021) .Prospects of artificial intelligence and machine learning application in banking risk management. Journal of Central Banking Theory and Practice, 10(3) ,41–57. <https://doi.org/10.2478/jcbtp-2021-0023>
- Moher, D., Liberati, A., Tetzlaff, J., Altman, D. G., & PRISMA Group. (2009) .Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. PLoS Medicine, 6(7) ,e1000097.
- Ngo, V. M., Nguyen, H. H., & Van Nguyen, P. (2023) .Does reinforcement learning outperform deep learning and traditional portfolio optimization models in frontier and developed financial markets ?Research in International Business and Finance, 65, Article 101936. <https://doi.org/10.1016/j.ribaf.2023.101936>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., ... & Moher, D. (2021) . The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. Systematic Reviews, 10(1) ,1-11. <https://doi.org/10.1186/s13643-021-01626-4>
- Pallathadka, H., Ramirez-Asis, E. H., Loli-Poma, T. P., Kaliyaperumal, K., Ventayen, R. J. M., & Naved, M. (2023) . Applications of artificial intelligence in business management, e-commerce and finance. Materials Today: Proceedings, 80, 2610–2613. <https://doi.org/10.1016/j.matpr.2021.06.419>
- Pena, A., et al. (2021) .Fuzzy convolutional deep-learning model to estimate the operational risk capital using multi-source risk events. Applied Soft Computing, 107. <https://doi.org/10.1016/j.asoc.2021.107381>

- Qasaimeh, M., Hammour, R. A., Yassein, M. B., Al-Qassas, R. S., Torralbo, J. A. L., & Lizcano, D. (2022) . Advanced security testing using a cyber-attack forecasting model: A case study of financial institutions. Journal of Software: Evolution and Process, 34(11) .<https://doi.org/10.1002/smr.2489>
- Rosenberg, J. V., & Schuermann, T. (2006) .A general approach to integrated risk management with skewed, fat-tailed risks. Journal of Financial Economics, 79(3) ,569–614. <https://doi.org/10.1016/j.jfineco.2005.03.001>
- Rundo, F., Trenta, F., di Stallo, A. L., & Battiato, S. (2019) .Machine learning for quantitative finance applications: A survey. Applied Sciences, 9(24) ,5574. <https://doi.org/10.3390/app9245574>
- Sadok, H., Mahboub, H., Chaibi, H., Saadane, R., & Wahbi, M. (2023) .Applications of artificial intelligence in finance: Prospects, limits and risks. In Proceedings - 2023 International Conference on Digital Age and Technological Advances for Sustainable Development)pp. 145–149 .(IEEE. <https://doi.org/10.1109/ICDATA58816.2023.00034>
- Sahingoz, O. K., Buber, E., Demir, O., & Diri, B. (2019) .Machine learning based phishing detection from URLs. Expert Systems with Applications, 117, 345–357. <https://doi.org/10.1016/j.eswa.2018.09.029>
- Sanford, A., & Moosa, I. (2015) .Operational risk modelling and organizational learning in structured finance operations: A bayesian network approach. Journal of the Operational Research Society, 66(1) ,86–115. <https://doi.org/10.1057/jors.2013.49>
- Sarangi, P. K., Mohanty, J., Mohapatra, S. K., & Sahu, P. (2023) .Computing stock market price behavior using machine learning approach. In 6th International Conference on Information Systems and Computer Networks. IEEE. <https://doi.org/10.1109/ISCON57294.2023.10112128>
- Seid, M. H., & Woldeyohannis, M. M. (2022) .Customer churn prediction using machine learning: Commercial Bank of Ethiopia. In 2022 International Conference on Information and Communication Technology for Development for Africa (ICT4DA)) pp. 1–6 .(IEEE. <https://doi.org/10.1109/ICT4DA56482.2022.9971224>
- Shahbazi, Z., & Byun, Y. C. (2022) .Machine learning-based analysis of cryptocurrency market financial risk management. IEEE Access, 10, 37848–37856. <https://doi.org/10.1109/ACCESS.2022.3162858>
- Shetu, S. F., Jahan, I., Islam, M. M., Ara Hossain, R., Moon, N. N., & Nur, F. N. (2021) .Predicting satisfaction of online banking system in Bangladesh by machine learning. In 2021 International Conference on Artificial Intelligence and Computer Science Technology (ICAICST)) pp. 223–228 .(IEEE. <https://doi.org/10.1109/ICAICST53116.2021.9497796>
- Shi, S., Tse, R., Luo, W., D'Addona, S., & Pau, G. (2022) .Machine learning-driven credit risk: A systemic review. Neural Computing and Applications. <https://doi.org/10.1007/s00521-022-07472-2>
- Singh, V., Chen, S.-S., Singhanian, M., Nanavati, B., Kar, A. K., & Gupta, A. (2022) .How are reinforcement learning and deep learning algorithms used for big data based decision making in financial industries—A review and research

agenda. International Journal of Information Management Data Insights, 2(2) .
<https://doi.org/10.1016/j.jjime.2022.100094>

•Snyder, H. (2019) .Literature review as a research methodology: An overview and guidelines. Journal of Business Research, 104, 333–339. <https://doi.org/10.1016/j.jbusres.2019.07.039>

•Stege, N., Basse, T., Wegener, C., & Kunze, F. (2017) .Mapping interest rate projections using neural networks under cointegration. In ACM International Conference Proceeding Series. ACM.
<https://doi.org/10.1145/3109761.3109774>

•Swankie, G., & Broby, D. (2019) .Examining the impact of artificial intelligence on the evaluation of banking risk. Online. <https://doi.org/10.13140/RG.2.2.33790.84524>

•Tadesse, T. (2022) .Combining control rules, machine learning models, and community detection algorithms for effective fraud detection. In 2022 International Conference on Information and Communication Technology for Development for Africa (ICT4DA)) pp. 42–46 .(IEEE. <https://doi.org/10.1109/ICT4DA56482.2022.9971235>

•Tan, X. (2019) .LIBOR prediction using genetic algorithm and genetic algorithm integrated with recurrent neural network. In 2019 Global Conference for Advancement in Technology (GCAT)) pp. 1–8 .(IEEE. <https://doi.org/10.1109/GCAT47503.2019.8978299>

•Tavana, M., Abtahi, A. R., Di Caprio, D., & Poortarigh, M. (2018) .An Artificial Neural Network and Bayesian Network model for liquidity risk assessment in banking. Neurocomputing, 275, 2525–2554. <https://doi.org/10.1016/j.neucom.2017.11.034>

•Taweerojkulsri, C., & Limpiyakorn, Y. (2014) .Learning model for assessing loss of severity of operational risk. In International Conference on Information Science & Applications (ICISA) .IEEE. <https://doi.org/10.1109/ICISA.2014.6847421>

•Taylor, S., & Keselj, V. (2021) .Predicting the distress of financial intermediaries using convolutional neural networks. In 2021 IEEE 23rd Conference on Business Informatics)pp. 71–77 .(IEEE. <https://doi.org/10.1109/CBI52690.2021.10057>

•Tengxi, W. (2023) .Research on forecasting and risk measurement of internet money fund returns based on error-corrected 1DCNN-LSTM-SAM and VaR: Evidence from China. IEEE Access. <https://doi.org/10.1109/ACCESS.2023.3309007>

•Tyagi, S. (2022) .Analyzing machine learning models for credit scoring with explainable AI and optimizing investment decisions. arXiv preprint arXiv:2209.09362.

•Ullah, I., Hussain, H., Ali, I., & Liaquat, A. (2019) .Churn prediction in banking system using K-means, LOF, and CBLOF. In 1st International Conference on Electrical, Communication and Computer Engineering (ICECCE) .IEEE.

- Varotto, S. (2011) .Liquidity risk, credit risk, market risk and bank capital. International Journal of Managerial Finance, 7(2) ,134–152. <https://doi.org/10.1108/17439131111122139>
- Viji, S., Kannan, R., & Jayalashmi, N. Y. (2021) .Intelligent anomaly detection model for atm booth surveillance using machine learning algorithm. In 2021 International Conference on Computing, Communication, and Intelligent Systems (ICCCIS)) pp. 1007–1012 .(IEEE. <https://doi.org/10.1109/ICCCIS51004.2021.9397103>
- Wang, Y., Jiang, Y., & He, G. (2019) .Using artificial neural network to predict value-at-risk of S&P 500 market index with external information. In 2019 IEEE International Conference on Big Data, Cloud Computing, Data Science & Engineering (BCD)) pp. 90–93 .(IEEE. <https://doi.org/10.1109/BCD.2019.8884865>
- Wanke, P., Azad, M. A. K., Barros, C. P., & Hadi-Vencheh, A. (2016) .Predicting performance in ASEAN banks: An integrated fuzzy MCDM–neural network approach. Expert Systems, 33(3) ,213–229. <https://doi.org/10.1111/exsy.12144>
- Xu, J., & Yang, D. (2022) .Financial risk control model based on deep neural networks. Scientific Programming. <https://doi.org/10.1155/2022/7253832>
- Yu, Y., Xu, Y., Wang, J., Li, Z., & Cao, B. (2022) .Anti-money laundering risk identification of financial institutions based on aspect-level graph neural networks. In 2022 IEEE 22nd International Conference on Software Quality, Reliability and Security Companion)pp. 542–546 .(IEEE. <https://doi.org/10.1109/QRS-C57518.2022.00086>
- Zaychenko, Y., & Zgurovsky, M. (2019) .Banks bankruptcy risk forecasting with application of computational intelligence methods. In IEEE 14th International Conference on Computer Sciences and Information Technologies (CSIT)) pp. 38–41 .(IEEE. <https://doi.org/10.1109/STC-CSIT.2019.8929872>
- Zhailybayevich, Z. K., & Hamada, M. A. (2023) .Development of a predictive intellectual model for predicting the financial crisis in banks. In Proceedings of the 2nd International Conference on Applied Artificial Intelligence and Computing, ICAAIC 2023)pp. 661–665 .(IEEE. <https://doi.org/10.1109/ICAAIC56838.2023.10140628>
- Zhou, F., Qi, X., Xiao, C., & Wang, J. (2021) .MetaRisk: Semi-supervised few-shot operational risk classification in banking industry. Information Sciences, 552, 1–16. <https://doi.org/10.1016/j.ins.2020.11.027>