



فصلنامه علمی پژوهشی دانش سرمایه‌گذاری
دوره ۱۵ / شماره ۱ (پیاپی ۵۷) / بهار ۱۴۰۵
صفحه ۱۸۷ تا ۲۲۲

طراحی و توسعه یک سیستم هشدار زود هنگام (EWS) مبتنی بر یادگیری ماشین جهت پیش‌بینی رویدادهای بحرانی جهانی بازارهای سهام

علی نمکی

استادیار، دانشکده حسابداری و علوم مالی، دانشگاه تهران، تهران، ایران، (نویسنده مسئول)
AliNamaki@ut.ac.ir

رضا عیوضلو

استادیار، دانشکده حسابداری و علوم مالی، دانشگاه تهران، تهران، ایران.
Eivazlu@ut.ac.ir

سعید فلاح‌پور

دانشیار، دانشکده حسابداری و علوم مالی، دانشگاه تهران، تهران، ایران.
Falahpor@ut.ac.ir

شاهین رامتین‌نیا

دانشجوی دکتری، دانشکده حسابداری و علوم مالی، دانشگاه تهران، تهران، ایران.
Shahin.Ramtinnia@ut.ac.ir

تاریخ دریافت: ۱۴۰۲/۱۰/۱۱ تاریخ پذیرش: ۱۴۰۲/۱۲/۲۴

چکیده

در دنیای همیشه در حال تحول بازارهای مالی، توانایی پیش‌بینی بحران‌های بازار سهام برای سیاست‌گذاران و سرمایه‌گذاران اهمیت فراوانی دارد. در این مطالعه سعی شده است رویکردی ارائه گردد که از قدرت روش‌های مبتنی بر یادگیری ماشین برای پیش‌بینی رویدادهای بحرانی جهانی بازار سهام استفاده کند. در این پژوهش با استفاده از یک مجموعه غنی داده شامل داده‌های روزانه بازارهای سهام ۳۷ کشور، اوراق قرضه ۳۰ کشور در سررسیدهای مختلف، ۲۷ جفت ارز و سایر متغیرهای تاثیرگذار در بازه زمانی ۲۰۲۱-۱۹۹۶ استفاده شده و یک مکانیزم پیش‌بینی مبتنی بر روش‌های مختلف یادگیری ماشین همچون درخت تصمیم، ماشین بردار پشتیبان، جنگل‌های تصادفی، شبکه‌های عصبی، تقویت شدید گرادیان، شبکه‌های عصبی عمیق، یادگیری تقویتی و شبکه‌های حافظه‌ی کوتاه‌مدت طولانی و همچنین جهت ترکیب پیش‌بینی آن‌ها از ۴ رویکرد میانگین‌گیری ساده و موزون، تکنیک بیزین و پشته‌سازی (استفاده از سه متا مدل) استفاده شده است.

نتایج حاصل از ارزیابی مدل‌های ارائه شده، حاکی از آن بود که عملکرد مدل‌های ترکیبی، به‌ویژه مدل‌های مبتنی بر پشته‌سازی، در پیش‌بینی رویدادهای بحرانی جهانی بازار سهام بهتر از مدل‌های انفرادی است. همچنین چارچوب معرفی شده در این پژوهش، می‌تواند به‌عنوان یک سیستم هشدار زود هنگام (EWS) عمل کند. با توجه به نوسانات و پویایی‌های پیچیده بازارهای مالی، روش‌های سنتی اغلب در ارائه هشدارهای به‌موقع ناکارآمد عمل می‌کنند، در حالی که استفاده از تکنیک‌های مبتنی بر یادگیری ماشین، می‌تواند منجر به شناسایی الگوهای ظریف و ناهنجاری‌هایی که قبل از یک رویداد بحرانی پیش می‌آیند، گردد.

واژه‌های کلیدی: رویدادهای بحرانی، بازار سهام، یادگیری ماشین، سیستم‌های هشدار زود هنگام (EWS)

۱- مقدمه

درهم‌تنیدگی و ارتباط عمیق میان بازارهای مالی، از ویژگی‌های بارز اکوسیستم بازارهای مالی جهانی به‌شمار می‌رود. در طول تاریخ بازارهای مالی، موارد متعددی از تبدیل بحران‌های کوچک مقیاس و محلی، به بحران‌های در مقیاس بزرگ، منطقه‌ای و یا حتی جهانی تجربه شده است. (مینویو و همکاران، ۲۰۱۴) این گونه رویدادهای بحرانی، که اغلب از بازارهای مالی کلیدی نشأت می‌گیرند، پیامدهای عمیقی در اقتصاد سرتاسر جهان دارند؛ که از جمله آن‌ها می‌توان به بحران مالی آسیایی در سال ۱۹۹۷ از تایلند شروع شد و بعد از درگیر کردن بازارهای مالی سایر کشورهای آسیایی، به اروپا و آمریکا رسید و همچنین بحران مالی جهانی در سال ۲۰۰۸ اشاره کرد که از بازارهای مالی آمریکا شروع شد و تقریباً کل اقتصاد جهانی را درگیر کرد. (رینهارت و روگوف، ۲۰۰۹)

امروزه پیامدهای این رویدادها از حوزه‌های مالی و اقتصادی فراتر رفته و این موضوع بر جنبه‌های اجتماعی، سیاسی و حتی زیست محیطی در مقیاس جهانی تأثیر می‌گذارد. (مارتین، ۲۰۱۱) ازین‌رو، درک و پیش‌بینی این رویدادها برای رسیدن به ثبات اقتصادی و برنامه‌ریزی‌های کلان مالی، اقتصادی و راهبردی ضروری به‌نظر می‌رسد. سیستم‌های هشدار زودهنگام (EWS) به‌عنوان ابزارهایی حیاتی در پیش‌بینی و کاهش اثرات مخرب رویدادهای بحرانی نقشی با اهمیت و حیاتی در ارائه هشدارهای به‌موقع به سیاست‌گذاران و سرمایه‌گذاران ایفا می‌کنند. (قلیزاده و همکاران، ۱۴۰۰) این سیستم‌ها به سیاست‌گذاران، تصمیم‌گیران و سرمایه‌گذاران اجازه می‌دهد تا اقدامات پیشگیرانه مناسبی را در برابر رکودهای اقتصادی ناشی از وقوع رویدادهای بحرانی به‌کار گیرند. (ساراکو و همکاران، ۲۰۱۶) توسعه این سیستم‌ها به‌دلیل نیاز به پیش‌بینی دقیق بحران‌های احتمالی و در عین حال به حداقل رساندن وقوع آلام‌های کاذب، نیازمند تعادل ظریفی در طراحی است که نقشی اساسی در میزان کارایی و اثربخشی آن‌ها ایفا می‌کند. (کلوپوتن و همکاران؛ ۲۰۱۸) توانایی این سیستم‌ها در تجزیه و تحلیل مجموعه‌های گسترده‌ای از داده‌های مالی و شاخص‌های اقتصادی، تأثیری اساسی بر عملکرد آن‌ها دارد. امروزه سیستم‌های هشدار زودهنگام از مدل‌های تحلیلی و پیش‌بینی‌کننده مختلف، از جمله روش‌های مبتنی بر یادگیری ماشین و یادگیری آماری استفاده می‌کنند (هانسن، ۲۰۲۱؛ امینی‌راد و همکاران، ۱۴۰۱). این رویکرد مبتنی بر داده، به درک دقیق‌تری از پویایی‌های بازارهای مالی منجر شده و به سیاست‌گذاران و تصمیم‌گیرندگان اجازه می‌دهد تا با تسهیل مداخلات به‌موقع از شدت بحران‌های مالی گسترده و یا تبعات و اثرات آن‌ها بکاهد. طراحی و اجرای سیستم‌های هشدار زودهنگام، با چالش‌های فراوانی همراه است؛ چراکه حصول اطمینان از دقت شناسایی رویدادهای بحرانی و در عین حال اجتناب از هشدارهای کاذب کار پیچیده‌ای است و نیازمند اصلاح مداوم مدل‌ها و الگوریتم‌های به‌کار گرفته شده در این سیستم‌ها است. ماهیت پویای بازارهای مالی منجر به لزوم تکامل و تغییر سیستم‌های هشدار زودهنگام، با تغییر شرایط اقتصادی و پویایی‌های حاکم بر بازارهای مالی می‌شود. (رینهارت و روگوف، ۲۰۰۹) سیر تکامل روش‌های پیش‌بینی به‌کار گرفته شده در سیستم‌های هشدار زودهنگام از روش‌های سنتی به رویکردهای یادگیری ماشینی مدرن حاکی از یک تغییر پارادایم در چشم‌انداز مباحث مربوط به پیش‌بینی در بازارهای مالی است. در ابتدا، روش‌های پیش‌بینی در بازارهای مالی به شدت به مدل‌های خطی و تکنیک‌های بنیادی وابسته بود، از جمله این دسته از پژوهش‌ها می‌توان به فاما و فرنچ (۱۹۹۲) اشاره نمود که بر عواملی مانند ارزش بازار و نسبت‌های

ارزش برای درک روندهای بازار تمرکز داشتند. این روش‌های سنتی که ریشه در تئوری‌های آماری و اقتصادسنجی دارند، به عنوان سنگ بنای پیش‌بینی‌های مالی و استراتژی‌های سرمایه‌گذاری عمل می‌کردند. (راعی و همکاران، ۱۴۰۰)

با این حال، ظهور روش‌های یادگیری آماری و یادگیری ماشینی عصر جدیدی را در این حوزه آغاز کرده است که با رویکردی دقیق‌تر و مبتنی بر داده شناخته می‌شود. مطالعات پیشگام در این حوزه توسط براک و همکاران (۱۹۹۲) صورت گرفت که به کاوش در مدل‌های غیرخطی مانند شبکه‌های عصبی پرداختند و زمینه را برای ادغام تکنیک‌های یادگیری ماشینی پیچیده‌تر در پیش‌بینی بازارهای مالی فراهم کردند. امروزه، یادگیری ماشین، به ویژه یادگیری عمیق، تجزیه و تحلیل بازارهای مالی را با امکان پردازش و تفسیر مجموعه داده‌های بزرگ و پیچیده تغییر داده است (لیکان و همکاران، ۲۰۱۵). این گذار صورت گرفته به رویکردهای یادگیری ماشینی نه تنها دقت پیش‌بینی‌ها در بازارهای مالی را افزایش داده است، بلکه شیوه تحلیل بازارها را نیز متحول کرده است و پیش‌بینی روندها و حرکات بازار را با دقت بهتری ممکن می‌سازد. (سو و همکاران، ۲۰۱۶)

همان‌طور که گفته شد، بازارهای سهام جهانی به دلیل نقش محوری‌شان در اقتصاد جهانی، همواره مورد توجه محققان، سرمایه‌گذاران و سیاست‌گذاران بوده‌اند. نوسانات شدید و بحران‌های مالی می‌توانند تأثیرات عمیق و گسترده‌ای بر سرمایه‌گذاری‌ها، ثبات مالی و رشد اقتصادی داشته باشند. با این حال، شناسایی و پیش‌بینی این رویدادهای بحرانی قبل از وقوع، به دلیل پیچیدگی‌های موجود در داده‌ها و تأثیرپذیری از عوامل متعدد، چالش‌برانگیز است. همچنین موارد زیر ضرورت‌هایی است که در جهت استفاده از روش‌های یادگیری ماشین و یادگیری عمیق ایجاد انگیزه می‌کند. کمبود استفاده از رویکردهای پیش‌بینی دقیق؛ با وجود تلاش‌های فراوان برای پیش‌بینی رویدادهای بحرانی، هنوز هم رویکردهایی که بتوانند با دقت بالا و در زمان کافی هشدار دهند، محدود هستند. نیاز به استفاده از تکنولوژی‌های پیشرفته‌تر؛ با پیشرفت تکنولوژی و دسترسی به حجم عظیمی از داده‌های بازار و همچنین توان انجام محاسبات سنگین‌تر، استفاده از روش‌های پیشرفته یادگیری ماشین و یادگیری عمیق برای کشف الگوهای پیچیده و پیش‌بینی دقیق‌تر ضروری به نظر می‌رسد. مدیریت ریسک و کاهش خسارت؛ توانایی در پیش‌بینی زود هنگام رویدادهای بحرانی به مدیران و سرمایه‌گذاران اجازه می‌دهد تا استراتژی‌های مدیریت ریسک موثرتری اتخاذ کنند و از خسارت‌های احتمالی جلوگیری به عمل آورند. تقویت ثبات در بازارهای مالی؛ پیش‌بینی دقیق رویدادهای بحرانی و اتخاذ تدابیر پیشگیرانه می‌تواند به ثبات بیشتر بازارهای مالی کمک کرده و اعتماد سرمایه‌گذاران را افزایش دهد.

این پژوهش با تمرکز بر کاهش شکاف موجود در ادبیات و بهره‌گیری از دانش فنی پیشرفته، نه تنها به پیش‌بینی زود هنگام رویدادهای بحرانی می‌پردازد، بلکه با ارائه روش‌های نوآورانه، به بهبود فرآیند تصمیم‌گیری در بازارهای مالی کمک می‌کند، تا به این ترتیب، به مدیریت بهتر ریسک‌های بازار و کاهش آسیب‌های ناشی از بحران‌های مالی اهتمام ورزد. در این پژوهش سعی شده است تا با بهره‌گیری از تکنیک‌های یادگیری ماشین و یادگیری عمیق، رویدادهای بحرانی بازارهای سهام که می‌توانند منجر به ایجاد یک رویداد بحرانی در مقیاس جهانی گردند شناسایی شوند. بدین منظور سعی شده است تا مجموعه گسترده‌ای از داده‌های بازارهای مالی مختلف، شامل

داده‌های روزانه بازارهای سهام ۳۷ کشور، اوراق قرضه ۳۰ کشور در سررسیدهای مختلف، ۲۷ جفت ارز و سایر متغیرهای تاثیرگذار و مهمی مانند قیمت طلا و کامودیتی‌ها از ابتدای سال ۱۹۹۶ تا انتهای سال ۲۰۲۱، جهت در نظر گرفتن و امکان انتشار و سرایت رویدادهای بحرانی از سایر بازارهای مالی به بازار سهام و همچنین انتشار این رویدادها از بازارهای سهام یک کشور به سایر کشورها در یک منطقه و یا تبدیل به رویدادی بحرانی در مقیاس جهانی، جمع‌آوری گشته و به کار گرفته شوند. از طرفی در این پژوهش سعی شده است تا با به‌کارگیری یک فرآیند چندلایه و جامع انتخاب ویژگی، به چالش ابعاد بالای مسئله پرداخته شود. در این فرایند با استفاده از روش‌های پرستفاده انتخاب ویژگی و کاهش ابعاد مانند بروتا، لسو و انتخاب ویژگی بر اساس مدل‌های مبتنی بر درخت تصمیم ابعاد مسئله کاهش داده شود. سپس با ادغام تکنیک‌های مختلف یادگیری ماشین، شامل رگرسیون لجستیک، درخت تصمیم، ماشین بردار پشتیبان، جنگل‌های تصادفی، شبکه‌های عصبی، تقویت شدید گرادیان، یادگیری تقویتی و شبکه‌های حافظه کوتاه‌مدت طولانی از نقاط قوت هر یک، جهت ارائه یک پیش‌بینی دقیق از رویدادهای بحرانی بازار سهام و تشکیل یک سیستم هشدار زودهنگام استفاده شود. مطابق بررسی‌های صورت گرفته، تا کنون در هیچ پژوهشی استفاده از دو روش یادگیری تقویتی و شبکه‌های حافظه کوتاه‌مدت طولانی جهت پیش‌بینی رویدادهای بحرانی بازار سهام و یا تشکیل سیستم هشدار زودهنگام استفاده نشده است. از دیگر یافته‌های این مطالعه می‌توان به ارائه یک چارچوب مشخص و چندلایه برای به‌کارگیری روش‌های یادگیری ماشین در طراحی یک سیستم هشدار زودهنگام برای پیش‌بینی رویدادهای بحرانی در بازارهای سهام اشاره کرد. این پژوهش با تمرکز بر داده‌های بازار سهام و تلاش برای شناسایی الگوهای پیش‌بینی‌کننده بحران، نوآوری‌ها و سهم قابل توجهی را در حوزه تحقیقات مالی در زمینه‌های زیر ارائه می‌دهد.

(۱) استفاده از روش‌های شبکه‌های حافظه طولانی کوتاه‌مدت (LSTM) و یادگیری تقویتی (Reinforcement Learning) برای اولین بار در حوزه پیش‌بینی رویدادهای بحرانی بازار سهام و طراحی سیستم‌های هشدار زودهنگام.

(۲) ارائه یک چارچوب مفهومی استوار و چندلایه جهت طراحی سیستم‌های هشدار سریع پیش‌بینی رویدادهای بحرانی بازارهای مالی متشکل از نحوه شناسایی رویدادهای بحرانی به‌صورت مکانیزه، رویکرد چندلایه انتخاب ویژگی با استفاده از ۴ روش انتخاب ویژگی، ترکیب پیش‌بینی مدل‌های یادگیری ماشین و یادگیری عمیق با استفاده از چهار رویکرد مختلف.

(۳) استفاده از داده‌های بزرگ و پیچیده بازارهای مختلف مالی در افق زمانی بلندمدت: این پژوهش با بهره‌گیری از حجم عظیمی از داده‌های بازارهای مالی و تحلیل دقیق آن‌ها با به‌کارگیری یک رویکرد چندلایه مبتنی بر روش‌های یادگیری ماشین و یادگیری عمیق، به دنبال شناسایی الگوهایی است که قادر به پیش‌بینی زودهنگام رویدادهای بحرانی هستند. این کار با توجه به تنوع و پیچیدگی داده‌های بازارهای مالی و ارتباط گسترده میان بازارهای مختلفی همچون بازارهای سهام، بدهی، جفت‌ارزها و کامودیتی‌ها، چالش‌های نسبتاً بزرگی به‌شمار آمده و نیازمند تحلیل‌های پیشرفته‌تری است.

۴) پیاده‌سازی روش‌های بهینه‌سازی و انتخاب ویژگی: در این پژوهش، روش‌های متعدد بهینه‌سازی و انتخاب ویژگی برای افزایش قدرت تمایز و کاهش بیش‌برازش مدل‌ها استفاده شده است. این کار به افزایش قابلیت اطمینان و کارایی مدل‌ها در شرایط واقعی بازارهای مالی کمک می‌کند.

۲- پیشینه پژوهش

پیش‌بینی رویدادهای بحرانی در بازارهای سهام به دلیل تأثیر قابل توجهی که بر اقتصاد جهانی دارند، از اهمیت بالایی برخوردار است، چراکه می‌توان از پیش‌بینی‌های صورت گرفته به طور اثربخشی در حوزه‌های مالی، کسب‌وکار، اقتصادی و تصمیم‌گیری‌های راهبردی و کلان استفاده نمود. (کارا و همکاران، ۲۰۱۱) اهمیت این پیش‌بینی‌ها در سال‌های اخیر و به خصوص بعد از وقوع بحران مالی جهانی در سال ۲۰۰۸ و یا رکود رخ داده در سال ۲۰۲۰ پس از شیوع ویروس کووید ۱۹، فزونی یافته است. ازین‌رو عمده پژوهش‌های اخیر در حوزه پیش‌بینی بازارهای مالی، به سمت استفاده از روش‌های پیشرفته‌ای مانند روش‌های مبتنی بر یادگیری آماری، یادگیری ماشینی و یادگیری عمیق سوق یافته است. (نبی‌پور و همکاران، ۲۰۲۰)

پژوهش‌های مربوط به پیش‌بینی بحران‌های بازارهای مالی با مدل‌های اقتصادسنجی سنتی آغاز شد که پایه و اساس درک پویایی‌های بازار بود. این مدل‌ها، عمدتاً مبتنی بر رگرسیون خطی و تجزیه و تحلیل سری‌های زمانی، در درک الگوهای خطی عملکرد مناسبی را نشان می‌دادند. با این حال، با تکامل بازارهای مالی، ارتباط بیشتر بازارهای مالی با یکدیگر، محدودیت‌های این مدل‌های سنتی آشکار شد. از طرفی این مدل‌ها در حالی که در شرایط باثبات عملکرد قابل قبولی داشتند، در زمان نوسانات شدیدتر بازارها، ضعیف عمل می‌کردند. (داود و همکاران، ۲۰۱۷). مدل‌هایی مانند مدل میانگین متحرک یکپارچه خودرگرسیون (ARIMA) از پراستفاده‌ترین مدل‌های این دسته بودند که در پیش‌بینی سری‌های زمانی اقتصادی و مالی به صورت گسترده به کار گرفته شده‌اند. (آمیونتالاس، ۲۰۲۳). با این حال، مفروضات مرتبط با مدل‌های سری زمانی خطی، مانند فرض ثابت بودن واریانس، خطی بودن روابط میان متغیرها و نرمال بودن بازدهی‌ها، با رفتار بازارهای مالی که اغلب غیرخطی و ناماننا بود، همسو نبودند. (جیا و همکاران، ۲۰۲۱). پیشگامان اقتصادسنجی مالی، مانند انگل (۱۹۸۲) با معرفی مدل ARCH، شروع به پرداختن به برخی از این مسائل کردند؛ اما نیاز به مدل‌های پیشرفته تر و سازگارتر مشهود بود.

ظهور یادگیری ماشینی راه‌حلی متحول‌کننده برای این چالش‌ها ارائه کرد. برخلاف مدل‌های سنتی، تکنیک‌های مبتنی بر یادگیری ماشین در شناسایی الگوهای پیچیده و روابط غیرخطی در مجموعه داده‌های بزرگ برتری قابل توجهی داشتند. این قابلیت در بازارهای مالی، که در آن متغیرها به شکل پیچیده و اغلب غیرمنتظره‌ای با یکدیگر تعامل دارند، بسیار مهم است. تغییر به سمت استفاده از این روش‌ها در پیش‌بینی‌های بازارهای مالی نه به صورت آنی بلکه تدریجی رخ داد؛ زیرا محققان و پژوهشگران شروع به شناخت پتانسیل این تکنیک‌ها کردند. پذیرندگان اولیه، مانند کیموتو و همکاران (۱۹۹۰) که شبکه‌های عصبی را در بورس اوراق بهادار توکیو به کار بردند، برتری مدل‌های یادگیری ماشین را در درک ظرافت‌های حرکات بازار نشان دادند و راه را برای پذیرش و کاربرد گسترده‌تر این روش‌ها در پیش‌بینی بازارهای مالی هموار نمودند.

از جمله پژوهش‌هایی که این راه را در موضوعات مختلف مالی ادامه دادند و از روش‌های یادگیری ماشین در زمینه‌های مختلف مالی استفاده کردند می‌توان به موارد زیر اشاره نمود. ژانگ و همکاران (۱۹۹۸) گام مهمی را در به‌کارگیری شبکه‌های عصبی در پیش‌بینی مالی برداشتند. آن‌ها عملکرد شبکه‌های عصبی را با روش‌های آماری سنتی در پیش‌بینی شاخص‌های بورس مقایسه کردند و برتری قدرت پیش‌بینی شبکه‌های عصبی، به ویژه در مدل‌سازی داده‌های غیرخطی را نشان دادند. حمید و اقبال (۲۰۰۴) با استفاده از شبکه‌های عصبی در پیش‌بینی نوسانات بازار، بینش‌هایی را در مورد کاربرد شبکه‌های عصبی در درک و پیش‌بینی عدم قطعیت بازار و یک جنبه کلیدی مدیریت ریسک مالی ارائه کردند. لانگ و همکاران (۲۰۱۹)، از یادگیری عمیق در قیمت‌گذاری دارایی‌ها استفاده نمودند. پژوهش‌های آن‌ها به درک روابط پیچیده در بازدهی دارایی‌ها کمک کرد و یکی از اولین کاربردهای یادگیری عمیق در این زمینه به شمار می‌رود.

در مباحث مربوط به بهینه‌سازی سبد سهام نیز در حالی که پژوهش‌های مارکوویتز زمینه را برای بهینه‌سازی سبد سهام فراهم کرده بود، محققان بعدی مانند دمینگل و همکاران (۲۰۰۹) استفاده از تکنیک‌های یادگیری ماشینی را برای غلبه بر محدودیت‌های روش‌های بهینه‌سازی، به ویژه در مدیریت وابستگی‌های غیرخطی و مجموعه داده‌های بزرگ بررسی کردند. بای و همکاران (۲۰۰۹)، از ماشین‌های بردار پشتیبان (SVM) در انتخاب سبد سهام استفاده کردند و کارایی مدل را در مدیریت روابط غیرخطی و بهبود عملکرد سبد نشان دادند. هیتون و همکاران (۲۰۱۷)، با استفاده از یادگیری عمیق، به‌ویژه رمزگذارهای خودکار، نشان دادند که چگونه می‌توان از شبکه‌های عصبی عمیق برای شناسایی ساختارهای پیچیده در داده‌های مالی برای مدیریت سبد استفاده کرد و رویکردی نوآورانه برای تخصیص اوزان دارایی‌ها ارائه دادند. جی‌یانگ و همکاران (۲۰۱۷) نیز از یادگیری تقویتی برای بهینه‌سازی پویای سبد سهام استفاده کردند و پتانسیل روش یادگیری تقویتی را در تطبیق استراتژی‌های سبد سهام با شرایط متغیر بازار نشان دادند.

روش‌های یادگیری ماشینی کاربردهای گسترده‌ای در زمینه‌های مختلف مالی داشته‌اند. به عنوان مثال، در مباحث مربوط به نظارت بر بازار، لی و همکاران (۲۰۱۷) الگوریتم‌هایی را برای تشخیص رفتارهایی که به‌عنوان دستکاری در بازار شناخته می‌شوند توسعه دادند و بولتون و هند (۲۰۰۱) بر روی تشخیص ناهنجاری در داده‌های معاملاتی برای شناسایی فعالیت‌های کار کردند.

در حوزه رتبه‌بندی اعتباری، لسمن و همکاران (۲۰۱۵) تکنیک‌های مختلف یادگیری ماشین را برای امتیازدهی اعتباری مقایسه کردند و خندان و همکاران (۲۰۱۰) از این روش‌ها در پیش‌بینی ریسک اعتباری مصرف‌کنندگان استفاده کردند. یادگیری ماشین همچنین در مباحث مربوط به مشاوره سرمایه‌گذاری خودکار به‌طور قابل توجهی پیشرفت کرده است. به‌عنوان مثال، یونگ و همکاران (۲۰۱۸) اثربخشی الگوریتم‌های مشاوره رباتیک در برنامه‌ریزی مالی شخصی را مورد بررسی قرار دادند و لم (۲۰۱۶) تأثیرات مشاوران رباتی بر رفتارهای سرمایه‌گذاری را بررسی کردند.

در کشف تقلب، باتچاریا و همکاران (۲۰۱۱) یک رویکرد قوی مبتنی بر یادگیری ماشین برای تشخیص تقلب کارت‌های اعتباری ارائه دادند؛ پرولز (۲۰۱۱) نیز از یادگیری عمیق برای بهبود تشخیص تقلب در صورت‌های مالی استفاده

نمود. در نهایت، در مباحث مربوط به معاملات الگوریتمی نیز به می‌توان به پژوهش دیکسون و همکاران (۲۰۱۷) و نومیواکا و همکاران (۲۰۰۶) اشاره کرد که از یادگیری تقویتی در بهینه‌سازی معاملات الگوریتمی استفاده کردند.

به‌کارگیری روش‌های مبتنی بر یادگیری ماشینی در سیستم‌های هشدار زود هنگام برای پیش‌بینی رویدادهای بحرانی در بازارهای مالی، زمینه‌ای است که در سال‌های اخیر به طور قابل توجهی تکامل یافته است. در اواخر دهه ۱۹۹۰، پایه‌های سیستم‌های هشدار زود هنگام مدرن در بازارهای مالی، عمدتاً با استفاده از مدل‌های آماری پایه‌گذاری شد. از جمله پژوهش‌های مهم در این زمینه توسط کامینسکی و همکاران (۱۹۹۸) مدلی را برای پیش‌بینی بحران‌های ارزی، به‌ویژه در بازارهای نوظهور، معرفی کرد. این مدل، اگرچه در ابتدا مبتنی بر یادگیری ماشینی نبود، اما با برجسته کردن شاخص‌ها و الگوهای کلیدی مرتبط با بحران‌های مالی، زمینه را برای حرکت سیستم‌های هشدار زود هنگام به سمت به‌کارگیری روش‌های پیشرفته‌تر فراهم کرد. در اوایل دهه ۲۰۰۰، استفاده از یادگیری ماشین در سیستم‌های هشدار زود هنگام به کار گرفته شد. از جمله آن‌ها می‌توان به پژوهش‌های هوانگ و همکاران (۲۰۰۵) اشاره نمود که ماشین‌های بردار پشتیبان (SVM) را برای پیش‌بینی سری‌های زمانی مالی به کار گرفتند؛ همچنین کیم (۲۰۰۳) که از شبکه‌های عصبی مصنوعی جهت پیش‌بینی رکود بازارهای مالی استفاده کرد. در ادامه استفاده از رویکردهای یادگیری ماشینی در سیستم‌های هشدار زود هنگام تنوع بیشتری یافت. استفاده از روش‌های جمعی، مانند پژوهش‌های لین و همکاران (۲۰۰۸) شروع به ظهور کردند که از چند یادگیری ماشین و ترکیب پیش‌بینی‌های آن‌ها برای بهبود دقت استفاده می‌کردند. در این میان، معرفی روش جنگل‌های تصادفی توسط براینم (۲۰۰۱) ابزار جدیدی را ارائه کرد که استحکام مدل‌های پیش‌بینی‌کننده رویدادهای بحرانی را به ویژه در مدیریت مجموعه داده‌های متنوع و پیچیده افزایش داد. دیکسون و همکاران (۲۰۱۷) نشان دادند که روش‌های مبتنی بر شبکه‌های عصبی عمیق، قابلیت‌های پیشرفته‌تری در شناسایی الگوهای پیچیده و غیرخطی در داده‌های مالی ارائه می‌کنند. بوهل و همکاران (۲۰۱۳) مفاهیم کلان داده را در پیش‌بینی اقتصادی مورد بررسی قرار دادند و پتانسیل تجزیه و تحلیل جامع داده‌های بزرگ را در تقویت مدل‌های پیش‌بینی برجسته کردند. ظهور مدل‌های ترکیبی که روش‌های اقتصادسنجی سنتی را با تکنیک‌های پیشرفته یادگیری ماشین ترکیب می‌کردند، همانطور که در کار سرمیپینیس و همکاران (۲۰۱۴) نشان داده شده است پیشرفت قابل توجهی را در این زمینه رقم زد. در اواخر دهه ۲۰۱۰، چاتزیس و همکاران (۲۰۱۸) رویکردی جامع برای پیش‌بینی رویدادهای بحرانی با استفاده از مدل‌های یادگیری ماشین و یادگیری عمیق ارائه دادند.

همان‌طور که ملاحظه می‌گردد، با گذر زمان، استفاده از روش‌های یادگیری ماشین در موارد متعددی از زمینه‌های مختلف مالی و اقتصادی، همچون سیستم‌های هشدار زود هنگام پررنگ‌تر می‌گردد. پذیرش الگوریتم‌های پیشرفته مانند XGBoost، که توسط چن و گسترین (۲۰۱۶) معرفی شد و استفاده از شبکه‌های حافظه طولانی کوتاه‌مدت در پیش‌بینی‌های مالی توسط فیشر و کراوس (۲۰۱۸) تاییدکننده این موضوع است. این پیشرفت‌ها نه تنها دقت پیش‌بینی این سیستم‌ها را افزایش می‌دهد، بلکه راه‌های جدیدی را برای تحلیل و تصمیم‌گیری بلندمدت در بازارهای مالی ارائه می‌دهد. هر مرحله از این تکامل، از مدل‌های بنیادی اواخر دهه ۱۹۹۰ تا الگوریتم‌های

پیشرفته امروزی، به توسعه سیستم‌های هشدار زودهنگام قوی‌تر، دقیق‌تر و سازگارتر پیش‌گیری و با کاهش اثرات مخرب بحران‌های مالی اقتصادی کمک کرده است.

با توجه به اهمیت شناسایی و پیش‌بینی رویدادهای بحرانی در بازارهای مالی، مطالعات متعددی در ادبیات داخلی ایران نیز به بررسی و توسعه سیستم‌های هشدار زودهنگام و پیش‌بینی بحران‌های مالی و حساب‌های قیمتی می‌پردازند. این تحقیقات عمدتاً با استفاده از روش‌های آماری، اقتصادسنجی و تکنیک‌های مدل‌سازی سنتی انجام شده‌اند. این مطالعات را می‌توان به صورت زیر دسته‌بندی نمود.

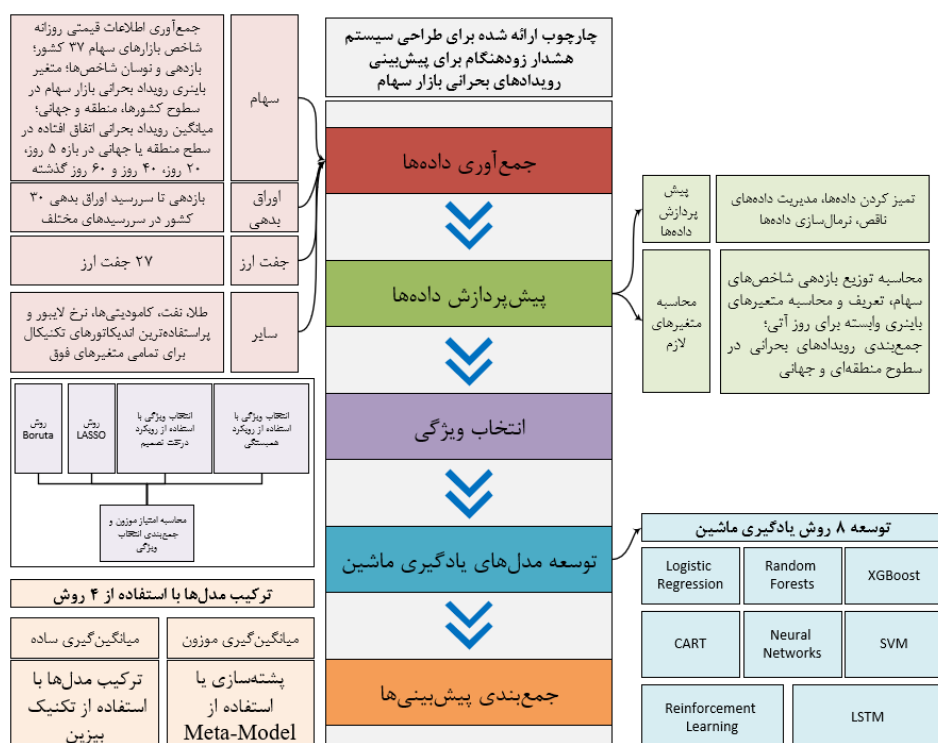
دسته اول از پژوهش‌ها به طراحی سیستم‌های هشدار دهنده و پیش‌بینی بحران‌های بانکی و ارزی پرداخته‌اند. اکبرموسوی و همکاران (۱۴۰۱) با استفاده از داده‌های کشورهای با درآمد متوسط بالا و روش لاجیت، به بررسی احتمال وقوع بحران بانکی پرداختند و عواملی مانند نسبت نقدینگی و اعتبار داخلی به تولید ناخالص داخلی را تاثیرگذار شناسایی کردند. در مطالعاتی نظیر نصرالهی و همکاران (۱۳۹۹)، به طراحی سیستم‌های هشدار دهنده برای بحران‌های ارزی با استفاده از رویکردهای مختلف نظیر رگرسیون لجستیک و تغییر رژیم مارکوف توجه شده است. پژوهش‌هایی در این حوزه نیز به طراحی سیستم هشدار دهنده در بازار سهام پرداخته‌اند. نوروزی و همکاران (۱۴۰۱)، از روش خودهمبسته واریانس ناهمسان شرطی چند متغیره جهت استخراج و شناسایی متغیر بحران مالی و حساب قیمتی در بازار سرمایه استفاده کردند و به این نتیجه رسیدند که متغیرهایی همچون تولید، نرخ تورم، نرخ ارز، شاخص کل بازار سهام تاثیر معنی‌داری بر بروز بحران مالی و احتمال رخداد حساب قیمتی در بازارهای مالی دارد. قلیزاده و همکاران (۱۳۹۹)، با استفاده از مدل‌های لاجیت و پروبیت، یک سیستم هشدار زودهنگام برای وقوع بحران مالی در بورس اوراق بهادار تهران طراحی کردند که نتایج حاصل از آن، حاکی از افزایش احتمال وقوع بحران با کاهش شاخص قیمت در دوره گذشته و نیز بروز بحران در دوره گذشته بود؛ در حالی که کاهش نرخ ارز، افزایش قیمت طلا و کاهش قیمت نفت بر بروز بحران در دوره جاری تاثیر معنی‌داری نداشت. نادمی و همکاران (۱۳۹۴) نیز با مدلسازی نوسانات بازار سهام ایران با استفاده از مدل مارکوف سوئیچینگ گارچ، یک الگوی هشدار پیش از وقوع نوسانات شدید در بازار سهام تهران معرفی نمودند.

در دسته بعدی از پژوهش‌ها به پیش‌بینی روند و بازدهی بازار سهام با استفاده از روش‌های یادگیری ماشین و یادگیری عمیق پرداخته شده است. از جمله این تحقیقات می‌توان به پژوهش ترابی پور و سیادت (۱۴۰۱) با استفاده از شبکه‌های عصبی پیچشی و حافظه طولانی کوتاه‌مدت اشاره کرد که به پیش‌بینی قیمت سهام در بازار بورس تهران پرداختند. غلامیان و داوودی (۱۳۹۷) نیز با به‌کارگیری الگوریتم جنگل‌های تصادفی و شاخص‌های تکنیکی، به پیش‌بینی قیمت سهام مبادرت ورزیدند.

همان‌طور که با بررسی پژوهش‌های مربوطه ملاحظه می‌شود، یک شکاف قابل توجه در ادبیات پژوهشی ایران در زمینه استفاده از روش‌های پیشرفته یادگیری ماشین و یادگیری عمیق برای پیش‌بینی رویدادهای بحرانی در بازار سهام ایران وجود دارد. اکثر تحقیقات انجام شده تا به حال بر رویکردهای سنتی متمرکز بوده‌اند و کمتر به بهره‌برداری از قدرت تحلیلی و تشخیصی روش‌های یادگیری ماشین و یادگیری عمیق در این زمینه پرداخته‌اند.

۳- روش شناسی پژوهش

این پژوهش برای درک پویایی‌های پیچیده بازارهای مالی جهانی و پیش‌بینی رویدادهای بحرانی بازار سهام طراحی شده است. در این پژوهش، از یک رویکرد و چارچوب چندلایه استفاده شده است که شامل جمع‌آوری داده‌های گسترده بازارهای مالی جهانی، پیش‌پردازش داده‌ها، انتخاب ویژگی، توسعه مدل‌های یادگیری ماشینی، یکپارچه‌سازی پیش‌بینی‌ها و ارزیابی چارچوب ارائه شده می‌باشد. به صورت کلی، چارچوب به کار گرفته شده در این پژوهش را می‌توان در شکل ۱ خلاصه نمود.




شکل ۱. چارچوب کلی ارائه شده برای طراحی سیستم هشدار زودهنگام پیش‌بینی رویدادهای بحرانی جهانی در بازار سهام

۳-۱ جمع‌آوری داده‌ها

در این پژوهش، به منظور مدل‌سازی رویدادهای بحرانی بازار سهام، اطلاعات مربوط به شاخص‌های مالی مختلف از منابع و پایگاه‌های مختلفی جمع‌آوری شده است. شایان ذکر است که تنها بازارهای مالی انتخاب شده است که داده‌های آن‌ها در دوره مورد مطالعه (ابتدای ۱۹۹۶ تا انتهای ۲۰۲۱) در دسترس بوده‌اند. به طور مشخص، داده‌های

مربوط به بازار سهام ۳۷ کشور، بازار اوراق بدهی ۳۰ کشور و در سررسیدهای مختلف، ۲۷ جفت ارز و سایر شاخص‌های با اهمیتی همچون قیمت نفت، طلا، کامودیتی‌ها و ... همگی در فرکانس روزانه جمع‌آوری و در این پژوهش به کار گرفته شده‌اند. این حجم بالای داده، به ما قابلیت مدل‌سازی پویایی سرایت و وابستگی‌های متقابل بازارهای مالی در طول زمان و در کشورها و بازارهای مالی مختلف را ارائه می‌دهد.

در این پژوهش، "رویداد بحرانی" در یک شاخص بازار سهام، زمانی اتفاق می‌افتد که بازدهی آن، کمتر از صدک اول توزیع تجربیش باشد. این تعریف با رویکرد اتخاذ شده توسط لانگین و سولنیک (۲۰۰۱)، که بر اهمیت نظریه مقادیر حدی در درک رفتار دنباله‌های بازارهای مالی تأکید داشتند و همچنین مطالعات مک‌نیل و فری (۲۰۰۰) که اهمیت درک دنباله‌ها در توزیع‌های بازارهای مالی را برای ارزیابی دقیق ریسک برجسته کردند؛ همسو می‌باشد. این رویکرد مکانیکی مبتنی بر صدک برای تشخیص رویداد بحرانی، به ما اجازه داد تا از انتخاب دلخواه رویدادهای بحرانی دوری کرده و آن‌ها را عمدتاً به سطوح نوسانات بالا مرتبط کنیم. بنابراین، تعریف به کار گرفته شده، جوهر یک بحران مالی را با تمرکز بر شدیدترین تحرکات بازار، که اغلب نشان‌دهنده چالش‌های اقتصادی گسترده‌تر و تشدید ریسک‌های سیستمی است، در بر می‌گیرد. همان‌طور که در یکی از پژوهش‌های اصلی راینهارت و روگوف (۲۰۰۹) در مورد بحران‌های مالی مورد استفاده قرار گرفت. با توجه به تعریف در نظر گرفته شده در خصوص رویدادهای بحرانی، نمودار ۲ تعداد کشورهایی را نشان می‌دهد که در بازه مورد بررسی این پژوهش (۲۰۲۱-۱۹۹۶)، در بازارهای سهام خود رویدادهای بحرانی را تجربه کرده‌اند. این نمودار تصویری از فراوانی و گسترش چنین بحران‌هایی در یک دوره ۲۶ ساله ارائه می‌کند و بینش‌هایی را در مورد الگوهای زمانی بی‌ثباتی مالی در کشورهای مختلف ارائه می‌دهد. با ملاحظه فراوانی این رویدادها، این نمودار نه تنها منعکس‌کننده نوسانات و حساسیت بازارهای مالی جهانی به شوک‌های اقتصادی و مالی است، بلکه ماهیت به‌هم‌پیوسته این بازارها را تایید می‌کند.




شکل ۲. تعداد رویدادهای بحرانی روی داده در بازار سهام کشورهای مختلف

- گستره داده‌ها از سال ۱۹۹۶ تا ۲۰۲۱ شامل چندین بحران مالی مهم است که اثرات عمیقی در بازارهای سهام جهانی داشته است؛ از جمله آن‌ها می‌توان به موارد زیر اشاره نمود.
- ۱) بحران تکبلا (۱۹۹۴): این بحران که با کاهش ناگهانی و شدید ارزش پزو مکزیکی آغاز شد، موجی از نوسانات را به اقتصاد آمریکای لاتین وارد نمود، که نمونه‌ای از آسیب‌پذیری بازارهای نوظهور در برابر تغییرات ناگهانی اعتماد سرمایه‌گذاران به‌شمار می‌رفت.
 - ۲) آنفلوآنزای آسیایی (۱۹۹۷): این بحران که از کاهش ارزش بات تایلند سرچشمه می‌گرفت، به سرعت بخش عمده‌ای از آسیای جنوب شرقی را فرا گرفت و منجر به سقوط شدید ارزش سهام و آشفتگی اقتصادی، در سطوح جهانی شد.
 - ۳) نکول روسی (۱۹۹۸): این بحران مالی که با عنوان ویروس روسی نیز شناخته می‌شود، نتیجه نکول روسیه در قبال بدهی‌های دولتی خود بود که منجر به بحران نقدینگی شدید، نه تنها در بازارهای نوظهور بلکه در اقتصادهای توسعه یافته نیز شد.
 - ۴) انحلال صندوق پوشش ریسک (۱۹۹۸): این صندوق که یک صندوق پوشش ریسک بزرگ بود و توسط اقتصاددانان برنده جایزه نوبل و معامله‌گران مشهور وال استریت رهبری می‌شد؛ به دنبال تجربه دو بحران بزرگ آنفلوآنزای آسیایی و نکول روسی منحل شد و موجی از نوسانات را در بازارهای مالی ایجاد نمود.
 - ۵) سقوط بازار سهام هنگ کنگ (۱۹۹۸): این رویداد رکود قابل توجهی را در یکی از قطب‌های مالی آسیا رقم زد و تأثیر شدیدی بر رویکرد و احساسات سرمایه‌گذاران در سراسر جهان گذاشت.
 - ۶) کاهش ارزش پول برزیل (۱۹۹۹): این کاهش ارزش منجر به نوسانات قابل توجهی در بازار سهام در برزیل شد که بر بسیاری از بازارهای آمریکای لاتین تأثیر گذاشت.
 - ۷) بحران دات-کام (۲۰۰۰): این سقوط که با ترکیدن حساب شرکت‌های دیجیتالی موسوم به دات کام آغاز شد، پیامدهای گسترده‌ای به‌ویژه در بازارهای سهام ایالات متحده و اروپا داشت.
 - ۸) فروپاشی هیئت ارزی آرژانتین (۲۰۰۱): این رویداد یک فروپاشی اقتصادی قابل توجه در آرژانتین بود که منجر به وحشت گسترده سرمایه‌گذاران و بی‌ثباتی بازارها شد.
 - ۹) انتخابات برزیل (۲۰۰۲): عدم اطمینان سیاسی پیرامون این انتخابات منجر به نوسانات قابل توجهی در بازار سهام برزیل شد.
 - ۱۰) بحران مالی جهانی (۲۰۰۷): با شروع فروپاشی بازار وام مسکن در ایالات متحده، این بحران به سرعت به یک رکود اقتصادی شدید در سراسر جهان تبدیل شد و به شدت بر بازارهای سهام جهانی تأثیر گذاشت.
 - ۱۱) بحران بدهی یونان (۲۰۱۰): بحران بدهی یونان نگرانی‌هایی را در مورد نکول اوراق بدهی دولتی ایجاد کرد که بر بازارهای اروپایی تأثیر شدیدی گذاشت و منجر به مشکلات اقتصادی گسترده شد.
 - ۱۲) بحران بدهی اروپا (۲۰۱۲): این بحران، ناشی از ترس از عدم پرداخت بدهی‌های دولتی در منطقه یورو، تأثیر قابل توجهی بر بازارهای سهام جهانی داشت.

۱۳) همه‌گیری ویروس کووید ۱۹ (۲۰۲۰): شیوع و همه‌گیری ویروس کرونا منجر به وقوع یک بحران جهانی و اختلال بی‌سابقه اقتصادی شد که منجر به نوسانات شدیدی در بازارهای مالی به‌خصوص بازارهای سهام در سراسر جهان شد.

علاوه بر موارد فوق، رویدادهایی مانند پرتگاه مالی آمریکا (۲۰۱۳)، تیپرینگ فدرال رزرو (۲۰۱۴)، انتخابات ایالات متحده آمریکا (۲۰۱۶) و رای برگزیت (۲۰۱۶) منجر به ایجاد نوساناتی قابل توجه در سطوح محلی و منطقه‌ای شدند. هر یک از این بحران‌ها، همان‌طور که در شکل نشان داده شده است، لحظات مهمی را در تاریخ مالی رقم زدند و شکنندگی و به‌هم‌پیوستگی بازارهای جهانی را آشکار کردند. این موضوع را می‌توان در نمودار حرارتی نوسانات بازارهای سهام مورد بررسی (شکل ۳)، با جزئیات بیشتری ملاحظه نمود.



شکل ۳. نوسانات (مجذور بازدهی) روزانه بازارهای سهام در کشورهای مورد بررسی

علاوه بر موارد فوق، رویدادهایی مانند پرتگاه مالی آمریکا (۲۰۱۳)، تیپرینگ فدرال رزرو (۲۰۱۴)، انتخابات ایالات متحده آمریکا (۲۰۱۶) و رای برگزیت (۲۰۱۶) منجر به ایجاد نوساناتی قابل توجه در سطوح محلی و منطقه‌ای شدند. هر یک از این بحران‌ها، همان‌طور که در شکل نشان داده شده است، لحظات مهمی را در تاریخ مالی رقم زدند و شکنندگی و به هم پیوستگی بازارهای جهانی را آشکار کردند. این موضوع را می‌توان در نمودار حرارتی نوسانات بازارهای سهام مورد بررسی (نمودار ۳)، با جزئیات بیشتری ملاحظه نمود.

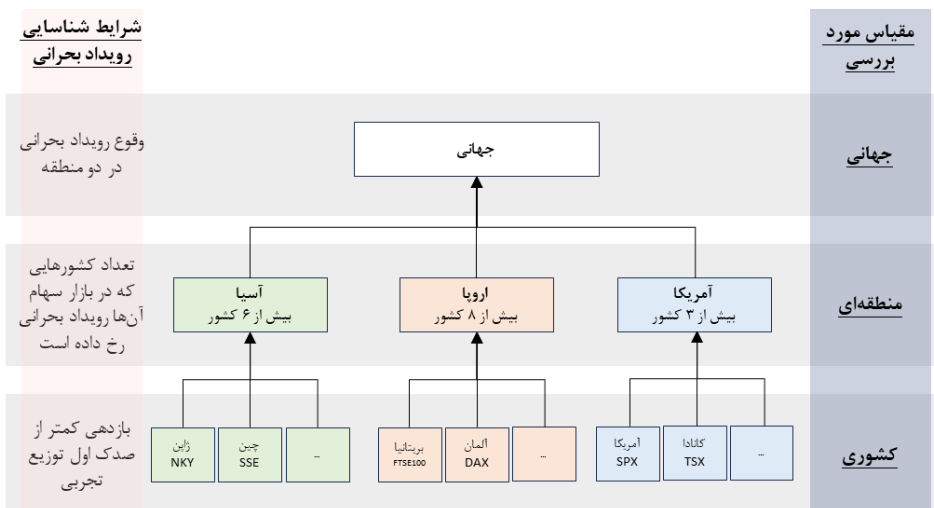
۳-۲ پردازش داده‌ها

در ساخت سیستم هشدار زود هنگام (EWS) برای پیش‌بینی بحران‌های بازار سهام، از ۸۰٪ داده‌های جمع‌آوری شده به عنوان داده‌های آموزش و از ۲۰٪ باقیمانده جهت آزمون مدل‌ها استفاده شده است. مجموعه داده‌های آموزشی برای برآزش اولیه مدل‌های به کار گرفته شده حیاتی است و مجموعه‌ای متنوع از داده‌ها که شامل شرایط مختلف بازار است را در بر می‌گیرد. بخش داده‌های آزمون نیز برای ارزیابی عملکرد و قابلیت تعمیم مدل‌های توسعه داده شده بسیار مهم است. با اعمال مدل‌ها بر روی داده‌های دیده نشده، می‌توان دقت و استحکام آن‌ها را در پیش‌بینی رفتارهای آینده بازار ارزیابی نمود. توسعه مدل‌های مورد بررسی در این پژوهش، حول یک متغیر وابسته صفر و یک که به شرح زیر مشخصاً تعریف شده متمرکز بوده است.

✓ متغیر وقوع رویداد بحرانی در افق پیش‌بینی یک روزه: این متغیر احتمال وقوع رویداد بحرانی در

بازار سهام در مقیاس جهانی را در روز معاملاتی بعدی نشان می‌دهد.

جهت تشخیص رویداد بحرانی در سطح جهانی، از یک رویکرد لایه‌ای پایین به بالا استفاده شده است. مرحله اول در این رویکرد، شناسایی رویدادهای بحرانی در هر کشور است که مطابق با بازدهی کمتر از صدک اول توزیع تجربی شاخص بازار سهام یک کشور در نظر گرفته شده است. این رویکرد، با تمرکز بر نوسانات منفی شدید، در شناسایی رکودهای قابل توجه بازار، که اغلب نشان‌دهنده بحران‌های مالی گسترده هستند، نقشی حیاتی ایفا می‌کند. در ادامه، وقوع رویداد بحرانی بازارهای سهام در مقیاس محلی یا منطقه‌ای برای سه منطقه آمریکا، آسیا و اروپا نیز با سه متغیر صفر و یک شناسایی شده است. به این صورت که در صورتی که در اکثر کشورهای هر منطقه (برای آمریکا بیش از ۳ کشور، برای آسیا بیش از ۶ کشور و برای اروپا بیش از ۸ کشور)، رویداد بحرانی شناسایی شده باشد، برای آن منطقه نیز رویداد بحرانی شناسایی می‌گردد. در نهایت نیز در صورتی که در دو منطقه از سه منطقه مورد بررسی رویداد بحرانی شناسایی شده باشد، رویداد بحرانی در مقیاس جهانی شناسایی می‌گردد. شکل ۴، به صورت شماتیک این رویکرد را نشان می‌دهد.



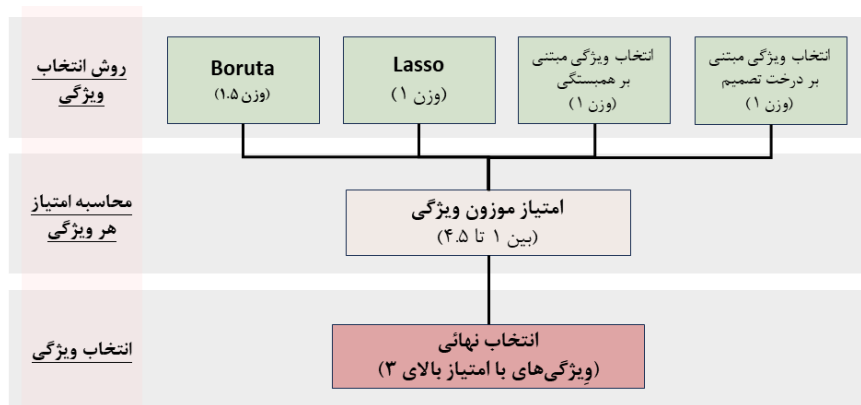
شکل ۴. رویه سیستماتیک شناسایی رویدادهای بحرانی در بازارهای سهام در سه مقیاس کشوری، منطقه‌ای و جهانی

در ادامه مرحله پردازش داده‌ها، جهت درک عمیق‌تر پیچیدگی‌های بازارهای مالی در توسعه مدل‌های مورد استفاده، مراحل دیگری نیز صورت پذیرفت. در ابتدا بازدهی همه متغیرهای مورد بررسی از جمله شاخص‌های بازار سهام، بازدهی اوراق بدهی و سایر متغیرهای مورد بررسی با استفاده از لگاریتم بر پایه نپرین و همچنین نوسانات بازدهی‌ها محاسبه گردید. در ادامه، برای هر یک از متغیرهای نشان‌دهنده رویدادهای بحرانی، وقفه‌های ۱، ۵، ۲۰، ۴۰ و ۶۰ روزه محاسبه و به مجموعه داده مورد بررسی اضافه گردید. همچنین جهت در نظر گرفتن الگوهای خوشه‌بندی رویدادهای بحرانی و تداوم پریشانی بازار میانگینی از وقوع رویدادهای بحرانی در بازار سهام هر کشور، منطقه و جهانی و همچنین میانگینی از کل رویدادهای بحرانی در ۵ روز و ۲۰ روز اخیر هر روز گرفته شد. علاوه بر این، برای تمامی متغیرهای مورد بررسی، اندیکاتورهای تکنیکال پر استفاده‌ای همچون میانگین متحرک ساده (SMA) و نمایی (EMA)، همگرایی و واگرایی میانگین متحرک (MACD)، شاخص قدرت نسبی (RSI) و باند بولینگر محاسبه و در نظر گرفته شد. با انجام این اقدامات، مجموعه‌ای بزرگ و گسترده از متغیرها و شاخص‌ها، جهت یادگیری و توسعه مدل‌های یادگیری ماشین به‌جود آمد.

۳-۳ انتخاب ویژگی

در حوزه توسعه مدل‌های پیش‌بینی‌کننده، به‌ویژه هنگام توسعه یک سیستم هشدار اولیه (EWS)، با توجه به گستردگی داده‌ها، استفاده از انتخاب ویژگی از اهمیت بالایی برخوردار است. هدف اصلی این فرآیند افزایش دقت پیش‌بینی مدل در عین حصول اطمینان از کارایی محاسباتی و کاهش حجم ابعاد مسئله است. یک مجموعه داده،

به‌ویژه مجموعه‌ای به اندازه آنچه در تحلیل‌های مربوط به بازارهای مالی استفاده می‌شود، گستردگی و پیچیدگی بالایی داشته و اغلب حاوی متغیرهای زیادی است. با این حال، همه این متغیرها به طور قابل توجهی به قدرت پیش‌بینی مدل کمک نکرده و ویژگی‌های نامربوط یا زائد می‌توانند منجر به برازش بیش از حد نیز شوند. این موضوع می‌تواند کاربرد عملی مدل را به شدت تضعیف کند. علاوه بر این، کاهش تعداد ویژگی‌ها، مدل را ساده‌تر کرده و تفسیر و درک آن را آسان‌تر می‌کند. در این بخش از پژوهش، جهت انجام انتخاب ویژگی، رویکردی چندلایه استفاده شده است که خلاصه آن را می‌توان در شکل ۵ مشاهده نمود.



شکل ۵. رویکرد چندلایه انتخاب ویژگی

این فرآیند با استفاده از الگوریتم بوروتا که یک روش انتخاب ویژگی مبتنی بر چارچوب جنگل تصادفی است، آغاز شد (کورسا و رودنیک، ۲۰۱۰). این الگوریتم با افزودن ویژگی‌های سایه تصادفی، استحکام مدل را افزایش داده و به طور مکرر مهم‌ترین ویژگی‌ها را شناسایی و حفظ می‌کند.

تکنیک دیگری که به کار گرفته شد، تکنیک لسو^۱ بود که به دلیل کارایی آن در مسائل با ابعاد بالای مجموعه داده شهرت دارد. (تیبشیرانی، ۱۹۹۶). این رویکرد در کاهش بیش‌برازش، که یک چالش رایج در مدل‌سازی مسائل پیش‌بینی به‌شمار می‌رود، کاربردهای فراوان دارد. این الگوریتم مبتنی بر ایجاد جریمه برای ضرایب رگرسیون می‌باشد که منجر به حذف پیش‌بینی‌کننده‌های کمتر مرتبط و در نتیجه افزایش قابلیت تعمیم‌پذیری مدل می‌گردد. در کنار روش‌های فوق، یک انتخاب ویژگی مبتنی بر همبستگی خطی نیز در این پژوهش به کار گرفته شد. این مرحله مربوط به شناسایی ویژگی‌هایی بود که همبستگی خطی قابل توجهی با متغیرهای هدف داشتند. علاوه بر روش‌های فوق، اهمیت ویژگی‌ها با استفاده از مدلی مبتنی بر درخت تصمیم مانند جنگل تصادفی ارزیابی شد.

¹ Least Absolute Shrinkage and Selection Operator

این رویکرد بینشی در مورد اینکه چگونه هر ویژگی بر دقت مدل تأثیر می‌گذارد، ارائه می‌دهد و کارایی آن به‌ویژه در توانایی مدیریت مجموعه داده‌های بزرگ مورد توجه قرار گرفته است.

در مرحله نهایی این بخش، ویژگی‌های انتخاب شده توسط همه روش‌های قبلی در یک سیستم امتیازدهی موزون جامع و ترکیب شده است؛ بدین گونه که در صورت انتخاب یک ویژگی در هر الگوریتم انتخاب ویژگی، ۱ امتیاز به آن تخصیص داده شده است. در نهایت با استفاده از وزن یکسان برای سه الگوریتم لسو، همبستگی خطی و الگوریتم مبتنی بر درخت تصمیم و وزن ۱.۵ برابر برای الگوریتم بروتا، امتیاز موزونی برای هر ویژگی محاسبه شد. سپس یک آستانه امتیاز (برابر با ۳ امتیاز از ۴.۵ امتیاز ممکن) برای نهایی کردن انتخاب مرتبط‌ترین ویژگی‌ها اعمال شد.

۳-۴ حل مسئله ناترازی مجموعه داده‌ها

در مسائل مربوط به پیش‌بینی رویدادهای بحرانی، اغلب یک چالش مهم وجود دارد: عدم تعادل در مجموعه داده‌ها. این عدم تعادل در درجه اول به دلیل ماهیت وقوع رویدادهای بحرانی و تعریف آن است. پراکندگی و نادر بودن آن‌ها منجر به تشکیل مجموعه داده‌ای می‌شود که در آن، تعداد روزهای عادی بسیار بیشتر از روزهایی است که در آن‌ها رویداد بحرانی رخ داده است. این عدم تعادل، مشکلاتی اساسی برای توسعه مدل‌های یادگیری ماشین ایجاد کرده و منجر به سوگیری پیش‌بینی آن‌ها به سمت طبقه داده‌های عادی می‌گردد؛ در نتیجه توانایی مدل برای تشخیص دقیق رویدادهای بحرانی نادر اما حیاتی تضعیف می‌گردد. برای حل این مشکل در این مطالعه، از تکنیک نمونه‌برداری بیش از حد اقلیت مصنوعی (SMOTE) استفاده شد، روشی که توسط چاولا و همکاران (۲۰۰۲) توسعه یافت و به دلیل اثربخشی آن در متعادل کردن توزیع‌های کلاس در مدل‌سازی پیش‌بینی‌کننده به‌وفور مورد استفاده قرار می‌گیرد. در این تکنیک نمونه‌های جدیدی از کلاس اقلیت ترکیب شده و توزیع کلاس‌ها متعادل می‌گردد. این تکنیک به‌ویژه برای مجموعه داده‌هایی که با رویدادهای نادر مانند سقوط بازار سهام همراه هستند مناسب به‌نظر می‌رسد.

۳-۵ توسعه مدل‌های یادگیری ماشین

در این پژوهش، جهت توسعه یک سیستم هشدار زود هنگام (EWS) قوی و موثر برای پیش‌بینی رویدادهای بحرانی در بازارهای سهام، طیف متنوعی از الگوریتم‌های یادگیری ماشین توسعه داده شد. این مدل‌ها شامل رگرسیون لجستیک^۱ (اولسن، ۱۹۸۰)، جنگل‌های تصادفی^۲ (برایمن، ۲۰۰۱)، ماشین‌های بردار پشتیبان^۳ (واپنیک، ۱۹۹۸)، شبکه‌های عصبی مصنوعی^۴ (وربوس، ۱۹۷۷)، درخت تصمیم، تقویت شدید گرادیان^۵، یادگیری تقویتی^۶ و شبکه‌های

^۱ Logistic Regression

^۲ Random Forests

^۳ Support Vector Machines (SVM)

^۴ Neural Networks

^۵ Extreme Gradient Boosting (XGBoost)

^۶ Reinforcement Learning

عصبی حافظه کوتاه مدت طولانی^۱ می باشد. مطابق جست و جوی صورت گرفته، تا کنون پژوهشی از روش های یادگیری تقویتی یا شبکه های عصبی حافظه کوتاه مدت طولانی جهت پیش بینی رویدادهای بحرانی و یا طراحی سیستم هشدار زودهنگام استفاده ننموده است.

در این پژوهش از رویکرد ترکیب پیش بینی انجام شده از هر یک از روش ها استفاده شده که امکان تجزیه و تحلیل جامع را فراهم نموده و از نقاط قوت منحصربه فرد هر الگوریتم در پیش بینی رویدادهای بحرانی بازارهای سهام استفاده می کند. در توسعه هر یک از مدل های مورد اشاره، جهت جلوگیری از بیش برآزش، از روش اعتبارسنجی متقابل k-fold^۲ با ۵ لایه، استفاده شده است.

۳-۵-۱ رگرسیون لجستیک

رگرسیون لجستیک یک الگوریتم جهت پیش بینی مسائلی است که ماهیت طبقه بندی باینری دارند. این مدل بر اساس اصل تخمین احتمالات با استفاده از تابع لجستیک بنا شده است. تابع لجستیک که به عنوان تابع سیگموئید نیز شناخته می شود به صورت زیر تعریف می شود.

$$P(Y = 1) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n)}}$$

که در آن ضرایب رگرسیون می باشند. تابع لجستیک هر مقدار ورودی را به مقداری بین ۰ و ۱ نگاشت می کند و در نتیجه مدلی مناسب برای برای طبقه بندی باینری به شمار می رود؛ از این رو یکی از مدل های مناسب برای مسئله مورد بررسی در این پژوهش به شمار می رود. در این مطالعه از رگرسیون لجستیک منظم استفاده شده است. تکنیک های منظم سازی نقشی حیاتی در کاهش خطر بیش برآزش دارند، که یک نگرانی رایج و اساسی در مدل سازی های مالی، به ویژه در زمان استفاده از داده های با ابعاد بالا به شمار می رود.

۳-۵-۲ درخت تصمیم

درخت های تصمیم، یکی از انواع روش های یادگیری ماشین تحت نظارت هستند که مهارت بالایی در درک روابط پیچیده و غیرخطی داده ها دارند. درخت های تصمیم، شامل مجموعه ای از گره ها (متغیرهای مستقل) و انشعابات (شرایط تقسیم بر اساس رویه سلسله مراتبی متغیرهای مستقل) هستند. دو نوع معروف درخت تصمیم عبارتند از آشکارساز تعامل خودکار کای-دو (CHAID)^۳ و مدل درخت طبقه بندی و رگرسیون (CART)^۴. الگوریتم به کار گرفته در این پژوهش، به علت ماهیت مسئله مورد بررسی، مدل درخت طبقه بندی و رگرسیون (CART) می باشد. یکی از مهم ترین مسائل در به کارگیری مدل های مبتنی بر درخت تصمیم بهینه سازی و تنظیم

¹ Long-Short Term Memory (LSTM) Networks

² K-Fold Cross-Validation

³ Chi-squared Automatic Interaction Detector

⁴ Classification and Regression Tree

هایپارامترهای آن است. جهت انجام این کار در این پژوهش، از یک رویکرد جست‌وجوی شبکه‌ای^۱ استفاده شد و هایپارامترهای مدل درخت تصمیم بر روی طیف وسیعی از مقادیر برای حداکثر عمق درخت، حداقل نمونه در هر شاخه درخت و حداقل نمونه در هر برگ تنظیم و پیکربندی بهینه برای آن به کار گرفته شد.

۳-۵-۳ جنگل‌های تصادفی

جنگل‌های تصادفی مدل توسعه یافته‌ای از الگوریتم‌های درخت تصمیم به‌شمار می‌روند. این مدل یک روش یادگیری گروهی است که در مسائل مربوط به طبقه‌بندی و رگرسیون استفاده زیادی دارد. این الگوریتم، سنگ بنای یادگیری ماشین مدرن به‌شمار می‌رود که توسط لئو برایمن در سال ۲۰۰۱ معرفی شد و توسعه یافت. این روش با ساخت چندین درخت تصمیم در مرحله آموزش و تولید خروجی بر اساس تجمیع این درختان عمل می‌کند. برای مسائل طبقه‌بندی، خروجی کلاسی است که توسط اکثریت درختان انتخاب می‌شود، درحالی‌که در مسائل رگرسیونی، میانگین پیش‌بینی درختان به‌عنوان خروجی توسط الگوریتم معرفی می‌گردد. این رویکرد به‌طور موثری مشکل بیش‌برازش موجود در الگوریتم‌های درخت تصمیم را کاهش داده و دقت و قابلیت اطمینان مدل را افزایش می‌دهد. توسعه جنگل‌های تصادفی توسط برایمن یک جهش قابل توجه در یادگیری ماشین بود، که رویکردی متعادل بین پیچیدگی و تفسیرپذیری ارائه کرد؛ به‌ویژه در زمینه‌هایی مانند مدل‌سازی مالی که درک فرآیند تصمیم‌گیری اساسی به اندازه دقت پیش‌بینی‌ها حیاتی است. درخشش عملکرد فنی جنگل‌های تصادفی را می‌توان منوط به روش ساخت منحصربه‌فرد آن‌ها دانست، چراکه در این روش، هر یک از درختان، بر روی یک نمونه متفاوت از مجموعه داده اصلی آموزش می‌بینند. این تکنیک با نام بگینگ^۲ یا جمع‌بندی بوت‌استرپ شناخته می‌شود. این موضوع، نه تنها تنوع را به اندازه کافی به مدل تزریق می‌کند، بلکه همبستگی بین درختان را کاهش داده و در نتیجه واریانس مدل کاهش می‌یابد. در این پژوهش از جنگل‌های تصادفی برای مقابله با پیچیدگی‌های ذاتی در تجزیه و تحلیل داده‌های مالی استفاده شده است. فرآیند کلی در مدل جنگل‌های تصادفی را می‌توان به‌صورت زیر نمایش داد.

$$RF(x) = \frac{1}{B} \sum_{b=1}^B T_b(x; \theta_b)$$

که در آن $RF(x)$ خروجی جنگل تصادفی برای ورودی x است. هر $T_b(x; \theta_b)$ یک درخت تصمیم، B تعداد کل درختان در جنگل و θ_b پارامترهای تصادفی انتخاب شده مستقل برای هر درخت را نشان می‌دهد. با استفاده از این روش یادگیری گروهی، حجم زیادی از داده‌ها پردازش شده و سعی شد تا روابط غیرخطی به‌طور موثری درک شوند. توانایی این مدل برای مواجهه با تعداد زیادی از متغیرهای ورودی و شناسایی مهم‌ترین پیش‌بینی‌کننده‌ها در مدل‌سازی مالی بسیار مهم است. برای مدل جنگل‌های تصادفی نیز، فرآیند تنظیم هایپارامترهای کلیدی

^۱ Grid Search

^۲ Bagging : Bootstrap Aggregation

شامل تعداد درختان در جنگل، عمق هر درخت و تعداد ویژگی‌های در نظر گرفته شده در هر تقسیم از اهمیت فراوانی برخوردار است. در این مدل نیز جهت پیدا کردن مدل بهینه در مسئله مورد بررسی، از روش جست‌وجوی شبکه‌ای جهت پیدا کردن مقادیر بهینه برای هایپرپارامترهای ذکر شده استفاده شد.

۴-۵-۳ ماشین بردار پشتیبان

ماشین‌های بردار پشتیبان دسته‌ای از مدل‌های یادگیری ماشین نظارت‌شده هستند که هم برای طبقه‌بندی و هم برای رگرسیون استفاده می‌شوند. مبنای کار این الگوریتم، یافتن یک ابرصفحه در یک فضای N بعدی است (N برابر با تعداد ویژگی‌ها یا متغیرهای مستقل است) که به‌طور مشخص داده‌ها را طبقه‌بندی می‌کند. برای تفکیک داده‌ها به طبقه‌های مختلف، ابرصفحه‌های ممکن زیادی وجود دارد که می‌توان انتخاب کرد، اما هدف این الگوریتم، یافتن صفحه‌ای است که بیشترین حاشیه را داشته باشد، یعنی به‌طوری که حداکثر فاصله بین نقاط داده هر دو کلاس در بیشترین حالت ممکن باشد. در مواردی که داده‌ها به صورت خطی قابل تفکیک نیستند، ماشین‌های بردار پشتیبان، از تابع کرنل برای تبدیل داده‌ها به فضایی با ابعاد بالاتر استفاده می‌کند که در آن می‌توان یک ابرصفحه جداکننده پیدا کرد. کرنل‌های رایج مورد استفاده عبارتند از تابع خطی، تابع چندجمله‌ای، تابع پایه شعاعی (RBF) و تابع سیگموئید. هر یک از این توابع مورد استفاده خاص خود را دارد و انتخاب مناسب تابع کرنل تاثیر زیادی بر عملکرد الگوریتم دارد. به‌عنوان مثال توابع کرنل RBF و چند جمله‌ای بیشتر برای داده‌هایی که رفتار غیرخطی دارند مناسب هستند. به بیان ریاضی مدل‌های ماشین بردار پشتیبان را می‌توان به‌صورت زیر نشان داد.

$$\text{Min} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i$$

subject to $y_i(\omega \cdot x_i + b) \geq 1 - \xi_i$ and $\xi_i \geq 0$, for all i

که در آن ξ_i متغیر لنگی^۱ هستند که درجه طبقه‌بندی اشتباه نقطه داده x_i را نشان می‌دهند، ω بردار وزن و C پارامتر منظم‌سازی (هزینه) هستند. مقادیر بالاتر C نشان‌دهنده جریمه بالاتر برای هر نقطه اشتباه طبقه‌بندی شده است و مدل را به سمت راه‌حلی سوق می‌دهد که نقاط داده بیشتری را به درستی طبقه‌بندی کند. توانایی مدیریت داده‌های خطی و غیرخطی، ماشین‌های بردار پشتیبان را به ابزاری ارزشمند در میان الگوریتم‌های مورد استفاده ما در این پژوهش تبدیل می‌کند، چراکه در پیش‌بینی رویدادهای بحرانی بازارهای سهام، با الگوهای پیچیده بازارها سروکار داریم که به‌صورت خطی قابل تفکیک نیستند. در این پژوهش، جهت استفاده از این الگوریتم نیز، تابع کرنل مناسب و هایپرپارامترهایی مانند هزینه (C) و گاما (γ) با استفاده از جست‌وجوی شبکه‌ای گسترده بهینه‌سازی و تنظیم شدند.

^۱ Slack Variable

۵-۳- شبکه‌های عصبی

شبکه‌های عصبی، سنگ بنای حوزه یادگیری ماشینی به‌شمار می‌روند و در شناسایی الگوهای پیچیده و غیرخطی در مجموعه داده‌های بزرگ عملکرد بسیار مناسبی دارند که این موضوع استفاده از آن‌ها را به‌ویژه در تجزیه و تحلیل‌های مربوط به بازارهای مالی مطلوب می‌کند. شبکه‌های عصبی، از لایه‌هایی از گره‌های به‌هم‌پیوسته یا نورون‌ها تشکیل شده‌اند که هر کدام قادر به انجام محاسبات ساده هستند. با ترکیب این محاسبات، شبکه‌های عصبی می‌توانند روابط پیچیده درون داده‌ها را مدل‌سازی کنند. از مزایای استفاده از شبکه‌های عصبی در این پژوهش می‌توان به سازگاری آن‌ها با انواع مختلف داده‌های مالی، چه ساختاریافته و چه بدون ساختار، اشاره نمود. همچنین، توانایی آن‌ها در یادگیری از حجم وسیعی از داده‌ها، آن‌ها را برای درک و مدل‌سازی ظرافت‌هایی که اغلب در بازارهای مالی وجود دارد، ایده‌آل می‌کند.

در پیاده‌سازی این روش در این پژوهش، از کتابخانه‌های کراس و تنسورفلو پایتون استفاده شده است. معماری مدل مورد استفاده در این پژوهش نیز بر مبنای لایه‌های با توابع فعال‌سازی ReLU و سیگموئید، برای مدل‌سازی طبقه‌بندی دودویی مورد استفاده در این پژوهش به‌کار گرفته شده است. جهت جلوگیری از بیش‌برازش در پیاده‌سازی این روش در این پژوهش، از روشی به‌نام چشم‌پوشی^۱ استفاده شد. این روش، یک تکنیک منظم‌سازی است که در شبکه‌های عصبی در طول آموزش به‌صورت تصادفی، زیرمجموعه‌ای از نورون‌ها را در طول شبکه حذف می‌کند. این موضوع به مدل کمک می‌کند تا ویژگی‌های قوی‌تری را آموخته که به هیچ مجموعه خاصی از نورون‌ها وابسته نیستند. تنظیم هاپرپارامترهایی همچون نرخ یادگیری، تعداد نورون‌ها و نرخ چشم‌پوشی نیز با استفاده از جست‌وجوی شبکه‌ای انجام شده است.

۶-۵-۳ تقویت شدید گرادیان (XGBoost)

الگوریتم‌های مبتنی بر تقویت گرادیان^۲، تکنیک‌هایی اساسی و مبتنی بر یادگیری ماشینی گروهی هستند که چندین یادگیرنده ضعیف ($h_i(x)$) را ترکیب می‌کنند تا یک مدل پیش‌بینی قوی ($H(x)$) تشکیل گردد. این فرآیند را می‌توان به صورت زیر نمایش داد.

$$H(x) = \sum_{i=1}^N \alpha_i h_i(x)$$

که در آن، α_i وزنی است که به هر یادگیرنده ضعیف داده شده و N تعداد کل یادگیرندگان ضعیف است. در هر تکرار i ، الگوریتم بر نمونه‌هایی تمرکز می‌کند که توسط $h_{i-1}(x)$ اشتباه طبقه‌بندی شده‌اند و اوزان به‌نحوی تنظیم می‌کند که $h_i(x)$ را برای تصحیح این خطاها هدایت کند. مدل نهایی $H(x)$ جمع وزنی از این یادگیرندگان ضعیف است که برای دستیابی به کمترین خطای ممکن در داده‌های آموزشی بهینه شده است. هر یادگیرنده، که معمولاً

^۱ Dropout^۲ Gradient Boosting

یک درخت تصمیم ساده است، به صورت متوالی به مدل اضافه شده و در هر دور بر اشتباهات مدل قبلی تمرکز می‌گردد. به بیان دیگر، در طی این فرآیند با دادن وزن بیشتر به مشاهداتی که در دورهای قبلی اشتباه طبقه‌بندی شده‌اند، دقت مدل به تدریج بهبود یافته و در نتیجه مدل مجبور به اصلاح این خطاها را در تکرارهای بعدی می‌گردد.

تقویت شدید گرادیان یا XGBoost، یکی از قوی‌ترین الگوریتم‌ها در مدل‌های تقویت گرادیان به‌شمار می‌رود که تکنیک تقویت را با اعمال یک الگوریتم نزول گرادیان را در جهت به حداقل رساندن تابع زیان مورد استفاده در الگوریتم انجام می‌دهد. تابع هدف در این الگوریتم را می‌توان به صورت زیر نمایش داد.

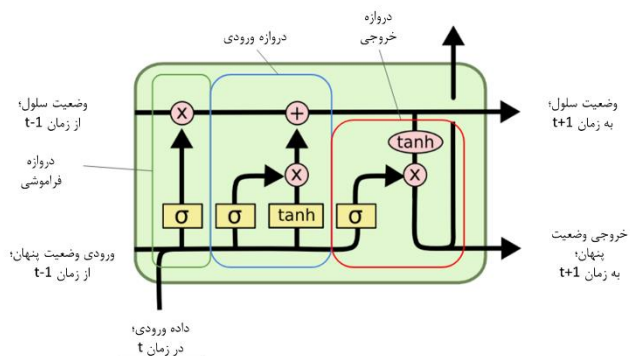
$$\text{Min} \sum_i l(y_i, \hat{y}_i) + \sum_k \Omega(f_k)$$

که در آن، $l(y_i, \hat{y}_i)$ تابع زیان محذب مورد استفاده است که تفاوت بین مقدار پیش‌بینی شده (\hat{y}_i) و مقدار واقعی (y_i) را اندازه‌گیری می‌کند. عبارت $\sum_k \Omega(f_k)$ نیز عبارت منظم‌سازی مورد استفاده در الگوریتم است که مدل را بر اساس میزان پیچیدگی آن برای جلوگیری از بیش‌برازش جریمه می‌کند. این عبارت معمولاً تابعی از تعداد برگ‌ها و امتیازهای روی برگ‌ها در هر درخت در مجموعه درخت‌های مورد استفاده در این الگوریتم است. در این پژوهش، مدل تقویت شدید گرادیان با استفاده از اعتبارسنجی متقاطع با ۵ لایه استفاده شده و همچنین مرحله تنظیم هایپرپارامترها، شامل هایپرپارامترهایی مانند آلفا، گاما، لامبدا، حداکثر عمق با دقت و با استفاده از جست‌وجوی شبکه‌ای انجام شد تا نسبت به عملکرد بهینه این مدل در داده‌های مورد استفاده اطمینان حاصل گردد.

۷-۵-۳ شبکه‌های حافظه‌ی کوتاه‌مدت طولانی

یکی دیگر از روش‌های یادگیری ماشین پیاده‌سازی شده در این پژوهش، شبکه‌های حافظه‌ی کوتاه‌مدت طولانی (LSTM) است. این مدل‌ها گونه‌ای از شبکه‌های عصبی بازگشتی^۱ (RNN) هستند که برای پردازش داده‌های متوالی یا سری زمانی طراحی شده‌اند و در عین حال محدودیت‌های شبکه‌های عصبی بازگشتی سنتی در گرفتن وابستگی‌های بلندمدت را برطرف می‌کنند.

^۱ Recursive Neural Networks



شکل ۶: ساختار سلول‌های LSTM

توانایی مدل‌های LSTM از ساختار سلولی پیچیده آن‌ها نشأت می‌گیرد؛ همان‌گونه که در شکل ۶ نشان داده شده است، این سلول‌ها شامل سلول‌های حافظه متمایز و سه مکانیزم دروازه‌ای است: دروازه ورودی، دروازه خروجی و دروازه فراموشی. هر دروازه عملکرد خاصی را انجام می‌دهد:

✓ **دروازه فراموشی (f_t):** این دروازه تصمیم می‌گیرد که چه اطلاعاتی باید از متغیر وضعیت سلول^۱ حذف شوند. با نگاه کردن به وضعیت پنهان منتقل شده از زمان قبلی (h_{t-1}) و ورودی سلول (x_t)، خروجی صفر و یکی را برای هر یک از اعداد وضعیت C_{t-1} تعیین می‌کند. مقدار ۱ به معنی نگهداشتن اطلاعات و ۰ به معنای فراموشی آن است. این فرایند را می‌توان به صورت رابطه زیر نشان داد.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

که در آن f_t دروازه فراموشی، σ تابع سیگموئید، W_f اوزان دروازه فراموشی و b_f متغیر اربیبی دروازه فراموشی هستند. به طور خلاصه، این فرمول خروجی دروازه فراموشی را در یک سلول LSTM محاسبه می‌کند و تعیین می‌کند که چه مقدار از وضعیت سلول از مرحله زمانی قبلی باید حفظ یا فراموش شود. این مکانیزم بخش کلیدی چیزی است که به LSTMها توانایی مدل‌سازی وابستگی‌های طولانی مدت در داده‌ها را می‌دهد.

✓ **دروازه ورودی (i_t) و به‌روزرسانی وضعیت سلول (\tilde{C}_t):** دروازه ورودی تصمیم می‌گیرد که کدام مقادیر در متغیرهای وضعیت سلول به‌روزرسانی گردند. به طور هم‌زمان، یک بردار از مقادیر کاندید جدید (\tilde{C}_t) ایجاد می‌شود که می‌تواند به وضعیت اضافه شود.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C)$$

^۱ Cell State

✓ وضعیت نهایی سلول (C_t): وضعیت قدیمی سلول (C_{t-1}) به وضعیت جدید C_t به روزسانی می‌گردد. به این صورت که بردار وضعیت قبلی در خروجی دروازه فراموشی ضرب شده و سپس خروجی دروازه ورودی به آن اضافه می‌گردد.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

✓ دروازه خروجی (O_t) و وضعیت پنهان (h_t): دروازه خروجی تصمیم می‌گیرد که وضعیت پنهان بعدی چگونه باشد. وضعیت سلول از طریق تانژانت هیپربولیک (جهت قرار دادن مقادیر بین -1 و 1) در خروجی دروازه خروجی ضرب شده و تعیین می‌کند که چه بخش‌هایی از وضعیت سلول به خروجی برسد.

$$O_t = \sigma(W_{O_0} \cdot [h_{t-1}, x_t] + b_{O_0})$$

$$h_t = O_t * \tanh(C_t)$$

در پیاده‌سازی و به‌کارگیری مدل LSTM برای پیش‌بینی رویدادهای بحرانی بازارهای سهام، معماری این شبکه به‌طور دقیق با لایه‌های متعدد LSTM که هر کدام از تعداد خاصی از واحدهای LSTM تشکیل شده‌اند، ساخته شد. هابپر پارامترهای کلیدی مانند تعداد واحدهای LSTM در هر لایه، تعداد لایه‌ها و نرخ یادگیری نیز با استفاده از جست‌وجوی شبکه‌ای تنظیم شده‌اند تا توانایی مدل برای مدلسازی و یادگیری پویایی‌های زمانی پیچیده ذاتی در داده‌های بازارهای مالی را افزایش دهند.

۸-۵-۳ یادگیری تقویتی

یادگیری تقویتی، شاخه‌ای محوری از روش‌های یادگیری ماشین است که بر الگوریتم‌های آموزشی متمرکز می‌کند؛ تا با تعامل با یک محیط برای رسیدن به یک هدف خاص، دنباله‌ای از تصمیمات را اتخاذ کند. تفاوت آن با روش‌های مبتنی بر یادگیری تحت نظارت در این است که پاسخ‌های صریح در دسترس مدل نبوده و به عامل یادگیری^۱ باید آن‌ها را از طریق آزمون و خطا کشف کرده و توسط پاداش یا مجازات هدایت گردد. اجزای اساسی یک مدل یادگیری تقویتی را عامل، محیط، وضعیت‌ها، اقدامات و پاداش‌ها تشکیل می‌دهند. عامل بر اساس وضعیت فعلی خود در محیط، تصمیماتی گرفته و یا اعمالی را انجام می‌دهد؛ این اقدامات منجر به ایجاد وضعیت‌های جدید شده و جوایز یا مجازات‌های مرتبط با آن نصیب عامل می‌گردد. این فرآیند از طریق یک خط مشی یا استراتژی رسمیت می‌یابد، که عامل برای تعیین اقدامات خود بر اساس وضعیت خود دنبال می‌کند. هدف نهایی در یادگیری ماشین نیز یافتن یک خط مشی یا استراتژی بهینه است که پاداش تجمعی را در طول زمان به حداکثر برساند.

در این پژوهش، سعی شده است تا از یادگیری تقویتی برای توسعه یک سیستم هشدار اولیه برای پیش‌بینی رویدادهای بحرانی بازار سهام استفاده گردد. اساس این مدل حول تعامل یک عامل با محیط خود بنا شده است که

^۱ Agent

با فضای وضعیت (S)، فضای عمل (A) و تابع پاداش (R) توصیف می‌شود. هدف نماینده، یادگیری یک خط مشی (π: S → A) است که پاداش تجمعی مورد انتظار را به حداکثر می‌رساند. جهت استفاده از مدل مورد اشاره در این پژوهش، سعی شده است تا از الگوریتم شبکه عمیق Q¹ استفاده گردد. الگوریتم‌های یادگیری Q، یکی از انواع الگوریتم‌های یادگیری تقویتی بدون مدل هستند که فهم ارزش یک عمل در یک وضعیت خاص را دنبال می‌کنند. این کار با تخمین مطلوبیت مورد انتظار ترکیب وضعیت-عمل، که به‌عنوان ارزش Q² شناخته می‌شود، انجام می‌شود. تابع ارزش Q، که با Q(S,A) نشان داده می‌شود، نشان‌دهنده پاداش تجمعی مورد انتظار از انجام اقدام A در وضعیت S و سپس دنبال کردن سیاست بهینه پس از آن است. شبکه عمیق Q (یا به اختصار DQN) یک نسخه پیشرفته‌تر از یادگیری Q است که از شبکه‌های عصبی عمیق برای تخمین تابع ارزش Q استفاده می‌کند. این امر به ویژه در محیط‌هایی با فضاهای وضعیت بزرگ که عمدتاً روش‌های سنتی غیرعملی می‌شوند مفید واقع می‌شود. در یک DQN، ورودی وضعیت و خروجی مقادیر Q تخمینی برای تمام اقدامات ممکن در آن حالت در نظر گرفته می‌شود. بنابراین، شبکه عصبی به‌عنوان یک تقریب تابع برای تابع ارزش Q عمل می‌کند. در این پژوهش، تابع DQN در نظر گرفته شده را می‌توان به شکل زیر توصیف نمود.

$$Q(s, a) = E[R_t | s_t = s, a_t = a]$$

که در آن $Q(s, a)$ نشان دهنده پاداش مورد انتظار یا R_t در صورت انجام عمل a در وضعیت s با در نظر گرفتن وضعیت‌های آینده است. عامل DQN این تابع Q را با استفاده از یک شبکه عصبی تقریب می‌زند. به بیان بازارهای مالی، وضعیت‌ها (s) نشان دهنده وضعیت بازارهای مالی و عمل (a) نشان دهنده پیش‌بینی وقوع رویداد بحرانی در بازار سهام (وقوع یا عدم وقوع) می‌باشد.

عامل DQN در این پژوهش، مبتنی بر شبکه‌های عصبی متراکم جهت تقریب تابع Q است. حافظه عامل به‌صورت deque³ راه‌اندازی شده است که امکان پخش مجدد تجربه⁴ را فراهم می‌کند؛ تکنیکی که داده‌ها را تصادفی کرده، همبستگی‌ها را حذف نموده و تغییرات در توزیع داده‌ها را هموار می‌کند. فرآیند بهینه‌سازی در این مدل نیز شامل به‌روزرسانی مقادیر Q با استفاده از معادله بلمن است:

$$Q_{new}(s_t, a_t) = R_{t+1} + \gamma \max_a Q(s_{t+1}, a)$$

که در آن γ عامل تنزیلی است که پاداش‌های فوری و آتی را متعادل می‌کند. نرخ یادگیری عامل و ساختار شبکه عصبی، از جمله تعداد لایه‌ها و نورون‌ها، برای درک پیچیدگی و پویایی‌های غیرخطی داده‌های مالی تنظیم شده‌اند. معماری این مدل به‌گونه‌ای تنظیم شده است که به اندازه کافی حساس باشد تا سیگنال‌های ظریف بازار را یاد بگیرد و در عین حال به اندازه کافی قوی باشد تا از بیش‌برازش جلوگیری گردد.

¹ Deep Q-Network(DQN)

² Q-value

³ Double-Ended Queue

⁴ Experience Replay

۳-۶ ترکیب پیش‌بینی‌ها

در موضوع پیچیده‌ای مانند پیش‌بینی بحران‌های بازارهای سهام جهانی، پیچیدگی و تنوع ذاتی این بازارها باعث می‌شود که مدل‌های پیش‌بینی مورد استفاده در این پژوهش به‌تنهایی به اندازه کافی قوی نباشند. هر یک از مدل‌های مورد بررسی در این پژوهش، ممکن است در شرایط خاص بازار از دیگری بهتر عمل کند اما عملکرد آن در سایر مواقع تزلزل پیدا کند. هیچ مدل واحدی به طور کلی در جذب طیف کامل الگوهای نهفته بازار که بیانگر بحران‌های قریب الوقوع هستند، مهارت کافی را ندارد. برای حل این موضوع، در این پژوهش ادغام استراتژی‌های ترکیبی پیش‌بینی با اختصاص وزن‌های متناسب به پیش‌بینی‌های هر مدل و با هدف افزایش عملکرد پیش‌بینی کلی به‌کار گرفته شد. این روش، در پژوهش‌های مختلفی به‌کار گرفته شده است که نشان می‌دهد که تجمیع تکنیک‌های آماری متنوع می‌تواند به‌طور قابل‌توجهی خطاهای پیش‌بینی‌ها را کاهش دهد و ریسک تعیین و به‌کارگیری نادرست مدل را کاهش دهد. (هوتا و همکاران، ۲۰۲۰؛ استوک و واتسون، ۲۰۰۴) در این پژوهش از ۴ روش میانگین‌گیری ساده، میانگین‌گیری با اوزان متغیر، تکنیک بیزین و پشته‌سازی (استفاده از یک متامدل جهت وزن‌دهی) استفاده شده است.

۱-۶-۳ میانگین‌گیری ساده

این روش، یک رویکرد ساده اما مؤثر است که در آن پیش‌بینی نهایی مجموعه مدل مورد استفاده، میانگین پیش‌بینی‌های همه مدل‌ها است. این روش فرض می‌کند که هر مدل به‌طور مساوی به پیش‌بینی نهایی کمک می‌کند. استفاده از میانگین‌گیری ساده به‌عنوان یک روش ترکیب پیش‌بینی‌ها در ادبیات این مباحث وجود دارد. برخی از مطالعات نشان داده‌اند که میانگین‌گیری ساده می‌تواند در زمینه‌های در بهبود پیش‌بینی‌ها و کاهش خطای پیش‌بینی موثر باشد. برای مثال، پالم و زلنر (۱۹۹۲) کاربرد عملی میانگین‌گیری ساده در ترکیب پیش‌بینی را مورد بحث قرار دادند و استفاده تاریخی از آن توسط سازمان‌هایی مانند شرکت بلو چیپ را برجسته کردند. به طور مشابه، رایت (۲۰۰۳) دریافت که میانگین‌گیری ساده پیش‌بینی‌ها از مدل‌های مختلف به طور قابل‌توجهی برای پیش‌بینی خارج از نمونه مفید بوده است. علاوه بر این، رایتر و بولهیس (۲۰۲۰) بر مزایای ترکیب چندین مدل یادگیری ماشین در مجموعه‌ها تاکید کردند که می‌تواند به طور موثر خطاهای پیش‌بینی را کاهش دهد.

۲-۶-۳ میانگین‌گیری با اوزان متغیر

به‌دنبال افزایش دقت مدل‌های پیش‌بینی بحران در این پژوهش، تکنیک پیچیده‌تر میانگین وزنی اجرا شد. این رویکرد امکان ترکیبی دقیق‌تر و مؤثرتر از پیش‌بینی‌های مدل‌های مورد استفاده را فراهم می‌کند (کلمنتز و هاروی، ۲۰۰۹). فرض اساسی میانگین وزنی تخصیص وزن‌های متمایز به پیش‌بینی‌های هر مدل است که عملکرد و اهمیت نسبی آن‌ها را در چارچوب پیش‌بینی کلی منعکس می‌کند. روش مورد استفاده در این پژوهش شامل اکتشاف طیف گسترده‌ای از ترکیبات اوزان برای مدل‌های مختلف به‌کار گرفته شده در مطالعه است. در ابتدا شبکه‌ای از مجموعه‌های بالقوه اوزان تعریف شد و سپس برای هر جایگشت از وزن‌ها در شبکه، میانگین وزنی پیش‌بینی‌های تولید شده توسط هر مدل محاسبه شد. پس پیاده‌سازی این فرایند، اثربخشی هر ترکیب وزنی با استفاده از معیار

عملکرد منحنی مشخصه عملکرد سیستم یا منحنی عملیاتی گیرنده^۱ (ROC) و منطقه زیر منحنی^۲ (AUC) ارزیابی شد. در نهایت مجموعه اوزان بهینه که بالاترین امتیاز ROC-AUC را کسب کرده بود، انتخاب شد.

۳-۶-۳ تکنیک ترکیب مدل بیزین

تکنیک ترکیب مدل بیزین، یک چارچوب احتمالی را برای ادغام پیش‌بینی‌های مدل‌های مختلف معرفی می‌کند. این رویکرد بر اساس اصل استنتاج بیزین است که ترکیبی از پیش‌بینی‌های مدل را با در نظر گرفتن عدم قطعیت و عملکرد هر یک از مدل‌ها امکان‌پذیر می‌کند. این تکنیک، یک چارچوب بر پایه آماری قوی برای یکپارچه‌سازی پیش‌بینی‌های مدل فراهم می‌کند. به طوری که خروجی هر مدل را به عنوان توزیعی از نتایج احتمالی در نظر می‌گیرد، که منعکس‌کننده عدم قطعیت ذاتی در پیش‌بینی، به‌ویژه در حوزه‌های پرنوسان مانند بازارهای سهام است. استفاده از واریانس به عنوان مکانیزم وزندهی با اصل بیزین در به‌روزرسانی اوزان با استفاده از شواهد جدید (عملکرد مدل) همسو می‌شود. در زمینه پیش‌بینی بحران‌های مالی، با توجه به این‌که هزینه تشخیص نادرست مدل می‌تواند بالا باشد، توانایی BMC برای کاهش تعصبات و خطاهای فردی مدل می‌تواند ارزشمند تلقی گردد. این رویکرد به‌طور موثر از نقاط قوت هر مدل به‌صورت بهینه استفاده کرده و مکانیزم آن نهایتاً منجر به پیش‌بینی ترکیبی قابل اعتمادتر و قوی‌تر می‌گردد. انعطاف‌پذیری تکنیک بیزین در مدیریت انواع مختلف مدل‌ها و ظرفیت آن برای انطباق با الگوهای متغیر داده، آن را به ابزاری قدرتمند در پیش‌بینی مالی و ارزیابی ریسک تبدیل می‌کند.

۳-۶-۴ تکنیک پشته‌سازی^۳ (استفاده از متا مدل)

تکنیک پشته‌سازی که به‌عنوان تعمیم انباشته^۴ نیز شناخته می‌شود، یک تکنیک نسبتاً پیچیده‌تر در ترکیب مدل‌های یادگیری ماشین یا یادگیری مجموعه‌ای است که چندین پیش‌بینی چندین مدل را برای بهبود دقت ترکیب می‌کند. در این روش، از پیش‌بینی‌های ایجاد شده توسط مدل‌ها، به‌عنوان ورودی مدل ثانویه (متا مدل) استفاده می‌شود و پیش‌بینی نهایی توسط این متا مدل صورت می‌پذیرد. این رویکرد می‌تواند عملکرد پیش‌بینی را به‌ویژه در حوزه‌های پیچیده‌ای مانند پیش‌بینی‌های حوزه‌های مربوط به بازارهای مالی افزایش دهد. پیاده‌سازی این تکنیک در این پژوهش را می‌توان به این شکل تشریح نمود که ابتدا هر یک از مدل‌های یادگیری ماشین توسعه داده شده (M_i) با استفاده از یک مجموعه داده (D_{train}) آموزش دیده‌اند، سپس پیش‌بینی هر یک از مدل‌ها ($P_i = M_i(D_{train})$) به‌عنوان مجموعه متغیرهای مورد استفاده جهت آموزش لایه دوم یا همان متا مدل به‌کار گرفته شدند. در لایه دوم آموزش متا مدل‌ها بر روی مجموعه داده جدید $D_{meta} = [P_1, P_2, \dots, P_8]$ که از پیش‌بینی‌های لایه اول ایجاد شده بودند صورت پذیرفت. در این مرحله از سه نوع مدل یادگیری ماشین رگرسیون لوجستیک، جنگل تصادفی و تقویت شدید گرادیان (XGBoost) به‌عنوان متا مدل لایه دوم (M_{meta}) استفاده شد. سپس با استفاده از این سه مدل آموزش داده شده و پیش‌بینی‌های نهایی را تولید نمودند.

$$P_{final} = M_{meta}(D_{meta})$$

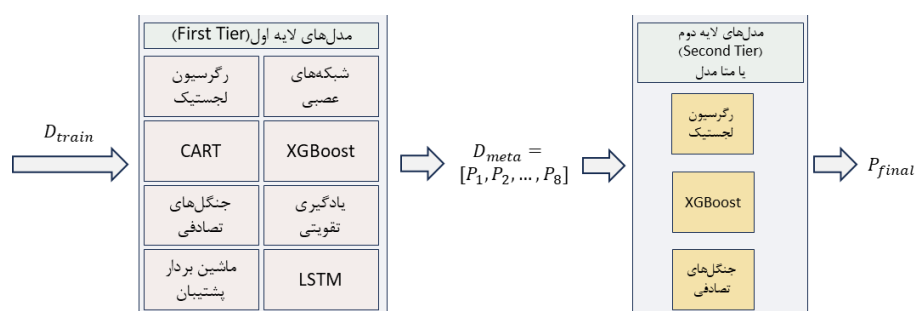
¹ Receiver Operating Characteristic

² Area Under the Curve

³ Stacking

⁴ Stacked Generalization

شکل ۷ این فرایند را به صورت شماتیک نمایش می دهد.



شکل ۷. فرایند شماتیک به کارگیری تکنیک پشته سازی (استفاده از متا مدل)

۴- نتایج پژوهش

در ادبیات مربوط به مدل های پیش بینی کننده در حوزه های مختلف، معیارهای متعددی جهت ارزیابی مدل ها وجود دارد. جهت محاسبه این معیارها، از پارامترهای مربوط به پیش بینی های مدل ها استفاده می شود. با توجه به هدف این پژوهش و توسعه مدل های یادگیری ماشین جهت پیش بینی زود هنگام رویدادهای بحرانی در بازارهای سهام، می توان گفت که میزان تشخیص درست رویدادهای بحرانی یا نرخ اصابت (موفقیت/به هدف زدن)^۱، اصلی ترین برای ارزیابی اثربخشی هر روش و انتخاب قوی ترین روش از نظر قدرت تمایز است. بعد از این معیار، میزان کمتر نرخ سیگنال اشتباهی مدل در عملکرد آن ها تاثیر گذار است. جدول ۱، نمایی کلی از ارزیابی مدل های توسعه یافته بر مبنای این معیار ارائه می دهد؛ در این جدول مدل های توسعه داده شده ابتدا بر اساس نرخ به هدف زدن و سپس بر اساس نرخ سیگنال اشتباهی مرتب شده اند.

جدول ۱. ارزیابی مدل های توسعه داده شده بر اساس نرخ پیش بینی درست رویدادهای بحرانی و نرخ سیگنال اشتباه

سیگنال		مدل
نرخ سیگنال اشتباه (تشخیص اشتباه رویداد بحرانی)	نرخ به هدف زدن (تشخیص درست رویداد بحرانی)	
۱۴.۱۳٪	۹۳.۳۷٪	ترکیب پیش بینی ها - متا مدل جنگل های تصادفی
۱۴.۷۹٪	۹۳.۰۶٪	ترکیب پیش بینی ها - متا مدل XGBoost
۱۴.۵۸٪	۹۲.۶۴٪	جنگل های تصادفی
۱۴.۹۵٪	۹۲.۳۳٪	ترکیب پیش بینی ها - متا مدل رگرسیون لجستیک

^۱ Hit-Rate

سیگنال		مدل
نرخ سیگنال اشتباه (تشخیص اشتباه رویداد بحرانی)	نرخ به هدف زدن (تشخیص درست رویداد بحرانی)	
۱۴.۱۱٪	۹۱.۶۱٪	ترکیب پیش‌بینی‌ها - میانگین‌گیری موزون
۱۳.۸۹٪	۹۱.۴۰٪	یادگیری تقویتی (RL)
۱۴.۵۳٪	۹۱.۱۹٪	تقویت شدید گرادیان (XGBoost)
۱۳.۹۵٪	۹۱.۰۹٪	ترکیب پیش‌بینی‌ها - میانگین‌گیری ساده
۱۳.۷۹٪	۹۰.۷۸٪	شبکه‌های حافظه کوتاه‌مدت طولانی (LSTM)
۱۴.۶۸٪	۹۰.۶۷٪	درخت تصمیم (CART)
۱۴.۲۱٪	۹۰.۱۶٪	شبکه‌های عصبی مصنوعی
۱۴.۳۲٪	۹۰.۱۶٪	ترکیب پیش‌بینی‌ها - تکنیک بیزین
۱۲.۴۲٪	۸۴.۰۴٪	ماشین بردار پشتیبان
۱۰.۷۲٪	۷۳.۲۶٪	رگرسیون لجستیک

همان‌طور که در جدول فوق مشاهده می‌شود، رویکرد ترکیب پیش‌بینی‌ها با استفاده از مدل جنگل تصادفی و پس از آن مدل XGBoost در صدر جدول قرار دارند؛ همچنین ۴ مدل از ۵ مدل برتر، از دسته مدل‌های ترکیبی هستند که این موضوع، حاکی از اثربخشی ترکیب پیش‌بینی‌ها در بهبود کارایی مدل‌های پیش‌بینی‌کننده دارد. همچنین در میان روش‌های ترکیب مدل‌ها، استفاده از تمام‌مدل‌ها یا تکنیک پشته‌سازی بهتر از سایر تکنیک‌ها عمل کرده است.

مدل‌های شبکه حافظه طولانی کوتاه‌مدت (LSTM) و یادگیری تقویتی (RL) نیز علی‌رغم این‌که نتوانسته‌اند رتبه‌های بالایی در تشخیص درست رویدادهای بحرانی داشته باشند، اما نرخ سیگنال اشتباه پایین‌تری نسبت به سایر مدل‌ها داشتند که این موضوع می‌تواند کاربرد بالقوه آن‌ها در شرایطی که کاهش سیگنال‌های اشتباه نیز به اندازه شناسایی رویدادهای واقعی بحرانی حائز اهمیت باشند را نشان دهد.

در ادامه سعی شده است تا مجموعه‌ای از معیارهای ارزیابی ارائه شود که به‌طور گسترده در تحقیقات مربوط به ارزیابی مدل‌های یادگیری ماشین استفاده می‌شوند. عمده این معیارها بر اساس پارامترهای ماتریس درهم‌ریختگی^۱ (تعداد پیش‌بینی درست رویدادهای مثبت (TP) و منفی (TN) و همچنین تعداد پیش‌بینی‌های غلط رویدادهای مثبت (FP) و منفی (FN)^۲) محاسبه می‌شوند.

۱. معیار دقت: تعداد کل پیش‌بینی‌های درست به کل پیش‌بینی‌های صورت گرفته می‌باشد.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

^۱ Confusion Matix

^۲ True Positive (TP), True Negative (TN), False Positive (FP), False Negative (FN)

۲. معیار صحت^۱: تعداد کل پیش‌بینی‌های درست رویدادهای مثبت به کل پیش‌بینی‌های مثبت صورت گرفته می‌باشد.

$$Precision = \frac{TP}{TP + FP}$$

۳. معیار حساسیت (یادآوری)^۲: این معیار را می‌توان در قالب تعداد مثبت‌های واقعی تعریف کرد.

$$Sensitivity(Recall) = \frac{TP}{TP + FN}$$

۴. معیار تشخیص‌پذیری^۳: این معیار را می‌توان به‌عنوان توانایی مدل برای پیش‌بینی درست رویدادهای منفی توصیف کرد. در ادبیات، به تحت عنوان نرخ منفی واقعی نیز شناخته می‌شود.

$$Specificity = \frac{TN}{TN + FP}$$

۵. امتیاز F1: این معیار هر دو مشخصه صحت و یادآوری را توأمان در نظر می‌گیرد و می‌توان آن را با استفاده از رابطه زیر محاسبه نمود.

$$F1 - Score = 2 * \frac{Precision * Recall}{Precision + Recall}$$

۶. میانگین هندسی: این معیار میانگین هندسی حساسیت و تشخیص‌پذیری است و در حقیقت تعادل بین عملکرد مدل در طبقه اکثریت و اقلیت را نشان می‌دهد.

$$G = \sqrt{Sensitivity * Specificity}$$

بر اساس این معیار، عملکرد ضعیف در پیش‌بینی موارد مثبت منجر به مقدار میانگین هندسی پایین می‌شود، حتی اگر موارد منفی به‌درستی توسط مدل شناسایی شده باشند.

۷. نسبت‌های درست‌نمایی مثبت و منفی^۴: نسبت درست‌نمایی مثبت نشان دهنده نسبت احتمال پیش‌بینی مثبت یک رویداد در زمانی که واقعا مثبت است به احتمال پیش‌بینی یک نمونه به‌عنوان مثبت، زمانی که واقعا مثبت نیست را نشان می‌دهد. به همین ترتیب، نسبت درست‌نمایی منفی نیز نسبت بین احتمال پیش‌بینی یک مورد به‌عنوان منفی در زمانی که واقعا مثبت است به احتمال پیش‌بینی آن به‌عنوان منفی در صورتی که واقعا منفی است را نشان می‌دهد.

$$LP = \frac{Sensitivity}{1 - Specificity}, LR = \frac{1 - Sensitivity}{Specificity}$$

¹ Precision

² Sensitivity(Recall)

³ Specificity

⁴ LP: Positive Likelihood Ratio, LR: Negative Likelihood Ratio

بدیهی است مقادیر بالاتر LP و مقادیر کمتر LR به معنی عملکرد بهتر مدل می‌باشد.

۸. مساحت زیر منحنی ROC: منطقه زیر منحنی عملیاتی گیرنده (ROC) یک معیار پرکاربرد در ارزیابی مدل‌های یادگیری ماشین به‌ویژه در سناریوهای طبقه‌بندی باینری است. منحنی ROC یک نمایش گرافیکی است که توانایی تشخیص و تمایز یک مدل را نشان می‌دهد. این منحنی نرخ مثبت واقعی در برابر نرخ مثبت کاذب را در تنظیمات آستانه مختلف ترسیم می‌کند. مساحت زیر این منحنی به‌عنوان یک معیار، یک رقم واحد و جامع از شایستگی مدل ارائه می‌دهد. جدول زیر معیارهای محاسبه شده برای هر یک از مدل‌ها را نشان می‌دهد.

جدول ۲. ارزیابی مدل‌های توسعه داده شده بر اساس معیارهای مختلف

مدل	دقت	محت	حسابیت(راآوری)	تشخیص‌پذیری	معیار			مساحت زیر نمودار ROC	
					F1	میانگین هندسی	نسبت درست‌نمایی مثبت نسبت درست‌نمایی منفی		
رگرسیون لجستیک	۰.۷۰۵	۰.۸۴۷	۰.۷۳۳	۰.۶۲۹	۰.۷۸۶	۰.۶۷۹	۱.۹۷۵	۰.۴۲۵	۰.۷۵
درخت تصمیم (CART)	۰.۷۶۶	۰.۸۰۱	۰.۹۰۷	۰.۳۷۱	۰.۸۵۱	۰.۵۸۰	۱.۴۴۲	۰.۲۵۱	۰.۶۸
جنگل‌های تصادفی	۰.۷۸۲	۰.۸۰۶	۰.۹۲۶	۰.۳۷۷	۰.۸۶۲	۰.۵۹۱	۱.۴۸۷	۰.۱۹۵	۰.۷۶
ماشین بردار پشتیبان	۰.۷۵۰	۰.۸۳۳	۰.۸۴۰	۰.۴۹۶	۰.۸۳۳	۰.۶۴۵	۱.۶۶۶	۰.۳۲۲	۰.۷۴
شبکه‌های عصبی مصنوعی	۰.۷۶۹	۰.۸۰۷	۰.۹۰۲	۰.۳۶۷	۰.۸۵۲	۰.۵۹۸	۱.۴۹۵	۰.۲۴۸	۰.۷۳
تقویت شدید گرادین (XGBoost)	۰.۷۷۲	۰.۸۰۴	۰.۹۱۲	۰.۳۸۰	۰.۸۵۵	۰.۵۸۸	۱.۴۷۰	۰.۲۳۲	۰.۷۵
شبکه‌های حافظه کوتاه‌مدت طولانی (LSTM)	۰.۷۷۹	۰.۸۱۴	۰.۹۰۸	۰.۴۲۰	۰.۸۵۸	۰.۶۱۸	۱.۵۶۶	۰.۲۱۹	۰.۷۳
یادگیری تقوینی (RL)	۰.۷۸۲	۰.۸۱۴	۰.۹۱۴	۰.۴۱۴	۰.۸۶۱	۰.۶۱۶	۱.۵۶۱	۰.۲۰۸	۰.۷۱
ترکیب پیش‌بینی‌ها - میانگین‌گیری ساده	۰.۷۷۹	۰.۸۱۲	۰.۹۱۱	۰.۴۱۲	۰.۸۵۹	۰.۶۱۲	۱.۵۴۸	۰.۲۱۷	۰.۷۴
ترکیب پیش‌بینی‌ها - میانگین‌گیری موزون	۰.۷۸۱	۰.۸۱۱	۰.۹۱۶	۰.۴۰۳	۰.۸۶۰	۰.۶۰۸	۱.۵۳۴	۰.۲۰۸	۰.۷۷
ترکیب پیش‌بینی‌ها - تکنیک بیزین	۰.۷۶۷	۰.۸۰۶	۰.۹۰۲	۰.۳۹۱	۰.۸۵۱	۰.۵۹۴	۱.۴۸۱	۰.۲۵۲	۰.۷۴
ترکیب پیش‌بینی‌ها - متا مدل رگرسیون لجستیک	۰.۷۷۴	۰.۸۰۱	۰.۹۲۳	۰.۳۵۷	۰.۸۵۸	۰.۵۷۴	۱.۴۳۵	۰.۲۱۵	۰.۶۴
ترکیب پیش‌بینی‌ها - متا مدل XGBoost	۰.۷۸۲	۰.۸۰۴	۰.۹۲۱	۰.۳۶۵	۰.۸۶۳	۰.۵۸۳	۱.۴۶۶	۰.۱۹۰	۰.۶۵
ترکیب پیش‌بینی‌ها - متا مدل جنگل‌های تصادفی	۰.۷۸۱	۰.۸۰۲	۰.۹۲۴	۰.۳۵۴	۰.۸۶۳	۰.۵۷۵	۱.۴۴۴	۰.۱۸۸	۰.۶۴

همان‌طور که در جدول ۲ مشاهده می‌گردد، هیچ مدلی وجود ندارد که از نظر کلیه معیارها برتری قابل توجهی نسبت به سایر مدل‌ها داشته باشد. هرچند می‌توان ملاحظه نمود که به‌طور کلی عملکرد مدل‌های ترکیبی نسبت به مدل‌های انفرادی در اغلب معیارهای ارزیابی عملکرد بهتر بوده است. همچنین، در میان مدل‌های ترکیبی، رویکرد استفاده از متا مدل XGBoost و متا مدل جنگل‌های تصادفی دارای بهترین عملکردها بوده‌اند.

علاوه بر این، مدل‌های ترکیبی با یکپارچه‌سازی نقاط قوت مدل‌های فردی مختلف، یک مزیت استراتژیک ارائه می‌دهند و در نتیجه ضعف‌های ذاتی هر رویکرد پیش‌بینی‌کننده را کاهش می‌دهند. به‌عنوان مثال، رویکرد استفاده از متا مدل جنگل‌های تصادفی، با بالاترین میزان در معیار یادآوری، نشان می‌دهد که کمترین احتمال را دارد که یک رویداد بحرانی را از دست بدهد؛ این موضوع یک ویژگی بسیار مهم در مدیریت ریسک پیشگیرانه و طراحی سیستم‌های هشدار زودهنگام به‌شمار می‌رود. تکنیک‌های ترکیب پیش‌بینی‌ها، بینش‌های جمعی را از الگوریتم‌های متنوع درک نموده و منجر به ایجاد یک ابزار پیش‌بینی انعطاف‌پذیرتر و قابل اعتمادتر می‌گردند؛ ازین‌رو یکی از

نتایج کلیدی این پژوهش را می‌توان مطلوبیت استفاده از رویکرد ترکیب پیش‌بینی‌ها، به‌خصوص استفاده از مدل‌ها در طراحی سیستم‌های هشدار زود هنگام دانست.

۵- بحث و بررسی

این پژوهش با هدف افزایش قدرت پیش‌بینی رویدادهای بحرانی در بازارهای سهام و طراحی یک سیستم هشدار زود هنگام جهت تشخیص آن‌ها و از طریق بهره‌گیری از الگوریتم‌های یادگیری ماشین صورت پذیرفته است. تحلیل‌های انجام شده در این پژوهش نشان می‌دهد که مدل‌های ترکیبی، که از توانایی‌های مختلف الگوریتم‌های پیش‌بینی بهره می‌برند، می‌توانند دقت پیش‌بینی‌های انجام شده را به‌طور قابل توجهی افزایش دهند. این ویژگی مدل‌ها به‌ویژه در مواجهه با داده‌های پیچیده و متغیر مربوط به بازارهای مالی که می‌توانند حاوی اطلاعات مهمی برای شناسایی رویدادهای بحرانی احتمالی باشند، ارزشمند به‌شمار می‌روند. همچنین در میان مدل‌های ترکیبی بررسی شده، مشاهده شد که رویکرد پشته‌سازی و استفاده از متامدل‌هایی همچون XGBoost و جنگل‌های تصادفی جهت ترکیب پیش‌بینی‌های مدل‌های یادگیری ماشین، عملکرد بهتری نسبت به سایر مدل‌های ترکیبی از جمله تکنیک ترکیب مدل‌های بیزین و میانگین‌گیری‌های ساده و موزون دارد.

در راستای بهبود قابلیت‌های پیش‌بینی رویدادهای بحرانی در بازارهای سهام و توسعه سیستم‌های هشدار زود هنگام مؤثرتر، پیشنهادات تکمیلی زیر برای تحقیقات و پژوهش‌های آتی ارائه می‌شود.

استفاده از منابع داده‌ای از جنس زبان طبیعی و تحلیل احساسات؛ استفاده از داده‌های چندمنبعی می‌تواند دیدگاه جامع‌تری در تحلیل بازارهای مالی ارائه دهد. ادغام داده‌های متنوع شامل داده‌های مالی، اخبار اقتصادی، و تحلیل‌های احساسی سرمایه‌گذاران می‌تواند به شناسایی الگوهای پیچیده‌تر و تحلیل دقیق‌تر روندهای بازار کمک کند. به‌ویژه، پردازش زبان طبیعی (NLP) برای تجزیه و تحلیل محتوای متنی اخبار و گزارش‌های تحلیلی می‌تواند در تشخیص بهتر تأثیرات خبری بر بازار سهام مؤثر باشد. این رویکرد می‌تواند به ساخت مدل‌های پیش‌بینی با قدرت تمایز بالاتر و قابلیت اطمینان بهتر منجر شود.

توسعه سایر الگوریتم‌های یادگیری عمیق؛ الگوریتم‌های یادگیری عمیق پیشرفته‌تری مانند شبکه‌های عصبی پیچشی (CNN)، مکانیزم‌های مبتنی بر توجه (Attention Mechanisms) و شبکه‌های مولد تخصصی (GAN) قابلیت شناسایی الگوهای پیچیده‌تر در داده‌های بازار سهام را دارند. این تکنولوژی‌ها می‌توانند در تحلیل داده‌های زمانی فضایی کاربرد داشته باشند و به تحلیل گران کمک کنند تا تصمیم‌گیری‌های دقیق‌تری داشته باشند. به‌ویژه، کاربرد این الگوریتم‌ها در ترکیب با داده‌های چندمنبعی می‌تواند به ساخت مدل‌های پیش‌بینی بسیار قدرتمندی منجر شود که قادر به تحلیل و پیش‌بینی بهتری از روندهای بازار در شرایط مختلف باشند.

توسعه مدل‌های قابل تفسیر؛ افزایش تفسیرپذیری مدل‌ها از طریق به‌کارگیری تکنیک‌هایی مانند SHAP و LIME، امکان فهم بهتر و شفاف‌سازی تصمیم‌گیری‌های مدل‌های پیش‌بینی را فراهم می‌آورد. این امر به‌ویژه برای سیاست‌گذاران و مدیران سرمایه‌گذاری اهمیت دارد که می‌خواهند دلایل پشت پیش‌بینی‌ها و توصیه‌های مدل را

درک کنند. تفسیرپذیری بالاتر می‌تواند به افزایش اعتماد به مدل‌های پیش‌بینی و استفاده بهینه‌تر از آن‌ها در تصمیم‌گیری‌های مالی منجر شود.

بررسی اثرات رویدادهای جهانی بر بازارهای سهام؛ تحلیل تأثیر رویدادهای جهانی بر بازارهای سهام می‌تواند به درک عمیق‌تری از پویایی‌های بازار و توسعه مدل‌های دقیق‌تر پیش‌بینی منجر شود. تحقیق بر روی چگونگی تأثیر انتخابات بزرگ، تغییرات سیاستی، بحران‌های اقتصادی و سایر رویدادهای مهمی همچون تقویم‌های اقتصادی بر بازدهی و نوسانات بازار سهام می‌تواند به توسعه مدل‌های پیش‌بینی بحران کمک شایان توجهی کند.

فهرست منابع

- اکبرموسوی، سید صالح، سلمانی، بهزاد، حقیقت، جعفر، و اصغرپور، حسین. (۱۴۰۱). پیش‌بینی بحران‌های بانکی: سیستم هشدار زودهنگام پویا. مدل‌سازی اقتصادسنجی، ۱۷(۱) (پیاپی ۲۵)، ۹-۳۸.
- امینی‌راد، مهدی، مهرگان، نادر، جعفری سرشت، داود، شاه‌آبادی، ابوالفضل. (۱۴۰۱). ترجیحات ریسکی و بحران در بورس اوراق بهادار تهران. دانش سرمایه‌گذاری، ۱۱(۴۳)، ۱۴۹-۱۷۰.
- ترابی‌پور، طویی، سادت، سیده صفیه. (۱۴۰۱). روشی جهت پیش‌بینی قیمت سهام بازار بورس تهران مبتنی بر یادگیری عمیق. پدافند الکترونیکی و سایبری، ۱۰(۲)، ۹۱-۱۰۰.
- راعی، رضا، هنردوست، اعظم، عباسیان، عزت‌الله. (۱۴۰۰). محاسبه ارزش در معرض ریسک دنباله با استفاده از مدل EGARCH-Extreme Learning Machine و رویکرد صنعت بیمه. دانش سرمایه‌گذاری، ۱۰(۳۹)، ۱۰۳-۱۲۲.
- غلامیان، الهام، و داوودی، سیدمحمد رضا. (۱۳۹۷). پیش‌بینی روند قیمت در بازار سهام با استفاده از الگوریتم جنگل تصادفی. مهندسی مالی و مدیریت اوراق بهادار (مدیریت پرتفوی)، ۹(۳۵)، ۳۰۱-۳۲۲.
- قلی‌زاده، علیرضا، فلاح شمس، میرفیض، افشار کاظمی، محمد علی. (۱۴۰۰). طراحی سیستم هشدار سریع وقوع بحران مالی در بورس اوراق بهادار تهران با رویکرد درخت تصمیم. دانش سرمایه‌گذاری، ۱۰(۴۰)، ۳۵-۵۵.
- نادمی، یونس، ابونوری، اسمعیل، و علمی، زهرا. (۱۳۹۴). ارائه یک الگوی هشدار پیش از وقوع نوسانات شدید در بازار سهام تهران: رویکرد مارکوف سوئیچینگ گارچ. دانش مالی تحلیل اوراق بهادار (مطالعات مالی)، ۸(۲۸)، ۲۷-۴۰.
- نصرالهی، محمد، یآوری، کاظم، نجارزاده، رضا، و مهرگان، نادر. (۱۳۹۹). طراحی یک سیستم هشدار زودهنگام بحران‌های ارزی در ایران: رویکرد تغییر رژیم مارکوف. سیاست‌گذاری اقتصادی، ۱۲(۲۴)، ۱۰۷-۱۳۸.

نوروزی، مهدیه، محمد پورزندی، محمدابراهیم، و مینویی، مهرزاد. (۱۴۰۱). طراحی سیستم هشدار دهنده حساب قیمتی و بحران مالی در بازار سهام ایران. دانش مالی تحلیل اوراق بهادار (مطالعات مالی)، ۱۴(۵۴)، ۳۷-۴۹.

- Bai, Z., Liu, H., & Wong, W. K. (2009). Enhancement of the applicability of Markowitz's portfolio optimization by utilizing random matrix theory. *Mathematical Finance: An International Journal of Mathematics, Statistics and Financial Economics*, 19(4), 639-667.
- Bhattacharyya, S., Jha, S., Tharakunnel, K., & Westland, J. C. (2011). Data mining for credit card fraud: A comparative study. *Decision support systems*, 50(3), 602-613.
- Bohl, M. T., Kaufmann, P., & Siklos, P. L. (2015). What drove the mid-2000s explosiveness in alternative energy stock prices? Evidence from US, European and global indices. *International Review of Financial Analysis*, 40, 194-206.
- Bolhuis, M. A., & Rayner, B. (2020). *Deus ex machina? A framework for macro forecasting with machine learning*. International Monetary Fund.
- Bolton, R. J., & Hand, D. J. (2001). Unsupervised profiling methods for fraud detection. *Credit scoring and credit control VII*, 235-255.
- Breiman, L. (2001) Random Forests. *Machine Learning*, 45, 5-32.
- Brock, W., Lakonishok, J., & LeBaron, B. (1992). Simple technical trading rules and the stochastic properties of stock returns. *The Journal of finance*, 47(5), 1731-1764.
- Chatzis, S. P., Siakoulis, V., Petropoulos, A., Stavroulakis, E., & Vlachogiannakis, N. (2018). Forecasting stock market crisis events using deep and statistical machine learning techniques. *Expert systems with applications*, 112, 353-371.
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, 16, 321-357.
- Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining* (pp. 785-794).
- Clements, M. P., & Harvey, D. I. (2009). Forecast combination and encompassing. In *Palgrave Handbook of Econometrics: Volume 2: Applied Econometrics* (pp. 169-198). London: Palgrave Macmillan UK.
- Dawood, M., Horsewood, N., & Strobel, F. (2017). Predicting sovereign debt crises: An early warning system approach. *Journal of Financial Stability*, 28, 16-28.
- DeMiguel, V., Garlappi, L., & Uppal, R. (2009). Optimal versus naive diversification: How inefficient is the 1/N portfolio strategy? *The review of Financial studies*, 22(5), 1915-1953.
- Dixon, M., Klabjan, D., & Bang, J. H. (2017). Classification-based financial markets prediction using deep neural networks. *Algorithmic Finance*, 6(3-4), 67-77.
- Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica: Journal of the econometric society*, 987-1007.
- Fama, E. F., & French, K. R. (1992). The cross-section of expected stock returns. *the Journal of Finance*, 47(2), 427-465.
- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European journal of operational research*, 270(2), 654-669.
- Hamid, S. A., & Iqbal, Z. (2004). Using neural networks for forecasting volatility of S&P 500 Index futures prices. *Journal of Business Research*, 57(10), 1116-1125.
- Hansen, K. B. (2021). Financial contagion: problems of proximity and connectivity in financial markets. *Journal of Cultural Economy*, 14(4), 388-402.
- Hansen, K. B. (2021). Financial contagion: problems of proximity and connectivity in financial markets. *Journal of Cultural Economy*, 14(4), 388-402.

- Heaton, J. B., Polson, N. G., & Witte, J. H. (2017). Deep learning for finance: deep portfolios. *Applied Stochastic Models in Business and Industry*, 33(1), 3-12.
- Hota, S., Jena, S. K., Gupta, B. K., & Mishra, D. (2021). An empirical comparative analysis of NAV forecasting using machine learning techniques. In *Intelligent and Cloud Computing: Proceedings of ICICC 2019, Volume 2* (pp. 565-572). Springer Singapore.
- Hsu, M. W., Lessmann, S., Sung, M. C., Ma, T., & Johnson, J. E. (2016). Bridging the divide in financial market forecasting: machine learners vs. financial economists. *Expert systems with Applications*, 61, 215-234.
- Huang, W., Nakamori, Y., & Wang, S. Y. (2005). Forecasting stock market movement direction with support vector machine. *Computers & operations research*, 32(10), 2513-2522.
- Jia, H. (2021). Deep learning algorithm-based financial prediction models. *Complexity*, 2021, 1-9.
- Jiang, Z., Xu, D., & Liang, J. (2017). A deep reinforcement learning framework for the financial portfolio management problem. *arXiv preprint arXiv:1706.10059*.
- Jung, D., Dörner, V., Glaser, F., & Morana, S. (2018). Robo-advisory: digitalization and automation of financial advisory. *Business & Information Systems Engineering*, 60, 81-86.
- Kaminsky, G., Lizondo, S., & Reinhart, C. M. (1998). Leading indicators of currency crises. *Staff Papers*, 45(1), 1-48.
- Kara, Y., Boyacıoğlu, M. A., & Baykan, Ö. K. (2011). Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. *Expert systems with Applications*, 38(5), 5311-5319.
- Khandani, A. E., Kim, A. J., & Lo, A. W. (2010). Consumer credit-risk models via machine-learning algorithms. *Journal of Banking & Finance*, 34(11), 2767-2787.
- Kim, K. J. (2003). Financial time series forecasting using support vector machines. *Neurocomputing*, 55(1-2), 307-319.
- Kimoto, T., Asakawa, K., Yoda, M., & Takeoka, M. (1990, June). Stock market prediction system with modular neural networks. In *1990 IJCNN international joint conference on neural networks* (pp. 1-6). IEEE.
- Kimoto, T., Asakawa, K., Yoda, M., & Takeoka, M. (1990, June). Stock market prediction system with modular neural networks. In *1990 IJCNN international joint conference on neural networks* (pp. 1-6). IEEE.
- Klopotan, I., Zoroja, J., & Meško, M. (2018). Early warning system in business, finance, and economics: Bibliometric and topic analysis. *International Journal of Engineering Business Management*, 10, 1847979018797013.
- Kursa, M. B., & Rudnicki, W. R. (2010). Feature selection with the Boruta package. *Journal of statistical software*, 36, 1-13.
- Lam, J. W. (2016). Robo-advisors: A portfolio management perspective. *Senior thesis, Yale College*, 20.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- 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.
- Li, A., Wu, J., & Liu, Z. (2017). Market manipulation detection based on classification methods. *Procedia Computer Science*, 122, 788-795.
- Lin, C. S., Khan, H. A., Chang, R. Y., & Wang, Y. C. (2008). A new approach to modeling early warning systems for currency crises: Can a machine-learning fuzzy expert system predict the currency crises effectively? *Journal of International Money and Finance*, 27(7), 1098-1121.
- Long, W., Lu, Z., & Cui, L. (2019). Deep learning-based feature engineering for stock price movement prediction. *Knowledge-Based Systems*, 164, 163-173.

- Longin, F. M., & Solnik, B. (2001). Extreme Correlation of International Equity Markets. *Journal of Finance*, 56(2), 649–676.
- Martin, R. (2011). The local geographies of the financial crisis: from the housing bubble to economic recession and beyond. *Journal of economic geography*, 11(4), 587-618.
- McNeil, A. J., & Frey, R. (2000). Estimation of Tail-Related Risk Measures for Heteroscedastic Financial Time Series: an Extreme Value Approach. *Journal of Empirical Finance*, 7(3–4), 271–300.
- Minoiu, C., Kang, C., Subrahmanian, V. S., & Berea, A. (2015). Does financial connectedness predict crises? *Quantitative Finance*, 15(4), 607-624
- Nabipour, M., Nayyeri, P., Jabani, H., Shahab, S., & Mosavi, A. (2020). Predicting stock market trends using machine learning and deep learning algorithms via continuous and binary data; a comparative analysis. *IEEE Access*, 8, 150199-150212.
- Nevmyvaka, Y., Feng, Y., & Kearns, M. (2006, June). Reinforcement learning for optimized trade execution. In *Proceedings of the 23rd international conference on Machine learning* (pp. 673-680).
- Ohlson, J. A. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of accounting research*, 109-131.
- Palm, F. C., & Zellner, A. (1992). To combine or not to combine? Issues of combining forecasts. *Journal of Forecasting*, 11(8), 687-701.
- Perols, J. (2011). Financial statement fraud detection: An analysis of statistical and machine learning algorithms. *Auditing: A Journal of Practice & Theory*, 30(2), 19-50.
- Reinhart, C. M., & Rogoff, K. S. (2009). The aftermath of financial crises. *American Economic Review*, 99(2), 466-472.
- Saracco, F., Di Clemente, R., Gabrielli, A., & Squartini, T. (2016). Detecting early signs of the 2007–2008 crisis in the world trade. *Scientific reports*, 6(1), 30286.
- Sermpinis, G., Theofilatos, K., Karathanasopoulos, A., Georgopoulos, E. F., & Dunis, C. (2013). Forecasting foreign exchange rates with adaptive neural networks using radial-basis functions and particle swarm optimization. *European Journal of Operational Research*, 225(3), 528-540.
- Stock, J. H., & Watson, M. W. (2004). Combination forecasts of output growth in a seven-country data set. *Journal of forecasting*, 23(6), 405-430.
- Tibshirani, R. (1996). Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society Series B: Statistical Methodology*, 58(1), 267-288.
- Vapnik, V. (1999). *The nature of statistical learning theory*. Springer science & business media.
- Werbos, P. (1977). Advanced forecasting methods for global crisis warning and models of intelligence. *General System Yearbook*, 25-38.
- Wright, J. H. (2008). Bayesian model averaging and exchange rate forecasts. *Journal of Econometrics*, 146(2), 329-341.
- Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. *International journal of forecasting*, 14(1), 35-62.

Design and Development of an Early Warning System (EWS) Based on Machine Learning Models to Predict Global Crisis Events in Stock Markets

Ali Namaki

Assistant Professor, Faculty of Accounting and Financial Sciences, University of Tehran, Tehran,
Iran,(Corresponding Author),(AliNamaki@ut.ac.ir).

Reza Eivazlu

Assistant Professor, Faculty of Accounting and Financial Sciences, University of Tehran, Tehran,
Iran.(Eivazlu@ut.ac.ir).

Saeid Falahpour

Associate Professor, Faculty of Accounting and Financial Sciences, University of Tehran, Tehran,
Iran.(Falahpor@ut.ac.ir).

Shahin Ramtinia

Ph.D. Candidate, Faculty of Accounting and Financial Sciences, University of Tehran, Tehran,
Iran.(Shahin.Ramtinnia@ut.ac.ir)

Abstract

In the ever-evolving world of financial markets, the ability to predict stock market crises is of great importance for policymakers and investors. This study aims to present an approach that leverages the power of machine learning-based methods to predict global stock market crisis events. Utilizing a rich dataset that includes daily stock market data from 37 countries, bond data from 30 countries across various maturities, 27 currency pairs, and other influential variables over the period from 1996 to 2021, a prediction mechanism based on various machine learning methods such as decision trees, support vector machines, random forests, neural networks, gradient boosting, deep neural networks, reinforcement learning, and long short-term memory networks was developed. Additionally, to combine their predictions, four approaches were used: simple and weighted averaging, Bayesian technique, and stacking (meta-models).

The evaluation results of the presented models indicate that the performance of the composite models, especially those based on stacking, is superior in predicting global stock market crises compared to individual models. Furthermore, the framework introduced in this study can serve as an early warning system (EWS). Given the complex volatilities and dynamics of financial markets, traditional methods often fail to provide timely warnings, whereas machine learning-based techniques can lead to the identification of subtle patterns and anomalies that precede a crisis event.

Keywords: Crisis Events, Stock Market, Machine Learning, Early Warning Systems(EWS)