



موسسه آموزش عالی زنت شیراز  
پایان نامه کارشناسی ارشد در رشته‌ی  
کامپیوتر – مهندسی نرم افزار

ترکیب تحلیل احساسات و رویکرد مبتنی بر شبکه های عصبی بازگشتی برای تخمین و  
تحلیل رمزارزها

به کوشش  
علی منصورآبادی

استاد راهنما  
امیرحسین راسخ

شهریور ۱۴۰۴

رسالة محمد

به نام خدا

## تعهدنامه

اینجانب علی منصورآبادی به شماره‌ی دانشجویی ۴۰۰۴۳۰۳۰۷ دانشجوی مقطع کارشناسی ارشد تأیید می‌کنم که این پایان‌نامه حاصل پژوهش خودم است و در مواردی که از منابع دیگران استفاده شده، نشانی دقیق و مشخصات کامل آن را نوشته‌ام. همچنین اظهار می‌نمایم که تحقیق و موضوع پایان‌نامه‌ام تکراری نیست و موارد زیر را نیز تعهد می‌کنم:

۱- بدون کسب مجوز موسسه آموزش عالی زند و اجازه از استاد راهنما، تمام یا قسمتی از دستاوردهای پایان‌نامه‌ی خود را در مجامع و رسانه‌های علمی اعم از همایش‌ها و مجلات داخلی و خارجی به صورت مکتوب یا غیرمکتوب منتشر ننمایم.

۲- اسامی افراد خارج از کمیته‌ی پایان‌نامه را بدون اجازه‌ی استاد راهنما به جمع نویسندگان مقاله‌های مستخرج از پایان‌نامه اضافه نکنم.

۳- از درج نشانی یا وابستگی کاری (affiliation) نویسندگان سازمان‌های دیگر (غیر از موسسه آموزش عالی زند) در مقاله‌های مستخرج از پایان‌نامه بدون تأیید استاد راهنما اجتناب نمایم.

همه‌ی حقوق مادی و معنوی این اثر مطابق با آیین‌نامه‌ی مالکیت فکری، متعلق به موسسه آموزش عالی زند است. چنانچه مبادرت به عملی خلاف این تعهدنامه محرز گردد، موسسه زند در هر زمان و به هر نحو مقتضی حق هرگونه اقدام قانونی را در استیفای حقوق خود دارد.

علی منصورآبادی



امضا و تاریخ:

۱۴۰۴/۰۵/۳۰

به نام خدا

ترکیب تحلیل احساسات و رویکرد مبتنی بر شبکه های عصبی بازگشتی برای تخمین و  
تحلیل رمزارزها

به کوشش  
علی منصورآبادی

پایان نامه ی  
ارائه شده به موسسه آموزش عالی زند به عنوان بخشی از فعالیت های تحصیلی لازم  
برای اخذ درجه ی کارشناسی ارشد

در رشته ی  
کامپیوتر – مهندسی نرم افزار

موسسه آموزش عالی زند  
شیراز  
جمهوری اسلامی ایران

ارزیابی کمیته ی پایان نامه، با درجه ی:

دکتر امیر حسین راسخ، استادیار بخش کامپیوتر (استاد راهنما).....  
دکتر علی قرمزیان، استادیار بخش کامپیوتر (استاد مشاور).....  
دکتر ، استادیار بخش کامپیوتر (داور متخصص داخلی).....

شهریور ۱۴۰۴

## تقدیم به:

با نهایت احترام و عشق، این پایان نامه را تقدیم می کنم به:

- خانواده عزیزم که با حمایت بی دریغشان بزرگترین پشتوانه زندگیم بودند.
- دوستان و همکاران صمیمی ام که در تمام طول مسیر همراه من بودند.

## سپاس‌گزاری

بزرگ‌پروردگار را سپاس که به ما استعداد آموختن عطا کردی.

با نهایت احترام، وظیفه خود می‌دانم مراتب سپاس صمیمانه خود را از اساتید ارجمندم، جناب آقای دکتر امیرحسین راسخ، جناب آقای دکتر علی قرمزیان، جناب آقای دکتر محمدرضا اسلامی نژاد و سرکار خانم دکتر بتسابه تنوری که با راهنمایی‌های ارزشمند، همواره پشتیبان بنده بودند، ابراز نمایم.

از خانواده عزیزم که همواره با محبت، صبوری و حمایت بی‌دریغ خود پشتیبان من بودند، صمیمانه قدردانی می‌کنم.

همچنین از دوستان و همکاران گرامی‌ام سرکار خانم مهندس فاطمه تابع، جناب آقای مهندس مجید سعیدی‌زاده، جناب آقای مهندس محمدرضا باقری، جناب آقای مهندس عرفان امیدوار، و جناب آقای مجتبی بهروزی‌نژاد که با دلگرمی‌ها و یاری‌های خود همراهی‌ام کردند، سپاسگزارم.

## چکیده

### ترکیب تحلیل احساسات و رویکرد مبتنی بر شبکه های عصبی بازگشتی برای تخمین و تحلیل رمزارزها

به کوشش  
علی منصورآبادی

بازار ارزهای رمزنگاری شده به دلیل رشد پرشتاب و نوسانات غیرقابل پیش بینی خود، بستر مناسبی برای تحقیقات علمی در حوزه مدل سازی و پیش بینی فراهم ساخته است. این امر موجب شده است که توسعه مدل های پیش بینی به عنوان یکی از محورهای کلیدی در پشتیبانی از تصمیم گیری های سرمایه گذاری و راهنمایی فعالان و محققان بازار مورد توجه قرار گیرد. هدف این تحقیق بررسی ترکیب شبکه های عصبی عمیق بازگشتی در افزایش دقت پیش بینی قیمت ارزهای دیجیتال است. در این تحقیق از ترکیب شبکه های عصبی بازگشتی به صورت باقی مانده استفاده شده است که باعث کاهش مشکلاتی مثل کاهش گرادیان می شود که می تواند دقت را در توالی های طولانی افزایش دهد. برای کسب اطمینان از توانایی روش پیشنهادی از چندین ارزیابی دیجیتال استفاده شده است. روش پیشنهاد شده از داده های تاریخی قیمت و اخبار برای پیش بینی قیمت روز آینده استفاده می کند. برای تحلیل احساسات اخبار از مدل های CryptoBert، FinBert و DistilRoBerta استفاده شده است. نتایج نشان می دهد که مدل پیشنهادی در مقایسه با سایر مدل ها، دقت بالاتری ارائه می دهد. روش پیشنهاد شده در این پایان نامه به حیطه پیش بینی قیمت ارزهای دیجیتال به دلیل استفاده از روش های نوین تحلیل احساسات و برتری روش پیشنهادی در حل مسائل سری زمانی، کمک می کند. نتایج نشان می دهد ترکیب داده های قیمت و تحلیل احساسات اخبار و همچنین استفاده از روش پیشنهاد شده برای پیش بینی، دقت بالایی را ارائه می دهد.

واژگان کلیدی: رمزارزها، شبکه های عصبی بازگشتی، تحلیل احساسات، یادگیری عمیق

## فهرست مطالب

صفحه	عنوان
فصل اول	
۱-۱-۱	مقدمه..... ۲
۱-۲-۱	بیان مساله..... ۷
۱-۳-۱	اهمیت انجام پژوهش و ضرورت تحقیق..... ۸
۱-۴-۱	اهداف پژوهش..... ۱۰
۱-۵-۱	محدودیت های تحقیق..... ۱۰
۱-۵-۱-۱	محدودیت در طرح تحقیق..... ۱۰
۱-۵-۲	محدودیت در اثر بخشی..... ۱۱
۱-۵-۳	محدودیت در جمع آوری داده ها..... ۱۱
۱-۶-۱	جمع بندی..... ۱۲
فصل دوم	
۲-۱-۱	مقدمه..... ۱۴
۲-۲-۱	پیشینه تحقیق..... ۱۴
۲-۳-۱	فرصت ها و شکاف تحقیقاتی..... ۳۰
۲-۴-۱	جمع بندی..... ۳۱
فصل سوم	
۳-۱-۱	مقدمه..... ۳۳
۳-۲-۱	مبانی نظری..... ۳۴
۳-۲-۱-۱	بازارهای مالی..... ۳۴
۳-۲-۲-۱	بازار ارزهای دیجیتال..... ۳۶



۳۷	.....تحلیل بازارهای مالی
۳۸	.....هوش مصنوعی و یادگیری ماشین
۴۰	.....یادگیری عمیق
۴۱	.....۶ پرسپترون چند لایه
۴۲	.....۷ شبکه‌های عصبی کانولوشنی
۴۳	.....۸ شبکه‌های عصبی بازگشتی
۴۵	.....۹ حافظه طولانی کوتاه مدت
۴۶	.....۱۰ حافظه طولانی کوتاه مدت دوطرفه
۴۷	.....۱۱ واحد بازگشتی دروازه‌ای
۴۸	.....۱۲ تحلیل احساسات
۴۹	.....13-2-3 متد های تحلیل احساسات استفاده شده
۵۱	.....۳-۳ معیارهای ارزیابی
۵۳	.....۴-۳ روش پژوهش
۵۳	.....۱-۴-۳ داده‌های تاریخی به همراه سایر ویژگی ها و اندیکاتور
۵۶	.....۲-۴-۳ اخبار
۵۷	.....۳-۴-۳ پیش پردازش داده‌ها
۵۸	.....۴-۴-۳ تحلیل احساسات اخبار
۵۹	.....۵-۴-۳ ترکیب داده‌ها
۵۹	.....۶-۴-۳ مدل‌های پیاده سازی شده برای مقایسه
۶۲	.....۷-۴-۳ مدل پیشنهادی
۶۷	.....۵-۳ جمع بندی

## فصل چهارم

۶۹	.....۱-۴ مقدمه
----	----------------

۴-۲ نتایج و تحلیل ..... ۶۹

۴-۲-۱ ارزش بایننس ..... ۶۹

۴-۲-۲ ارزش اتریوم ..... ۷۲

۴-۳ جمع بندی ..... ۷۵

## فصل پنجم

۵-۱ مقدمه ..... ۷۷

۵-۲ نتیجه گیری ..... ۷۷

۵-۳ پیشنهادها ..... ۷۸

۵-۴ جمع بندی ..... ۷۹

## فهرست جدول‌ها

صفحه	عنوان
۶۰	جدول ۳-۴-۶-۲ - مشخصات مدل‌های یادگیری عمیق
۶۲	جدول ۳-۴-۶-۳ - مدل‌های پیاده‌سازی شده مطالعات با منابع
۶۵	جدول ۳-۴-۷-۱ - هایپرپارامترهای مدل پیشنهادی
72	جدول 4-2-1-1 - مقایسه مدل‌ها در پیش‌بینی رمزارز بایننس
74	جدول 4-2-2-1 - مقایسه مدل‌ها در پیش‌بینی رمزارز اتریوم

## فهرست شکل‌ها

صفحه	عنوان
۵۶	شکل ۱-۱-۴-۳ - نمونه‌ای از داده‌های خام تاریخی اتریوم
۵۷	شکل ۱-۲-۴-۳ - نمونه‌ای از اخبار تحت عنوان cryptocurrency
۵۸	شکل ۱-۴-۴-۳ - نمونه‌ای از تحلیل احساسات اخبار توسط هر سه مدل
۶۶	شکل ۱-۷-۴-۳ - معماری مدل پیشنهادی
۶۹	شکل ۱-۱-۲-۴ - تقسیم بندی داده‌های بایننس
۷۰	شکل ۲-۱-۲-۴ - نمودار همبستگی بایننس
۷۲	شکل ۱-۲-۲-۴ - تقسیم بندی داده‌های اتریوم
۷۳	شکل ۲-۲-۲-۴ - نمودار همبستگی اتریوم

# فصل اول

## کلیات پژوهش

### ۱-۱ مقدمه

بازارهای مالی، به‌ویژه حوزه ارزهای دیجیتال، از پویاترین و پرچالش‌ترین عرصه‌های اقتصادی جهان به شمار می‌روند. نوسانات شدید قیمتی و رفتار غیرخطی این بازارها سبب شده است که پیش‌بینی روند آن‌ها به یکی از پیچیده‌ترین مسائل در حوزه تحلیل داده و تصمیم‌گیری مالی تبدیل شود. بدیهی است که صرف انجام پیش‌بینی کافی نیست؛ چرا که اگر دقت مدل‌های پیش‌بین پائین باشد، نه تنها کمکی به استراتژی‌های معاملاتی نخواهد کرد، بلکه می‌تواند موجب زیان‌های قابل توجه شود. در سال‌های اخیر، پژوهش‌های متعددی در راستای ارائه مدل‌ها و رویکردهای مختلف برای افزایش دقت پیش‌بینی انجام شده است که در ادامه به آن‌ها پرداخته خواهد شد. در این بخش اما تمرکز بر بررسی جامع‌تر ماهیت ارزهای دیجیتال و ویژگی‌های بنیادین بازار آن‌ها خواهد بود.

از زمان معرفی فناوری بلاک‌چین<sup>۱</sup> به‌عنوان بستر اصلی نخستین ارز دیجیتال<sup>۲</sup>، یعنی بیت‌کوین<sup>۳</sup>، دامنه کاربرد این فناوری در بخش‌های گوناگون به‌ویژه در حوزه خدمات مالی به‌طور چشمگیری گسترش یافته است. بلاک‌چین با فراهم‌سازی قابلیت‌هایی همچون غیرمتمرکزسازی<sup>۴</sup>، شفافیت<sup>۵</sup>، امنیت<sup>۶</sup> و نوآوری، زمینه‌ساز تحول عمیق در ساختار و کارکرد نظام‌های مالی گردیده است. در واقع،

---

<sup>۱</sup> blockchain

<sup>۲</sup> cryptocurrencies

<sup>۳</sup> Bitcoin

<sup>۴</sup> decentralization

<sup>۵</sup> Transparency

<sup>۶</sup> Security

عرصه مالی را می‌توان بستر طبیعی بلاک‌چین دانست و ارزش‌های دیجیتال را یکی از موفق‌ترین نمودهای پیاده‌سازی این فناوری به شمار آورد. ارزش‌های دیجیتال مبتنی بر شبکه‌های غیرمتمرکز بلاک‌چین عمل می‌کنند و از این طریق، وابستگی به نهادهای متمرکز مالی از جمله بانک‌ها در مدیریت و تأیید تراکنش‌ها را برطرف می‌سازند. شفافیت ذاتی این فناوری موجب افزایش سطح اعتماد میان مشارکت‌کنندگان در اکوسیستم ارزش‌های دیجیتال شده و همین امر سبب گردیده است که این دارایی‌ها به‌عنوان گزینه‌ای جذاب برای سرمایه‌گذاری در سطح بین‌المللی مطرح شوند. علاوه بر این، ارزش‌های دیجیتال با فراهم کردن امکان تنوع‌بخشی پرتفوی و نقش پوشش‌دهی در برابر نوسانات بازار، ظرفیت قابل‌توجهی در کاهش ریسک سرمایه‌گذاری دارند. ویژگی‌های بنیادین همچون غیرمتمرکز بودن، تغییرناپذیری و امنیت بالا، جایگاه این پدیده را در سطح جهانی تثبیت نموده و موجب جذب روزافزون کاربران و سرمایه‌گذاران در سراسر جهان شده است ( Amirshahi & Lahmiri, ۲۰۲۵ ).

بیت‌کوین به‌عنوان نخستین ارز دیجیتال مبتنی بر فناوری بلاک‌چین، از زمان معرفی تاکنون توجه بسیار گسترده‌ای را در میان پژوهشگران، سرمایه‌گذاران و سیاست‌گذاران اقتصادی به خود جلب کرده است. این ارز دیجیتال بر پایه معماری شبکه‌های همتا به همتا<sup>۷</sup> شکل گرفته و با استفاده از الگوریتم‌های پیچیده ریاضی و رمزنگاری پیشرفته، جایگزینی برای اعتماد به نهادهای واسطه‌ای همچون بانک‌ها و مؤسسات مالی فراهم آورده است. در این سازوکار، تأیید تراکنش‌ها نه به واسطه یک مرجع متمرکز، بلکه به‌صورت جمعی توسط گره‌های شبکه صورت می‌گیرد که این امر باعث افزایش شفافیت، امنیت و مقاومت در برابر دست‌کاری و تقلب شده است. به‌عبارت دیگر، بیت‌کوین توانسته است مفهوم اعتماد را از سطح نهادی به سطح فنی و الگوریتمی منتقل کند. با وجود این نوآوری بنیادین، بازار ارزش‌های دیجیتال همچنان نوپا محسوب می‌شود و علی‌رغم رشد سریع و قابل توجه در سال‌های اخیر، بسیاری از ابعاد آن ناشناخته باقی مانده است. ویژگی‌هایی نظیر نوسانات شدید قیمتی، نبود چارچوب‌های نظارتی شفاف و پیچیدگی در درک سازوکارهای اقتصادی آن، موجب شده است که تحلیل این بازار به یک حوزه پژوهشی جذاب اما پرچالش تبدیل شود. از این منظر، ارزش‌های دیجیتال نه تنها به‌عنوان یک ابزار مالی نوین، بلکه به‌عنوان پدیده‌ای اقتصادی-

---

<sup>۷</sup> Peer to peer network

اجتماعی شناخته می‌شوند که می‌توانند بر سیاست‌های پولی، الگوهای سرمایه‌گذاری و حتی ساختارهای اقتصادی جهانی اثرگذار باشند. با توجه به رشد سریع این بازار و گسترش روزافزون کاربران و سرمایه‌گذاران، نیاز به تحقیقات جامع و نظام‌مند در این زمینه بیش از پیش احساس می‌شود. تحلیل رفتار بازار ارزهای دیجیتال، ارزیابی پایداری آن در برابر بحران‌های مالی، و بررسی پیامدهای آن بر مدیریت ریسک و متنوع‌سازی پرتفوی، از جمله حوزه‌هایی هستند که می‌توانند ارزش افزوده قابل توجهی برای جامعه علمی و تصمیم‌گیرندگان مالی ایجاد کنند. در مجموع، می‌توان گفت که فهم عمیق‌تر از عملکرد بازار ارزهای دیجیتال و پیامدهای اقتصادی آن، ضرورتی اجتناب‌ناپذیر برای توسعه دانش مالی و طراحی راهبردهای سرمایه‌گذاری مؤثر در دنیای معاصر به شمار می‌رود (Kazeminia et al., ۲۰۲۳).

در سال‌های اخیر، با توجه به سرعت بالای جریان اطلاعات و دسترسی به داده‌های پرتکرار، به‌کارگیری تکنیک‌های هوش مصنوعی<sup>۸</sup> و به خصوص یادگیری ماشین<sup>۹</sup> در بازار رمزارزها، به‌ویژه در حوزه پیش‌بینی قیمت، به‌عنوان یکی از مراحل حیاتی در فرآیند تصمیم‌گیری مالی، نظیر بهینه‌سازی پرتفوی، ارزیابی ریسک و معاملات، اهمیت چشمگیری یافته است. با این حال، بازار ارزهای دیجیتال بازاری بسیار پیچیده و ناپایدار است که داده‌های آن به‌شدت ناهمگن<sup>۱۰</sup> بوده و از معادلات پیچیده میان متغیرها تشکیل می‌شود. این پیچیدگی موجب می‌گردد که روش‌های مرسوم یادگیری ماشین در دستیابی به نتایج بهینه با چالش‌های اساسی روبه‌رو شوند. علاوه بر این، نوسان‌پذیری به‌عنوان شاخصی کلیدی برای تغییرات قیمتی، نقشی تعیین‌کننده در تدوین استراتژی‌های معاملاتی و اتخاذ تصمیم‌های سرمایه‌گذاری ایفا می‌کند. از این‌رو، ضرورت توسعه مدل‌هایی که بتوانند بازار رمزارزها را با دقتی هم‌سطح بازار سهام پیش‌بینی نمایند، بیش از پیش آشکار است. به‌ویژه آنکه اطلاع لحظه‌ای از حرکات قیمتی می‌تواند منجر به افزایش سودآوری و کاهش ریسک سرمایه‌گذاری برای سرمایه‌گذاران شود (Oyedele et al., ۲۰۲۳).

---

<sup>۸</sup> Artificial Intelligence

<sup>۹</sup> Machine Learning

<sup>۱۰</sup> Heterogeneous



یادگیری عمیق<sup>۱۱</sup> به عنوان شاخه‌ای پیشرفته از یادگیری ماشین، در سال‌های اخیر به دلیل توانایی چشمگیر خود در مدل‌سازی داده‌های پیچیده و استخراج الگوهای غیرخطی، جایگاهی ویژه در حوزه هوش مصنوعی پیدا کرده است. تفاوت اصلی یادگیری عمیق با روش‌های متعارف یادگیری ماشین در توانایی این الگوریتم‌ها برای کشف سلسله‌مراتبی از ویژگی‌ها نهفته است. در حالی که الگوریتم‌های کلاسیک یادگیری ماشین اغلب نیازمند استخراج ویژگی‌های اولیه به صورت دستی و توسط متخصصان هستند، یادگیری عمیق قادر است به طور خودکار ویژگی‌های ساده تا پیچیده را از داده‌ها استخراج نماید. این امر موجب می‌شود که مدل‌های مبتنی بر یادگیری عمیق، به ویژه در مواجهه با داده‌های حجیم، پربعد و پیچیده، عملکردی بسیار دقیق‌تر و کارآمدتر نسبت به روش‌های سنتی از خود نشان دهند.

فرآیند یادگیری در شبکه‌های عمیق به صورت سلسله‌مراتبی و تدریجی انجام می‌گیرد. در مراحل ابتدایی، لایه‌های اولیه شبکه به استخراج ویژگی‌های ساده از داده‌ها می‌پردازند، اما با عمیق‌تر شدن لایه‌ها، ویژگی‌های انتزاعی‌تر و پیچیده‌تر استخراج می‌شوند. در این روش، وزن‌های شبکه با استفاده از الگوریتم‌های بهینه‌سازی<sup>۱۲</sup> و براساس بازخورد حاصل از خطای پیش‌بینی به طور مداوم تنظیم می‌شوند تا در نهایت مدل بتواند الگوی مورد انتظار را با دقت بالا شناسایی کند. این امر موجب می‌شود که شبکه‌های عصبی عمیق توانایی درک و بازنمایی روابط بسیار پیچیده و غیرخطی<sup>۱۳</sup> را به دست آورند. به دلیل همین قدرت، یادگیری عمیق در حوزه‌های متعددی به کار گرفته شده و دستاوردهای چشمگیری به همراه داشته است. برخی از کاربردهای بارز آن شامل تشخیص تصویر و ویدئو، شناسایی و پردازش صوت، ترجمه ماشینی، پردازش زبان طبیعی، خودروهای خودران و سیستم‌های هوشمند تصمیم‌یار<sup>۱۴</sup> است. در تمامی این موارد، الگوریتم‌های یادگیری عمیق توانسته‌اند نسبت به روش‌های سنتی برتری معناداری در دقت، انعطاف‌پذیری و قابلیت تعمیم ارائه دهند.

---

<sup>۱۱</sup> Deep Learning

<sup>۱۲</sup> Optimization Algorithms

<sup>۱۳</sup> Nonlinear

<sup>۱۴</sup> Decision Support Systems

یکی از ویژگی‌های کلیدی یادگیری عمیق، توانایی در شناسایی الگوهای پیچیده در داده‌ها است؛ قابلیت‌هایی که آن را به گزینه‌ای بسیار مناسب برای تحلیل و پیش‌بینی سری‌های زمانی پیچیده تبدیل کرده است. بازار ارزهای دیجیتال نمونه بارزی از چنین داده‌هایی به شمار می‌رود، چراکه این بازار دارای نوسانات شدید و الگوهای غیرخطی زیادی است. پیش‌بینی دقیق قیمت ارزهای دیجیتال به دلیل ماهیت غیرایستا و پرنوسان آن‌ها، یکی از چالش‌برانگیزترین مسائل در حوزه مالی محسوب می‌شود. در همین راستا، پژوهش‌های متعددی در سال‌های اخیر نشان داده‌اند که استفاده از شبکه‌های عصبی عمیق می‌تواند در بهبود دقت پیش‌بینی قیمت ارزهای دیجیتال نقش چشمگیری ایفا کند.

از آنجا که بازار ارز دیجیتال ماهیتی سری زمانی دارد، الگوریتم‌های یادگیری عمیق به‌ویژه در ساختارهایی همچون شبکه‌های بازگشتی<sup>۱۵</sup> و نسخه‌های پیشرفته‌تر آن مانند حافظه طولانی کوتاه مدت<sup>۱۶</sup> و واحد بازگشتی دروازه‌ای<sup>۱۷</sup>، توانایی بالایی در شناسایی وابستگی‌های زمانی و الگوهای پنهان نشان داده‌اند. بر همین اساس، در این پایان‌نامه از الگوریتم‌های یادگیری عمیق برای مدل‌سازی و پیش‌بینی قیمت ارزهای دیجیتال بهره گرفته شده است.

تحلیل احساسات<sup>۱۸</sup> یکی از شاخه‌های مهم در حوزه‌ی هوش مصنوعی و پردازش زبان طبیعی<sup>۱۹</sup> است که به بررسی نگرش‌ها، هیجانات و دیدگاه‌های افراد نسبت به موضوعات، رویدادها یا محصولات مختلف می‌پردازد. هدف اصلی این روش، استخراج و شناسایی احساسات مثبت، منفی و یا خنثی در متن‌های نوشته شده توسط کاربران است. به‌کارگیری تحلیل احساسات در صنایع گوناگون، به‌ویژه بازاریابی و مطالعات افکار عمومی، اهمیت ویژه‌ای دارد؛ چراکه با استفاده از آن می‌توان میزان

---

<sup>۱۵</sup> Recurrent Neural Network (RNN)

<sup>۱۶</sup> Long Short-Term Memory (LSTM)

<sup>۱۷</sup> Gated Recurrent Unit (GRU)

<sup>۱۸</sup> Sentiment Analysis (SA)

<sup>۱۹</sup> Natural Language Processing (NLP)

رضایت مشتریان از خدمات و محصولات را ارزیابی و در جهت ارتقای کیفیت تصمیم‌گیری کرد. در زمینه‌ی بازارهای مالی و به‌خصوص ارزشهای دیجیتال، تحلیل احساسات جایگاه برجسته‌ای پیدا کرده است. داده‌های حاصل از اخبار می‌توانند منبع ارزشمندی برای شناسایی دیدگاه عمومی نسبت به یک ارز دیجیتال باشند. پردازش این داده‌ها با استفاده از تکنیک‌های متن‌کاوی<sup>۲۰</sup> و الگوریتم‌های تحلیل متنی، امکان دسته‌بندی<sup>۲۱</sup> نظرات کاربران را فراهم می‌کند و مشخص می‌سازد که گرایش غالب در جامعه مثبت، منفی و یا خنثی است. بر اساس چنین تحلیل‌هایی، می‌توان روند احتمالی تغییرات قیمت ارزشهای دیجیتال را با دقت بیشتری پیش‌بینی کرد. بنابراین، ترکیب مدل‌های هوش مصنوعی با تحلیل احساسات، ابزاری کارآمد برای بهبود پیش‌بینی محسوب می‌شود.

## ۲-۱ بیان مساله

رشد سریع بازار ارزشهای دیجیتال و افزایش روزافزون صرافی‌های فعال در این حوزه، موجب شده است که این دارایی‌ها به‌عنوان یکی از گزینه‌های مهم سرمایه‌گذاری مورد توجه قرار گیرند. از این‌رو، پیش‌بینی قیمت ارزشهای دیجیتال می‌تواند برای سرمایه‌گذاران در جهت تصمیم‌گیری‌های هوشمندانه، برای اقتصاددانان و پژوهشگران در بررسی رفتار بازار و همچنین برای سیاست‌گذاران در اتخاذ تصمیم‌های اثربخش ارزشمند باشد. مسئله‌ی پیش‌بینی قیمت ارزشهای دیجیتال در اصل یک مسئله‌ی سری‌های زمانی محسوب می‌شود. با این حال، مدل‌های سنتی نظیر رگرسیون خطی<sup>۲۲</sup> و مدل‌های خودرگرسیون میانگین متحرک تلفیقی<sup>۲۳</sup> به دلیل ناتوانی در شناسایی الگوهای پیچیده و غیرخطی، کارایی محدودی دارند. به دلیل ماهیت و نوسانات شدید قیمت ارزشهای دیجیتال، بهره‌گیری از روش‌های یادگیری عمیق به‌عنوان رویکردی کلیدی برای حل این مسئله اهمیت ویژه‌ای دارد.

---

<sup>۲۰</sup> Text Mining

<sup>۲۱</sup> Classification

<sup>۲۲</sup> Linear Regression (LR)

<sup>۲۳</sup> AutoRegressive Integrated Moving Average (ARIMA)

در سال‌های اخیر، پژوهش‌های متعددی با استفاده از تکنیک‌های یادگیری عمیق انجام شده است. مدل‌های یادگیری عمیق زیادی از جمله شبکه‌های عصبی کانولوشنی<sup>۲۴</sup> و شبکه‌های عصبی پرسپترون چندلایه<sup>۲۵</sup> بر روی داده‌های تاریخی موجود در پایگاه‌های مانند کگل<sup>۲۶</sup> پیاده شده‌اند (Rathee et al., 2023). همچنین لازم به ذکر است که تاثیر تحلیل احساسات اخبار بر نوسانات این بازار بر کسی پوشیده نیست. امید است، این تحقیق با استفاده از تحلیل احساسات اخبار و پیاده‌سازی مدل یادگیری عمیق بازگشتی باقی‌مانده بر روی داده‌های قیمت، پیش‌بینی ارزش‌های دیجیتال را بهبود دهد.

### ۳-۱ اهمیت انجام پژوهش و ضرورت تحقیق

سرمایه‌گذاری در ارزش‌های دیجیتال به دلایل متعددی از جمله رشد چشمگیر ارزش و پذیرش روزافزون آن‌ها مورد توجه بسیاری از سرمایه‌گذاران و پژوهشگران قرار گرفته است. افزایش قابل ملاحظه‌ای ارزش «بیت‌کوین» به عنوان نخستین ارز دیجیتال و کسب سودهای کلان توسط برخی سرمایه‌گذاران، بیانگر ظرفیت بالای این بازار است. علاوه بر این، تنوع گسترده‌ی رمزارزها، امکان سرمایه‌گذاری در بازاری نوین و پویا، و قابلیت مشارکت در سطح بین‌المللی بدون محدودیت‌های جغرافیایی، از مهم‌ترین مزایای این حوزه به شمار می‌روند. ویژگی فعالیت مداوم و بدون وقفه‌ی بازار در تمام ایام هفته و به صورت ۲۴ ساعته، یکی از جذابیت‌های اصلی آن محسوب می‌شود. همچنین، نوآوری‌های فناوری‌های فناورانه در بستر بلاکچین و کاربردهای مرتبط در زمینه‌هایی مانند تجارت الکترونیک، امنیت اطلاعات و انتقال مالی، نقش بسزایی در افزایش تمایل به سرمایه‌گذاری در این عرصه ایفا می‌کنند.

با وجود این مزایا، باید توجه داشت که ورود به بازار ارزش‌های دیجیتال مستلزم آگاهی کامل از ریسک‌ها و توانایی مدیریت نوسانات شدید است. پویایی بالای این بازار، لزوم برخورداری از دانش

---

<sup>۲۴</sup> Convolutional Neural Network (CNN)

<sup>۲۵</sup> Multi-Layer Perceptron (MLP)

<sup>۲۶</sup> Kaggle

تخصصی و قدرت ریسک‌پذیری مناسب را آشکار می‌سازد. علاوه بر آن، تفاوت قوانین و مقررات کشورها در مواجهه با ارزهای دیجیتال نیز می‌تواند تأثیر مستقیمی بر تصمیم‌گیری‌های سرمایه‌گذاران داشته باشد. از این‌رو، مشاوره‌ی مالی پیش از هرگونه سرمایه‌گذاری در این حوزه امری ضروری تلقی می‌شود. از زمان معرفی «بیت‌کوین» در سال ۲۰۰۹ تاکنون، بازار ارزهای دیجیتال دگرگونی‌های چشمگیری را تجربه کرده است. در ابتدای ظهور، ارزش «بیت‌کوین» ناچیز بود و تنها گروه محدودی از افراد به آن توجه داشتند. نخستین تراکنش تجاری ثبت‌شده در سال ۲۰۱۰، قیمت تقریبی ۰.۰۰۳ دلار را برای هر واحد «بیت‌کوین» رقم زد. در فاصله‌ی سال‌های ۲۰۱۰ و ۲۰۱۱، این بازار رشد سریعی را تجربه کرد و ارزش بیت‌کوین تا بیش از ۳۱ دلار افزایش یافت. روند صعودی در سال ۲۰۱۳ ادامه یافت و قیمت آن از مرز ۱۰۰۰ دلار گذشت. با این حال، بازار به سرعت وارد دوره‌ای از نوسانات شدید شد و ارزش بیت‌کوین طی یک سال به حدود ۲۰۰ دلار کاهش یافت. از سال ۲۰۱۶، روندی باثبات‌تر شکل گرفت و در سال ۲۰۱۷، رشد شتاب‌گونه‌ای مشاهده شد که در دسامبر همان سال، قیمت بیت‌کوین به بیش از ۱۹ هزار دلار رسید. این افزایش نمایی همراه با نوسانات شدید، موج گسترده‌ای از سرمایه‌گذاران را به سمت بازار رمزارزها جذب کرد. بر اساس داده‌های منتشر شده توسط کوین‌مارکت‌کپ<sup>۲۷</sup>، ارزش کل بازار در حال گردش ارزهای دیجیتال در حال حاضر از مرز یک تریلیون دلار عبور کرده است. این امر نشان می‌دهد که بازار ارزهای دیجیتال نه تنها جایگاه قابل توجهی در نظام مالی جهانی پیدا کرده، بلکه به‌عنوان یکی از مهم‌ترین حوزه‌های سرمایه‌گذاری نوین مطرح شده است.

ماهیت پرریسک بازار ارزهای دیجیتال، همراه با نبود دانش کافی و چالش‌های مدیریت سرمایه، موجب شده است که بسیاری از سرمایه‌گذاران بالقوه از ورود به این حوزه اجتناب کنند. در همین راستا، تحقیقات متعددی با هدف کاهش سطح ریسک سرمایه‌گذاری صورت گرفته که یکی از محورهای اصلی آن، پیش‌بینی نوسانات قیمتی ارزهای دیجیتال است. از سوی دیگر، سرمایه‌گذاران مالی به راهکارها و استراتژی‌های کارآمدی نیاز دارند تا بتوانند ریسک‌های ناشی از رفتار پیچیده و غیرقابل پیش‌بینی بازارهای مالی را کنترل کنند. ویژگی‌های غیرخطی در داده‌های قیمتی ارزهای دیجیتال، اثربخشی بسیاری از رویکردهای سنتی در حوزه‌ی پیش‌بینی سری‌های زمانی را محدود

---

<sup>۲۷</sup> CoinMarketCap

ساخته است. در مقابل، به کارگیری روش‌های یادگیری عمیق امکان شناسایی الگوهای پنهان و پیچیده را فراهم می‌سازد و می‌تواند به تدوین استراتژی‌های بهینه برای مدیریت سرمایه منجر شود. با وجود پیشرفت‌های حاصل‌شده، عملکرد مدل‌های پیش‌بینی همچنان جای بهبود دارد.

#### ۴-۱ اهداف پژوهش

همان‌گونه که پیش‌تر اشاره شد، بازار ارزهای دیجیتال با نوسانات شدید و غیرقابل پیش‌بینی همراه است و برآورد دقیق قیمت این دارایی‌ها یکی از چالش‌های اساسی در این حوزه محسوب می‌شود. انجام تحلیل‌ها و پیش‌بینی‌ها به روش‌های دستی و سنتی نیازمند سطح بالایی از دانش تخصصی، تجربه‌ی عملی و مهارت‌های تحلیلی است. دستیابی به این مهارت‌ها مستلزم صرف زمان و هزینه‌ی قابل توجهی است و حتی در صورت کسب این دانش، فرآیند پایش مداوم بازار و بررسی همزمان نمودارهای قیمتی و اخبار مرتبط به‌صورت ۲۴ ساعته و هفت روز هفته، عملاً غیرممکن خواهد بود؛ زیرا حتی برای معامله‌گران حرفه‌ای نیز امکان فعالیت مستمر و بی‌وقفه وجود ندارد.

تعداد بالای رمزارزها، بررسی جامع همه‌ی آن‌ها را ناممکن می‌سازد. بنابراین، وجود یک سامانه‌ی هوشمند که بتواند قیمت‌ها را با دقتی قابل قبول پیش‌بینی کند، به‌شدت ضروری به نظر می‌رسد. در این تحقیق، هدف اصلی طراحی و توسعه‌ی مدلی با بهره‌گیری از الگوریتم‌های نوین یادگیری عمیق و ترکیب آن با یک بخش مکمل تحلیل احساسات است. چنین رویکردی می‌تواند ضمن افزایش دقت پیش‌بینی‌ها، دید جامع‌تری از وضعیت بازار ارائه دهد و راهکاری مؤثر برای تصمیم‌گیری سرمایه‌گذاران در بازار پرنوسان ارزهای دیجیتال فراهم آورد.

#### ۵-۱ محدودیت های تحقیق

##### ۱-۵-۱ محدودیت در طرح تحقیق

برای کاهش خطا و افزایش دقت، لازمه کار پیاده‌سازی و اجرا چندین معماریه سنگین هستیم. به دلیل محدودیت‌های موجود در تهیه و استفاده از سخت‌افزار قوی و همچنین تحریم‌های موجود، نمی‌توان مدل‌های پیچیده را به سرعت و ساده اجرا کرد. لازم به ذکر است

که بخش اخبار و تحلیل احساسات تاثیرات زیادی روی قیمت ارزهای دیجیتال دارند. محدودیت دیگری که برای این پایان نامه وجود دارد این است که شبکه های اجتماعی بزرگی مانند ایکس در دسترس نیست و امکان استفاده از داده های آنها وجود ندارد.

## ۱-۵-۲ محدودیت در اثر بخشی

بسیاری از تحقیق های انجام شده در حیطه پیش بینی قیمت بازارها به صورت کامل معماری مدل ها، سخت افزار مورد استفاده، پایگاه داده های استفاده شده، نحوه پیاده سازی و هایپرپارامترها<sup>۲۸</sup> خود را شرح نداده اند. به دلایل گفته شده، برای مقایسه و بررسی مدل های موجود، باید آنها را پیاده سازی و اجرا کرد. لازم به ذکر است که این محدودیت ممکن است باعث تغییر نتایج بدست آمده در این تحقیق نسبت به چیزی که در تحقیقات آمده است، شود.

## ۱-۵-۳ محدودیت در جمع آوری داده ها

محدودیت های زیادی در جمع آوری داده ها وجود دارد. یکی از راه های بدست آوردن داده های تاریخی، خرید اشتراک از سایت های خارجی زبان است که نیاز به پرداخت ارزی دارد. همچنین داده های تاریخی ارزهای دیجیتال در هر بازه زمانی که نیاز است را نمی توان به راحتی بدست آورد. همچنین پیدا کردن داده ها به صورت رایگان و در فرمت و چهارچوبی که نیاز هست، نیازمند زمان و جست و جو زیادی است. همچنین برای دریافت داده های اخبار نیز محدودیت های زیادی دارند به طور مثال در هر روز فقط می توان یک تعداد داده مشخص را دریافت کرد و همین مقدار کم داده ها نیز صرفا می توانند از یک تعداد سایت خاص دریافت شوند و دسترسی به سایت های تخصصی تر به صورت رایگان امکان ندارد.

---

<sup>۲۸</sup> Hyperparameters

## ۶-۱ جمع بندی

در این فصل به کلیات پژوهش پرداخته شد. به این صورت که ابتدا مقدمه‌ای بر اینکه چرا باید این پژوهش انجام شود ارائه شد، در این فصل کلیات پژوهش مورد بحث قرار گرفت. بدین منظور، ابتدا به تبیین ضرورت و انگیزه‌های انجام تحقیق پرداخته شد تا روشن شود چرا اجرای این پژوهش از اهمیت برخوردار است. سپس مروری بر بازارهای مالی، با تمرکز ویژه بر بازار ارزهای دیجیتال و جایگاه آن در اقتصاد جهانی ارائه گردید و مسئله تحقیق به صورت شفاف بیان شد. در ادامه، پس از تشریح اهمیت موضوع، محدودیت‌های رایج در این حوزه از تحقیقات مورد بررسی قرار گرفت. بر این اساس، در فصل دوم به مرور پیشینه پژوهش‌های مرتبط و مطالعات انجام شده پرداخته خواهد شد. فصل سوم به مبانی نظری و روش‌شناسی تحقیق اختصاص دارد که در آن، علاوه بر معرفی چارچوب نظری، به تشریح الگوریتم‌های یادگیری عمیق، داده‌های به کار رفته، معیارهای ارزیابی و در نهایت معماری پیشنهادی این پژوهش پرداخته می‌شود. در فصل چهارم، نتایج حاصل از پیاده‌سازی مدل‌ها و تحلیل آن‌ها ارائه می‌گردد و در نهایت، فصل پنجم به جمع‌بندی یافته‌ها و ارائه پیشنهادهایی برای تحقیقات آتی اختصاص خواهد یافت.



## فصل دوم

## پیشینه‌ی پژوهش

### ۱-۲ مقدمه

در نظام‌های اقتصادی سنتی، انجام تراکنش‌های مالی عموماً از طریق نهادهای واسطه‌ای نظیر بانک‌ها و مؤسسات مالی صورت می‌گیرد. این نهادها نقش اصلی در پردازش و انتقال وجوه را بر عهده داشته و بر کلیه معاملات اعمال نظارت و کنترل می‌کنند. اگرچه این سامانه‌ها از منظر عملیاتی کارآمد بوده و توانسته‌اند بخش عمده‌ای از نیازهای مالی را پاسخ دهند، اما محدودیت‌های قابل توجهی نیز در آن‌ها وجود دارد. از جمله این محدودیت‌ها می‌توان به سقف مبالغ قابل انتقال، هزینه‌های بالای کارمزد، چالش‌های مرتبط با اعتماد عمومی، آسیب‌پذیری‌های امنیتی و انعطاف‌پذیری پایین اشاره کرد. در طول زمان تلاش‌های متعددی برای توسعه ارزهای مجازی غیرمتمرکز و مستقل از نظارت‌های متمرکز به منظور رفع این کاستی‌ها صورت پذیرفت، اما اغلب این ابتکارات با شکست مواجه شدند. با این وجود، ظهور فناوری بلاک‌چین توانست بخشی از این مشکلات را مرتفع سازد و زمینه‌ساز تحولی اساسی در سامانه‌های مالی گردد. در همین راستا، هدف اصلی این پایان‌نامه پیش‌بینی قیمت ارزهای دیجیتال با استفاده از داده‌های تاریخی و تحلیل احساسات بازار است.

### ۲-۲ پیشینه تحقیق

در این بخش به بررسی تحقیقاتی و مقالاتی پرداخته می‌شود که در سال‌های اخیر در زمینه پیش‌بینی قیمت ارزهای دیجیتال با روش‌های متفاوت منتشر شده‌اند.

التان و همکاران در سال ۲۰۱۹ در تحقیقی (Altan et al., ۲۰۱۹)، نشان داده‌اند که استفاده از یک مدل منفرد برای پیش‌بینی نمی‌تواند دقت بسیار بالایی را تضمین کند. مدل‌های منفرد هرچند دارای نقاط قوتی هستند، اما محدودیت‌هایی نیز دارند و در تمامی شرایط نمی‌توانند بهترین عملکرد پیش‌بینی را ارائه دهند. برای رفع این محدودیت، یک چارچوب ترکیبی-هیبریدی پیش‌بینی برای سری‌های زمانی ارزش‌های دیجیتال پیشنهاد شده است تا دقت پیش‌بینی افزایش یابد. در این پژوهش، یک مدل پیش‌بینی هیبریدی نوین توسعه یافته است که بر پایه شبکه عصبی حافظه طولانی کوتاه‌مدت و تجزیه موجک تجربی<sup>۲۹</sup> به همراه الگوریتم جستجوی کوکو<sup>۳۰</sup> طراحی شده است. این مدل با ترکیب شبکه حافظه طولانی کوتاه‌مدت و تکنیک تجزیه موجک تجربی و بهینه‌سازی خروجی‌های تخمین‌زده شده توسط تابع مد ذاتی<sup>۳۱</sup> با الگوریتم جستجوی کوکو ایجاد شده است. مدل پیشنهادی برای پیش‌بینی قیمت چهار ارز دیجیتال پرمعامله شامل بیت‌کوین، ریپل، دش<sup>۳۲</sup> و لایت‌کوین به کار گرفته شد و عملکرد آن مورد ارزیابی قرار گرفت. نتایج تجربی نشان داد که این مدل هیبریدی قادر است ویژگی‌های غیرخطی سری‌های زمانی ارزش‌های دیجیتال را به خوبی شناسایی کرده و پیش‌بینی دقیق‌تری ارائه دهد.

در سال ۲۰۱۹ جینگ (Jiang, ۲۰۱۹)، در مطالعاتی که انجام داد با تمرکز بر رمزارز بیت‌کوین، به بررسی کارایی شبکه‌های مختلف یادگیری عمیق در پیش‌بینی سری‌های زمانی قیمت پرداخت. در این پژوهش، داده‌های قیمتی بیت‌کوین در بازه زمانی یک دقیقه‌ای گردآوری و سپس به داده‌های ساعتی تبدیل شد که در مجموع بیش از پنجاه و شش هزار رکورد را شامل می‌شد. در فرآیند مدل‌سازی، از بازه‌ی ۲۴ ساعته داده‌ها برای پیش‌بینی قیمت ساعت بعدی استفاده شد. نتایج نشان داد که شبکه عصبی پرسپترون چند لایه به دلیل ناتوانی در ذخیره‌سازی حافظه‌ی روندهای گذشته، برای پیش‌بینی قیمت بیت‌کوین مناسب نیست. در مقابل، به‌کارگیری شبکه عصبی حافظه طولانی کوتاه‌مدت و واحد بازگشتی دروازه‌ای، که قادر به حفظ و پردازش حافظه زمانی هستند، توانستند دقت بالاتری را در پیش‌بینی ارائه دهند. این یافته‌ها نشان می‌دهد که برای تحلیل و پیش‌بینی

---

<sup>۲۹</sup> Empirical Wavelet Transform (EWT)

<sup>۳۰</sup> cuckoo search (CS)

<sup>۳۱</sup> Intrinsic mode function (IMF)

<sup>۳۲</sup> Dash

رمزارزهایی همچون بیت کوین، استفاده از مدل‌های بازگشتی با قابلیت یادگیری وابستگی‌های زمانی، به مراتب کارآمدتر از شبکه‌های پرسپترون ساده است.

در سال ۲۰۱۹ سلیم لاهمیری و همکاران در تحقیقی (Lahmiri & Bekiros, ۲۰۱۹)، از روش‌های یادگیری عمیق برای پیش‌بینی قیمت سه ارز دیجیتال پرمعامله شامل بیت کوین، دیجیتال کش<sup>۳۳</sup> و ریپل استفاده کردند. شبکه‌های عصبی حافظه طولانی کوتاه‌مدت توانایی پیش‌بینی قابل توجهی نسبت به معماری شبکه عصبی رگرسیون تعمیم‌یافته<sup>۳۴</sup> که به عنوان مدل مرجع مورد استفاده قرار گرفت، از خود نشان دادند. مدل شبکه عصبی رگرسیون تعمیم‌یافته نتوانست الگوهای پنهان غیرخطی کلی را به درستی شناسایی کند، زیرا این مدل‌ها بر پایه هسته‌های گاوسی<sup>۳۵</sup> طراحی شده‌اند و تنها برای تقریب محلی سیگنال‌های غیرایستا<sup>۳۶</sup> مناسب‌اند. اگرچه مدل حافظه طولانی کوتاه‌مدت از نظر محاسباتی سنگین‌تر است و بار پردازشی بیشتری نسبت به روش‌های ساده برای شناسایی الگوهای غیرخطی دارد، نتایج نشان داد که یادگیری عمیق به‌طور چشمگیری در پیش‌بینی رفتار نوسانی و غیرخطی بازار ارزهای دیجیتال کارآمد است.

در سال ۲۰۲۰، سلیم لاهمیری با همکارانش (Lahmiri et al., ۲۰۲۰)، با هدف پیش‌بینی حجم معاملات روزانه بیت کوین، یک سیستم ترکیبی<sup>۳۷</sup> مبتنی بر شبکه‌های عصبی مصنوعی ارائه داده است. اگرچه مدل‌های پیش‌بینی ترکیبی در حوزه‌های مختلف به کار گرفته شده‌اند، اما استفاده از آن‌ها برای برآورد حجم معاملات بیت کوین تاکنون به‌طور جدی بررسی نشده بود. در این مطالعه، برای مدل‌سازی، دو شبکه عصبی به کار گرفته شدند: شبکه‌های عصبی با تابع پایه شعاعی<sup>۳۸</sup> که توانایی استخراج الگوهای محلی را دارند، و شبکه‌های عصبی رگرسیون تعمیم‌یافته<sup>۳۹</sup> که قابلیت

---

<sup>۳۳</sup> Bitcoin Cash

<sup>۳۴</sup> Generalized Regression Neural Architecture

<sup>۳۵</sup> Gaussian kernels

<sup>۳۶</sup> Non-stationary Signals

<sup>۳۷</sup> Ensemble

<sup>۳۸</sup> Radial Basis Function Neural Network (RBFNN)

<sup>۳۹</sup> Generalized Regression Neural Networks (GRNN)

شناسایی الگوهای کلی را فراهم می‌کنند. سپس، پیش‌بینی‌های این دو مدل در قالب یک شبکه عصبی پیش‌خور ادغام شده و خروجی نهایی تولید گردید. بدین ترتیب، شبکه عصبی پیش‌خور نقش تلفیق‌کننده‌ای را بر عهده داشته و ترکیب غیرخطی پیش‌بینی‌های محلی و کلی را ممکن ساخته است. نتایج تجربی نشان داد که سیستم ترکیبی پیشنهادی توانسته است خطاهای پیش‌بینی را نسبت به مدل‌های شبکه‌های عصبی با تابع پایه شعاعی و شبکه‌های عصبی رگرسیون تعمیم‌یافته به ترتیب ۱۸٫۸۱ درصد و ۶۲٫۸۶ درصد کاهش دهد. همچنین، در مقایسه با مدل پایه شبکه عصبی پیش‌خور، میزان کاهش خطا به ۹۰٫۴۹ درصد رسیده است. این یافته‌ها بیانگر آن است که استفاده از معماری پیشنهادی ترکیبی نه تنها باعث بهبود دقت پیش‌بینی می‌شود، بلکه به دلیل سرعت و سهولت پیاده‌سازی، گزینه‌ای کارآمد برای تحلیل و پیش‌بینی حجم معاملات روزانه بیت‌کوین محسوب می‌گردد.

در سال ۲۰۲۱، همایل و یوسف‌اودا در تحقیق خود (Hamayel & Owda, ۲۰۲۱)، سه نوع الگوریتم شبکه‌های عصبی بازگشتی برای پیش‌بینی قیمت سه رمزارز اصلی شامل بیت‌کوین، لایت‌کوین و اتریوم مورد استفاده قرار گرفته داده‌اند. نتایج حاصل نشان می‌دهد که مدل‌ها بسته به معیار خطای میانگین درصدی مطلق، دقت بالایی در پیش‌بینی دارند. مقایسه مدل‌ها حاکی از آن است که واحد بازگشتی دروازه‌ای نسبت به مدل حافظه طولانی کوتاه‌مدت و مدل حافظه طولانی کوتاه‌مدت دوطرفه عملکرد بهتری در پیش‌بینی تمامی ارزهای دیجیتال داشته و می‌توان آن را به‌عنوان کارآمدترین الگوریتم معرفی کرد. بر اساس یافته‌ها، واحد بازگشتی دروازه‌ای دقیق‌ترین پیش‌بینی را برای لایت‌کوین ارائه داده است؛ به‌گونه‌ای که مقادیر خطای میانگین درصدی مطلق برای بیت‌کوین، اتریوم و لایت‌کوین به‌ترتیب برابر با ۰.۲۴۵۴ درصد، ۰.۸۲۶۷ درصد و ۰.۲۱۱۶ درصد بوده است. در مقابل، الگوریتم حافظه طولانی کوتاه‌مدت دوطرفه ضعیف‌ترین نتایج را به دست آورده و مقادیر خطای آن برای بیت‌کوین، اتریوم و لایت‌کوین به ترتیب ۵.۹۹۰ درصد، ۶.۸۵ درصد و ۲.۳۳۲ درصد ثبت شده است. به طور کلی، مدل‌های پیشنهادی در این پژوهش توانسته‌اند نتایجی بسیار نزدیک به قیمت واقعی رمزارزها ارائه دهند. اهمیت توسعه چنین مدل‌هایی در آن است که می‌توانند پیامدهای اقتصادی قابل توجهی به همراه داشته باشند و سرمایه‌گذاران و معامله‌گران را در تعیین زمان مناسب خرید و فروش یاری کنند. در راستای کارهای آینده نیز

پیشنهاد می‌شود عوامل دیگری که ممکن است بر تغییرات قیمتی بازار ارزهای دیجیتال تأثیرگذار باشند، همچون رسانه‌های اجتماعی، توییت‌ها و حجم معاملات مورد بررسی قرار گیرند.

ژنگ و همکارانش در سال ۲۰۲۱ (Zhang et al., ۲۰۲۱)، بیان کردند که پس از معرفی بیت‌کوین و سایر سیستم‌های پرداخت همتابه‌همتا مبتنی بر بلاکچین، بازار رمزارزها به سرعت محبوبیت فراوانی کسب کرده است. در نتیجه، نوسانات شدید قیمت رمزارزها توجه زیادی از سوی سرمایه‌گذاران و پژوهشگران به خود جلب کرده است. مدل‌های کنونی پیش‌بینی قیمت رمزارزها بیشتر بر تحلیل عوامل بیرونی مانند شاخص‌های کلان مالی، اطلاعات بلاکچین و داده‌های شبکه‌های اجتماعی متمرکز هستند تا دقت پیش‌بینی افزایش یابد. با این حال، نويزهای درونی ناشی از شرایط بازار و تحولات سیاسی بسیار پیچیده بوده و تفسیر آن دشوار است. با الهام از همبستگی‌های قوی میان رمزارزها و توانایی بالای روش‌های یادگیری عمیق در مدل‌سازی، یک مدل جدید تحت عنوان کانال‌های حافظه وزن‌دهی شده و توجهی<sup>۴۰</sup> برای پیش‌بینی قیمت بسته شدن روزانه و نوسانات رمزارزها ارائه شده است. این مدل شامل سه بخش اصلی است: ماژول حافظه توجهی<sup>۴۱</sup> که ترکیبی از واحد بازگشتی دروازه‌ای و مکانیزم خود-توجهی<sup>۴۲</sup> است، ماژول وزن‌دهی کانال‌ها<sup>۴۳</sup> که وابستگی بین رمزارزهای اصلی را از طریق بازتنظیم وزن‌ها فرا می‌گیرد، و ماژول استخراج ویژگی‌های زمانی محلی مبتنی بر کانولوشن و پولینگ<sup>۴۴</sup> برای افزایش توان تعمیم مدل<sup>۴۵</sup>. برای اعتبارسنجی<sup>۴۶</sup>، مجموعه‌ای از آزمایش‌ها انجام شد که نتایج نشان داد این مدل در مقایسه با مدل‌های پایه، عملکرد بهتری در معیارهای خطا، دقت و سودآوری دارد.

---

<sup>۴۰</sup> Weighted & Attentive Memory Channels

<sup>۴۱</sup> Attentive Memory

<sup>۴۲</sup> Self Attention

<sup>۴۳</sup> Channel-wise Weighting

<sup>۴۴</sup> Pooling

<sup>۴۵</sup> Model Generalization

<sup>۴۶</sup> Evaluation

کانوال و همکارانش در سال ۲۰۲۲ (Kanwal et al., ۲۰۲۲) در یک پژوهش تازه، به دلیل رشد چشمگیر علاقه سرمایه‌گذاران به بازار سهام در سال‌های اخیر، چالش پیش‌بینی دقیق قیمت سهام با توجه به نوسانات بالا و رفتار غیرخطی آن‌ها مورد بررسی قرار گرفته است. پژوهشگران به این نکته اشاره کرده‌اند که داده‌های قیمتی سهام اغلب ناقص، مبهم و پیچیده‌اند و همین امر باعث می‌شود استخراج الگوهای غیرخطی و پنهان برای سرمایه‌گذاران دشوار باشد. برای رفع این مشکل، مدلی نوین با رویکرد ترکیبی مبتنی بر یادگیری عمیق طراحی شد که از ترکیب شبکه عصبی بازگشتی دوجهته مبتنی بر کودا<sup>۴۷</sup> و شبکه عصبی کانولوشنی یک‌بعدی<sup>۴۸</sup> بهره می‌گیرد. این چارچوب ترکیبی، پس از آزمایش روی پنج مجموعه داده واقعی مربوط به قیمت سهام و مقایسه با سایر مدل‌های هیبریدی و مدل‌های پیشرفته موجود، عملکرد بهتری از خود نشان داد. نتایج حاصل نشان می‌دهد که این مدل قادر است با دقت بالا قیمت سهام را پیش‌بینی کرده و به‌عنوان ابزاری مطمئن در تصمیم‌گیری سرمایه‌گذاران و ارتقای بازده سرمایه‌گذاری مورد استفاده قرار گیرد.

اسلام و همکارانش در سال ۲۰۲۲ در تحقیق خود (Aslam et al., ۲۰۲۲) به تحلیل احساسات و همچنین شناسایی هیجانات با استفاده از داده‌های مربوط به توییت‌های مرتبط با ارزهای دیجیتال می‌پردازد؛ توییت‌هایی که به‌طور گسترده برای پیش‌بینی قیمت بازار رمزارزها مورد استفاده قرار می‌گیرند. به‌منظور افزایش کارایی تحلیل، یک مدل ترکیبی یادگیری عمیق از حافظه طولانی کوتاه‌مدت و واحد بازگشتی دروازه‌ای پیشنهاد شده است. در این مدل، خروجی‌های استخراج‌شده توسط حافظه طولانی کوتاه‌مدت به عنوان ورودی برای واحد بازگشتی دروازه‌ای مورد استفاده قرار گرفته و آموزش داده می‌شوند. برای استخراج ویژگی‌ها<sup>۴۹</sup> از روش‌های بسامد واژه-معکوس سند، مدل بردار کلمات<sup>۵۰</sup> و کیف کلمات<sup>۵۱</sup> بهره گرفته شده و چندین الگوریتم یادگیری ماشین و یادگیری عمیق به همراه مدل ترکیبی پیشنهادی مورد ارزیابی قرار گرفته‌اند. افزون بر این، ابزارهای

---

<sup>۴۷</sup> Cuda

<sup>۴۸</sup> 1D Convolutional Neural Network (1D-CNN)

<sup>۴۹</sup> Feature Extraction

<sup>۵۰</sup> Word2Vec

<sup>۵۱</sup> Bag of Words (BoW)

تکست بلاب<sup>۵۲</sup> و تکست توایموشن<sup>۵۳</sup> نیز برای تحلیل هیجان در کنار مدل‌های انتخابی به کار گرفته شده‌اند. نتایج نشان می‌دهد که بخش قابل توجهی از کاربران در مواجهه با ارزش‌های دیجیتال احساس خوشحالی و خرسندی داشته‌اند و پس از آن، هیجانات ترس و شگفتی در رتبه‌های بعدی قرار دارند. از نظر عملکرد، مدل‌های یادگیری ماشین هنگامی که ویژگی‌های کیف‌کلمات استفاده می‌شوند، نتایج بهتری به دست می‌آورند. همچنین، مدل ترکیبی پیشنهادی توانسته است دقت 0.99 در تحلیل احساسات و 0.92 در پیش‌بینی هیجانات به دست آورد که نسبت به مدل‌های یادگیری ماشین و حتی مدل‌های پیشرفته موجود، برتری قابل توجهی دارد.

در سال 2023 ژونگ و همکاران (Zhong et al., 2023)، بررسی کردند که تحقیقات پیشین عمدتاً به بررسی عواملی مانند داده‌های تاریخی معاملات، تحولات اقتصاد کلان و علاقه‌مندی عمومی به ارزش‌های دیجیتال برای پیش‌بینی روند قیمت پرداخته‌اند و نقش روابط میان ارزش‌های دیجیتال را نادیده گرفته‌اند. در واقع، حرکت قیمت یک ارز دیجیتال ممکن است تحت تأثیر تغییرات قیمت سایر ارزها قرار گیرد و بنابراین، در نظر گرفتن روابط بین رمزارزها می‌تواند عملکرد پیش‌بینی را بهبود بخشد. در این مطالعه، یک مدل نوآورانه انتها به انتها<sup>۵۴</sup> برای پیش‌بینی روند قیمت ارائه شده است که از شبکه عصبی حافظه طولانی کوتاه‌مدت و شبکه توجه گراف مبتنی بر روابط<sup>۵۵</sup> استفاده می‌کند، به‌طوری که هم ویژگی‌های فردی هر ارز دیجیتال و هم روابط میان آن‌ها مدنظر قرار گرفته است. به‌طور خاص، ابتدا یک شبکه رمزارزها با استفاده از ویژگی‌های مشترک میان ارزها ساخته شد. سپس، شبکه عصبی حافظه طولانی کوتاه‌مدت برای شناسایی الگوهای دنباله‌ای ویژگی‌های هر ارز دیجیتال به کار گرفته شد. برای استخراج کامل ویژگی‌های شبکه، این مدل طراحی شد تا اطلاعات حاصل از انواع مختلف روابط را جمع‌آوری کند و به‌طور خودکار اهمیت هر رابطه را تشخیص دهد. در نهایت، ویژگی‌های سنتی و شبکه‌ای با یکدیگر ترکیب شده و برای پیش‌بینی روند قیمت مورد استفاده قرار گرفتند. کارایی مدل پیشنهادی با استفاده از داده‌های واقعی بازار

---

<sup>۵۲</sup> TextBlob

<sup>۵۳</sup> Text2Emotion

<sup>۵۴</sup> End-to-End

<sup>۵۵</sup> Relationwise Graph Attention Network (ReGAT)



ارزهای دیجیتال اعتبارسنجی شده است. شبیه‌سازی‌های معاملاتی برای بیت‌کوین و سبدهای سرمایه‌گذاری نشان داد که مدل پیشنهادی بالاترین میزان سوددهی را ارائه می‌دهد.

در تحقیق ژو و همکاران در سال ۲۰۲۳ (Zhou et al., ۲۰۲۳)، ابتدا داده‌های مرتبط با ارزهای دیجیتال از توییت‌ر جمع‌آوری شده و تحلیل احساسات روی توییت‌ها انجام شده و شاخص‌های احساسات استخراج گردید. سپس با استفاده از داده‌های تاریخی معاملات، اطلاعات روزانه گوگل‌ترندز و شاخص‌های احساسات، حرکت قیمت ارزهای دیجیتال با کمک الگوریتم ماشین بردار پشتیبان<sup>۵۶</sup> پیش‌بینی شد. در مرحله بعد، مدلی برای بهینه‌سازی سبد سرمایه‌گذاری ارائه شد و بر اساس آن استراتژی سبد سرمایه‌گذاری استخراج گردید. نتایج تجربی نشان می‌دهد که از یک سو، استفاده از داده‌های چندمنبع توانایی مؤثری در پیش‌بینی حرکات قیمتی ارزهای دیجیتال دارد و از سوی دیگر استراتژی سبد پیشنهادی نسبت به روش‌های سنتی سبد سرمایه‌گذاری از منظر نسبت شارپ<sup>۵۷</sup>، نسبت سورتینو<sup>۵۸</sup> و بازده قطعی<sup>۵۹</sup> در نمونه‌های خارج از مجموعه آموزشی عملکرد بهتری دارد. این یافته‌ها نشان می‌دهد که استراتژی پیشنهادی توانسته است به خوبی اطلاعات گذشته و پیش‌بینی آینده را ترکیب کند.

در تحقیق رائو و همکاران در سال ۲۰۲۳ (Rao et al., ۲۰۲۳)، تمرکز بر ترکیب روش‌های سنتی یادگیری عمیق با الگوریتم‌های پرکاربرد یادگیری تجمعی<sup>۶۰</sup> برای پیش‌بینی قیمت ساعتی رمزارزهای اصلی بوده است. در این تحقیق، مدل‌های متداول یادگیری عمیق شامل شبکه‌های حافظه طولانی کوتاه‌مدت، شبکه‌های حافظه طولانی کوتاه‌مدت دوطرفه و لایه‌های کانولوشنی مورد استفاده قرار گرفتند تا کارایی روش‌های تجمعی پیشنهادی ارزیابی شوند. هدف پژوهش، هم پیش‌بینی عددی قیمت (رگرسیون<sup>۶۱</sup>) و هم پیش‌بینی جهت تغییر قیمت (افزایش یا کاهش نسبت

---

<sup>۵۶</sup> Support Vector Machine (SVM)

<sup>۵۷</sup> Sharp ratio

<sup>۵۸</sup> Sortino ratio

<sup>۵۹</sup> Certainty equivalent

<sup>۶۰</sup> Ensemble Learning

<sup>۶۱</sup> Regression

به زمان حاضر) در قالب یک مسئله طبقه‌بندی بوده است. نتایج آزمایش‌های گسترده نشان داد که ترکیب یادگیری عمیق با روش‌های یادگیری تجمعی می‌تواند منجر به توسعه مدل‌های پیش‌بینی پایدار، دقیق و قابل اعتماد شود.

هدف اصلی پژوهش لیونگ و همکارانش (Leung et al., 2023) در سال 2023، بررسی کارآمدی یک پلتفرم آنلاین معاملات سهام در ارتقای سواد مالی افرادی است که دانش مالی محدودی دارند. در این راستا، یک سیستم هوشمند طراحی شده که با ترکیب تحلیل احساسات در شبکه‌های اجتماعی، سامانه‌های ردیاب قیمت و تکنیک‌های یادگیری ماشین، سیگنال‌های معاملاتی ارزش‌های دیجیتال را تولید می‌کند. این سامانه علاوه بر یک بخش بصری‌سازی قیمت زنده که تغییرات قیمتی رمزارزها را به صورت لحظه‌ای نمایش می‌دهد، دارای یک تابع پیش‌بینی نیز هست که بر اساس امتیاز احساسات توییت‌های روز قبل مربوط به رمزارزها، سیگنال‌های معاملاتی کوتاه‌مدت و بلندمدت را در اختیار کاربر قرار می‌دهد. همچنین، روشی برای بهبود نتایج مدل تحلیل احساسات نیز در این مطالعه پیشنهاد گردیده است. یافته‌های تحقیق نشان می‌دهند که استفاده از داده‌های احساسات موجود در توییت‌ها برای رمزارزها، می‌تواند به شکل مؤثری در تولید سیگنال‌های معاملاتی قابل اعتماد به کار گرفته شود.

سامان کاظم‌نیا، هدیه ساجدی و مسعود ارجمند در تحقیق خود در سال ۲۰۲۳ (Kazeminia et al., ۲۰۲۳) به این نتیجه رسیدند که با توجه به رشد روزافزون اهمیت بازار ارزش‌های دیجیتال و گسترش بسترهای معاملاتی آنلاین، فناوری‌های مرتبط با این حوزه مورد توجه گسترده معامله‌گران، پژوهشگران و تحلیل‌گران قرار گرفته است. در این تحقیق داده‌های تاریخی بیت‌کوین به کار گرفته شد تا با استفاده از یک مدل ترکیبی نوین از ترکیب شبکه عصبی کانولوشنی و حافظه طولانی کوتاه مدت، همراه با تنظیم ابرپارامترها توسط آپتونا<sup>۶۲</sup>، قیمت پایانی<sup>۶۳</sup> روز بعد پیش‌بینی گردد. داده‌های آموزشی این مدل از طریق وب اسکرپینگ<sup>۶۴</sup> گردآوری شد. ارزیابی‌ها نشان داد که مدل پیشنهادی

---

<sup>۶۲</sup> OPTUNA

<sup>۶۳</sup> Close price

<sup>۶۴</sup> Web Scraping

با دستیابی به ضریب تعیین<sup>۶۵</sup> برابر با ۰.۹۸۱۶۶ و خطای میانگین مطلق درصدی<sup>۶۶</sup> معادل ۰.۰۳۴ عملکردی بسیار دقیق داشته است. مقایسه این مدل با سه الگوریتم پرکاربرد دیگر شامل شبکه عصبی کانولوشنی، حافظه طولانی کوتاه مدت و واحد بازگشتی دروازه‌ای بیانگر برتری مدل ترکیبی پیشنهادی در شاخص‌های ضریب تعیین و خطای میانگین مطلق درصدی بود. نتایج حاکی از آن است که این مدل علاوه بر دقت بالا در پیش‌بینی، قابلیت به‌کارگیری در پیش‌بینی‌های بلندمدت را<sup>۶۷</sup> نیز داراست و می‌تواند ابزاری سودمند در تصمیم‌گیری‌های سرمایه‌گذاران باشد.

در سال 2023 علی دگ و همکارانش (Dag et al., 2023)، به این نتیجه رسیدند که در سال‌های اخیر با افزایش محبوبیت فناوری بلاک‌چین و رشد اعتماد سرمایه‌گذاران به بیت‌کوین، افراد زیادی به سرمایه‌گذاری در بیت‌کوین و سایر ارزهای دیجیتال روی آوردند و انتظار کسب بازدهی بالا داشتند. با این حال، نوسانات اخیر بازار نشان داده است که نبود مقررات و نظارت کافی، خطرپذیری بالایی را به همراه داشته و پیش‌بینی‌ناپذیری شدید قیمت‌ها می‌تواند منجر به زیان‌های قابل توجه شود. در این پژوهش رویکردی داده‌محور بر پایه مدل بیز ساده توسعه‌یافته با درخت<sup>۶۸</sup> معرفی شده است که توانایی شناسایی عوامل کلیدی و همچنین روابط شرطی و وابستگی‌های میان آن‌ها در تغییرات قیمتی بیت‌کوین را دارد. این مدل به‌گونه‌ای طراحی شده که در عین سادگی، دقت، حساسیت و ویژگی مطلوبی ارائه می‌دهد و نتایج نشان می‌دهد که از میانگین دقت مناسبی برخوردار است. به همین دلیل، این روش می‌تواند در عمل برای تصمیم‌گیری‌های سرمایه‌گذاری کوتاه‌مدت در بازار رمزارزها به کار گرفته شود.

نیشا راتی و همکاران در سال ۲۰۲۳ (Rathee et al., ۲۰۲۳)، یک مدل ترکیبی پیشرفته مبتنی بر شبکه عصبی با استفاده از شبکه‌های عصبی کانولوشنی و شبکه‌های حافظه طولانی

---

<sup>۶۵</sup> R<sup>2</sup> (R-Squared)

<sup>۶۶</sup> Mean Absolute Percentage Error (MAPE)

<sup>۶۷</sup> Real-Time Forecasting

<sup>۶۸</sup> Tree Augmented Naïve Bayes – TAN

کوتاه‌مدت دوطرفه<sup>۶۹</sup> معرفی کردند که برای پیش‌بینی بلندمدت قیمت ارزهای دیجیتال مورد استفاده قرار گرفت. در این مدل، شبکه کانولوشنی قادر است نمایش داخلی هر ارز دیجیتال را به صورت مستقل یاد بگیرد و ویژگی‌های مفید استخراج کند، در حالی که لایه‌های شبکه‌های حافظه طولانی کوتاه‌مدت دوطرفه برای پیش‌بینی داده‌های سری زمانی و شناسایی وابستگی‌های کوتاه‌مدت و بلندمدت به کار گرفته می‌شوند. برای ارزیابی خطای هر مدل، از معیارهای میانگین مربعات خطا<sup>۷۰</sup> و ریشه میانگین مربعات خطا<sup>۷۱</sup> استفاده شد و چهار ارز دیجیتال بیت‌کوین، اتریوم<sup>۷۲</sup>، دوج‌کوین<sup>۷۳</sup> و لایت‌کوین<sup>۷۴</sup> با داده‌های تاریخی و داده‌های لحظه‌ای مورد بررسی قرار گرفتند. نتایج نشان داد که مدل پیشنهادی، پایین‌ترین ریشه میانگین مربعات خطا را با مقدار ۰.۱۶۴ برای داده‌های لحظه‌ای بیت‌کوین و ۰.۱۶۶ برای داده‌های تاریخی دوج‌کوین به دست آورد. همچنین میانگین مربعات خطا برابر با ۰.۰۲۷ برای بیت‌کوین و دوج‌کوین در داده‌های لحظه‌ای و ۰.۰۲۷ برای دوج‌کوین در داده‌های تاریخی ثبت شد. این نتایج نشان می‌دهد که دقت پیش‌بینی مدل پیشنهادی به‌طور قابل توجهی بالاتر از مدل‌های یادگیری عمیق به صورت تکی است و معماری پیشنهادی برای هر دو نوع داده تاریخی و لحظه‌ای قابل اعتماد است.

در سال ۲۰۲۳ فومودزو سیبه، کلود موتسینگا و ادسون پینزا (Seabe et al., ۲۰۲۳)، در پژوهشی با تمرکز بر پیش‌بینی نرخ ارزهای دیجیتال، سه معماری پرکاربرد در شبکه‌های عصبی بازگشتی شامل شبکه حافظه طولانی کوتاه‌مدت، واحد بازگشتی دروازه‌ای و شبکه حافظه طولانی کوتاه‌مدت دوطرفه را مورد بررسی قرار دادند. داده‌های مورد استفاده مربوط به سه رمزارز اصلی جهان از نظر ارزش بازار یعنی بیت‌کوین، اتریوم و لایت‌کوین بود. نتایج تجربی نشان داد که مدل حافظه طولانی کوتاه‌مدت دوطرفه در مقایسه با حافظه طولانی کوتاه‌مدت و واحد بازگشتی دروازه‌ای عملکرد دقیق‌تری در پیش‌بینی قیمت‌ها دارد. به‌طور مشخص، مقدار خطای میانگین درصدی مطلق

---

<sup>۶۹</sup> Bidirectional Long Short-Term Memory (Bi-LSTM)

<sup>۷۰</sup> Mean Squared Error (MSE)

<sup>۷۱</sup> Root Mean Squared Error (RMSE)

<sup>۷۲</sup> Ethereum (ETH)

<sup>۷۳</sup> Dogecoin

<sup>۷۴</sup> Litecoin

برای بیت‌کوین ۰.۰۳۶، برای لایت‌کوین ۰.۰۴۱ و برای اتریوم ۰.۱۲۴ گزارش شد که بیانگر برتری قابل توجه حافظه طولانی کوتاه‌مدت دوطرفه است. این یافته‌ها حاکی از آن است که استفاده از معماری حافظه طولانی کوتاه‌مدت دوطرفه می‌تواند در بهبود دقت پیش‌بینی قیمت رمزارزها مؤثر باشد و ابزار ارزشمندی برای تصمیم‌گیری سرمایه‌گذاران و معامله‌گران فراهم کند. همچنین، نویسندگان پیشنهاد می‌کنند که تحقیقات آتی عواملی همچون حجم معاملات و تحلیل احساسات شبکه‌های اجتماعی را به‌عنوان متغیرهای مؤثر بر روند قیمتی ارزهای دیجیتال مورد توجه قرار دهند.

در سال ۲۰۲۳، لیو و همکارانش در تحقیقی (Liu et al., ۲۰۲۳)، از مدل‌های یادگیری ماشین برای پیش‌بینی بازدهی ۳۷۰۳ رمزارز در بازه زمانی ۲۰۱۳ تا ۲۰۲۱ استفاده کردند. بر اساس داده‌های روزانه، یک پرتفوی با وزن مساوی (بر اساس سرمایه) ساخته شد که بازده روزانه ۷.۱٪ (۲.۴٪) را با نسبت شارپ ۱.۹۵ (۰.۲۷) ایجاد کرد. مقدار ضریب تعیین به میزان ۴.۸۵۵٪ به دست آمد. نتایج نشان می‌دهد که رمزارزها رفتاری شبیه به دارایی‌های متعارف دارند تا ارزهای فیات؛ زیرا متغیرهایی از جمله بازده‌های وقفه‌دار می‌توانند بازده‌های آینده را پیش‌بینی کنند. به‌عنوان دارایی، رمزارزها از کارایی ضعیف برخوردار نیستند و هزینه تولید نیز تعیین‌کننده قیمت آن‌ها نیست. بازده رمزارزهای کوچک‌تر نسبت به رمزارزهای بزرگ‌تر قابلیت پیش‌بینی بیشتری دارند. همچنین، قدرت پیش‌بینی بازده با وقفه یک‌روزه بیشتر از تمامی سایر ویژگی‌ها (پیش‌بین‌ها) به‌صورت ترکیبی گزارش شده است. این یافته‌ها دیدگاه‌های جدیدی برای سرمایه‌گذاران، معامله‌گران و تحلیل‌گران مالی ارائه می‌کند.

در سال ۲۰۲۳، عزیز اویدله و همکاران در تحقیق خود (Oyedele et al., ۲۰۲۳)، ظهور ارزهای دیجیتال در سال‌های اخیر را موجب جذب سرمایه‌های قابل توجهی دانستند و به این نتیجه رسیدند که روش‌های سنتی ممکن است در ارائه نتایج بهینه ناکارآمد باشند. در این پژوهش، عملکرد مدل‌های یادگیری عمیق با تنظیم پارامترهای ژنتیکی و روش‌های مبتنی بر درخت

تقویت شده<sup>۷۵</sup> برای پیش‌بینی قیمت پایانی چند ارز دیجیتال مورد بررسی قرار گرفت. مدل‌های یادگیری عمیق شامل شبکه‌های عصبی کانولوشنی، شبکه‌های عصبی روبه‌جلو عمیق<sup>۷۶</sup> و واحدهای بازگشتی دروازه‌ای بودند. ارزیابی‌ها با استفاده از شش مجموعه داده ارز دیجیتال از منابع مختلف و معیارهای عملکرد مرتبط انجام شد. نتایج نشان داد که مدل شبکه عصبی کانولوشنی، کمترین خطای میانگین مطلق درصدی (۰.۰۸) را داشته. بنابراین، شبکه کانولوشنی برای داده‌های آموزشی محدود، قابل اعتماد و قابل تعمیم است و می‌تواند پیش‌بینی‌های روزانه قیمت پایانی چند ارز دیجیتال را با دقت بالا انجام دهد. علاوه بر این، یافته‌ها می‌توانند به سرمایه‌گذاران و فعالان بازار کمک کنند تا چالش‌های بازار کریپتو را بهتر درک کرده و استراتژی‌های عملی برای کاهش ریسک تدوین نمایند.

در سال 2024 فاطمه تابع و همکاران در تحقیق خود (Tabe et al., 2024)، تعدادی از الگوریتم‌های محبوب یادگیری عمیق، شامل پرسپترون چندلایه، شبکه‌های عصبی بازگشتی یک‌طرفه و دوطرفه، حافظه طولانی کوتاه‌مدت یک‌طرفه و دوطرفه، واحد بازگشتی دروازه‌دار یک‌طرفه و دوطرفه و شبکه‌های عصبی کانولوشنی را برای پیش‌بینی قیمت بیت‌کوین کش مورد مقایسه قرار دادند. نتایج حاصل، با استفاده از معیارهای خطای میانگین مطلق و خطای میانگین مربعات، نشان می‌دهد که مدل‌های حافظه طولانی کوتاه‌مدت یک‌طرفه و حافظه طولانی کوتاه‌مدت دوطرفه عملکرد بهتری نسبت به سایر الگوریتم‌ها در پیش‌بینی قیمت ارائه داده‌اند و بنابراین می‌توان آن‌ها را به‌عنوان بهترین الگوریتم‌ها در نظر گرفت. علاوه بر این، مقایسه انجام‌شده با سایر مطالعات نشان می‌دهد که کیفیت داده‌ها و انتخاب ابرپارامترها اهمیت بالایی دارند و می‌توانند تأثیر قابل توجهی بر نتایج پیش‌بینی داشته باشند.

علی منصورآبادی و همکاران در سال ۲۰۲۴ (Mansourabady et al., ۲۰۲۴)، به این نتیجه رسیدند که معامله‌گران و سرمایه‌گذاران همواره به دنبال راهکارهایی برای پیش‌بینی قیمت ارزهای دیجیتال هستند تا از یک‌سو بازدهی سرمایه‌گذاری خود را افزایش دهند و از سوی دیگر میزان ریسک را کاهش دهند. با این حال، به دلیل غیرقابل پیش‌بینی بودن، ناپایداری و پویایی شدید بازار، پیش‌بینی قیمت رمزارزها به یکی از چالش‌های مهم در حوزه مالی و فناوری تبدیل

---

<sup>۷۵</sup> Boosted Tree

<sup>۷۶</sup> Deep Forward Neural Network

شده است. تاکنون پژوهشگران معماری‌های متعددی را برای پیش‌بینی پیشنهاد داده‌اند که بر پایه رویکردهای آماری، الگوریتم‌های یادگیری ماشین و روش‌های یادگیری عمیق بنا شده‌اند. هدف این پژوهش این است که تعدادی از این رویکردها مورد ارزیابی قرار گیرند؛ بدین منظور، معماری‌های پیشنهادی بر روی داده‌های تاریخی مربوط به رمزارز مونرو<sup>۷۷</sup> از ابتدای سال ۲۰۱۶ تا پایان نوامبر ۲۰۲۳ پیاده‌سازی شده و نتایج با یکدیگر مقایسه گردید. یافته‌های به‌دست‌آمده نشان می‌دهد که معماری ترکیبی از شبکه عصبی کانولوشنی با حافظه طولانی کوتاه‌مدت به همراه لایه تراکم<sup>۷۸</sup> بر اساس معیار ارزیابی خطای میانگین مربعات، عملکرد بهتری نسبت به سایر مدل‌ها ارائه داده و مقدار 0.00472 را کسب کرده است.

در سال ۲۰۲۵ آرمین مزینانی، لوکا داوولی و جیانلوئیجی فراری (Mazinani et al., ۲۰۲۵) در تحقیق خود بیان کردند از آنجا که قیمت دارایی‌ها و سهام در بازارهای مالی به عوامل متعددی وابسته است و ساختاری پیچیده دارد، توانایی پیش‌بینی دقیق قیمت اهمیت بالایی در تصمیم‌گیری‌های سرمایه‌گذاری، به‌ویژه در حوزه ارزهای دیجیتال، پیدا می‌کند. تحلیل مقایسه‌ای برای بررسی کارایی الگوریتم‌های یادگیری عمیق در پیش‌بینی قیمت سه ارز دیجیتال بیت‌کوین، اتریوم و ریپل<sup>۷۹</sup> در بازه‌های کوتاه‌مدت و بلندمدت انجام شده است. نتایج، بر اساس معیارهای ریشه میانگین مربعات خطا، میانگین قدرمطلق خطا، میانگین درصدی قدرمطلق خطا و ضریب تعیین ارزیابی شدند. یافته‌ها نشان می‌دهند که مدل ترنسفورمر<sup>۸۰</sup> عموماً برای پیش‌بینی‌های کوتاه‌مدت دقیق‌تر عمل کرده و در پیش‌بینی‌های بلندمدت نیز عملکرد مطلوبی دارد، اما به طور کلی، نتایج نشان داده‌اند که مدل ترکیبی کانولوشن و شبکه عصبی بازگشتی دروازه‌ای بهترین توازن بین دقت و پیچیدگی محاسباتی را در پیش‌بینی قیمت بیت‌کوین و اتریوم ارائه می‌دهد، در حالی که مدل ترکیبی کانولوشن و شبکه عصبی بازگشتی ساده عملکرد برتری در پیش‌بینی قیمت ریپل دارد.

در سال ۲۰۲۵، پریتی پاندی و گیتا شارما (Pandey & Geeta, ۲۰۲۵) به این نتیجه رسیدند که در سال‌های اخیر، پیش‌بینی روند ارزهای دیجیتال به یکی از موضوعات کلیدی برای

---

<sup>۷۷</sup> Monero (XMR)

<sup>۷۸</sup> Dense Layer

<sup>۷۹</sup> Ripple (XRP)

<sup>۸۰</sup> Transformer

سرمایه‌گذاران و معامله‌گران تبدیل شده است، زیرا این امر به آن‌ها کمک می‌کند تا تصمیمات آگاهانه‌تری درباره آینده بازار دارایی‌های دیجیتال اتخاذ کنند. هدف اصلی این تحقیق طراحی یک معماری مؤثر مبتنی بر یادگیری عمیق بوده است که از مدل‌های پیش‌بینی سری‌های زمانی همچون شبکه‌های عصبی بازگشتی، شبکه‌های عصبی کانولوشنی و شبکه حافظه طولانی کوتاه‌مدت برای پیش‌بینی قیمت دو ارز دیجیتال بیت‌کوین و اتریوم بهره می‌گیرد. در این مدل، شبکه کانولوشنی وظیفه استخراج ویژگی‌های پیچیده از داده‌های تاریخی قیمت را بر عهده دارد و به شناسایی الگوهای پنهان در حرکات قیمتی کمک می‌کند. سپس لایه‌های حافظه طولانی کوتاه‌مدت دوطرفه به کار گرفته می‌شوند تا بتوانند وابستگی‌های زمانی گذشته و آینده را هم‌زمان مدنظر قرار دهند. این ویژگی باعث می‌شود مدل برای سری‌های زمانی مالی، که غالباً دارای رفتار غیرخطی هستند، مناسب‌تر باشد. نتایج آزمایش‌ها بر روی مجموعه داده‌ای از ارزهای دیجیتال اصلی نشان داد که مدل پیشنهادی از دقت بالایی در پیش‌بینی قیمت‌ها برخوردار است. همچنین مشخص شد که استفاده از مدل دوطرفه نسبت به مدل‌های سنتی پیش‌بینی سری‌های زمانی و مدل‌های یک‌طرفه عملکرد بهتری دارد و می‌تواند دقت پیش‌بینی در بازار ارزهای دیجیتال را افزایش دهد.

رامنیت کائور و همکاران در سال 2025 (Kaur et al., 2025) در تحقیق خود، سه ارز دیجیتال برتر از نظر ارزش بازار، شامل اتریوم، بیت‌کوین و لایت‌کوین را برای پیش‌بینی مورد بررسی قرار گرفتند. در این مطالعه، دو نوع شبکه عصبی بازگشتی یعنی شبکه حافظه طولانی کوتاه‌مدت و واحد بازگشتی دروازه‌ای به کار گرفته شدند. چهار معیار ارزیابی عملکرد شامل میانگین مربعات خطا، میانگین قدر مطلق خطا، میانگین درصدی قدر مطلق خطا و ریشه میانگین مربعات خطا استفاده شدند که نتایج نشان دادند مدل واحد بازگشتی دروازه‌ای عملکرد بهتری نسبت به حافظه طولانی کوتاه‌مدت دارد. مدل واحد بازگشتی دروازه‌ای در قالب یک شبکه عمیق دومرحله‌ای پیاده‌سازی شد که با استفاده از بهینه‌ساز آدام<sup>۸۱</sup> و نرخ حذف تصادفی<sup>۸۲</sup> برابر با 0.2 برای جلوگیری از بیش‌برازش<sup>۸۳</sup> آموزش داده شد. داده‌های تاریخی مورد استفاده پس از نرمال‌سازی، با نسبت ۸۰

---

<sup>۸۱</sup> Adam

<sup>۸۲</sup> Dropout

<sup>۸۳</sup> Overfitting



درصد برای آموزش<sup>۸۴</sup> و ۲۰ درصد برای آزمون<sup>۸۵</sup> تقسیم شدند. نتایج نهایی نشان دادند که مقادیر میانگین درصدی قدر مطلق خطا برای بیت کوین، لایت کوین و اتریوم به ترتیب برابر با 0.03540، 0.08703 و 0.04415 هستند که حاکی از دقت بالاتر مدل واحد بازگشتی دروازه‌ای در مقایسه با حافظه طولانی کوتاه مدت است. این پژوهش نشان می‌دهد که مدل‌های مبتنی بر واحد بازگشتی دروازه‌ای می‌توانند ابزار مؤثری برای سرمایه‌گذاران و معامله‌گران در پیش‌بینی دقیق قیمت ارزهای دیجیتال باشند. همچنین پیشنهاد شده است که در تحقیقات آینده، متغیرهای دیگری همچون روندهای شبکه‌های اجتماعی و حجم معاملات نیز به عنوان عوامل مؤثر بر قیمت ارزهای دیجیتال در نظر گرفته شوند.

بهاره امیرشاهی و سلیم لاهمیری در سال ۲۰۲۵ (Amirshahi & Lahmiri, ۲۰۲۵)، در تحقیق خود، یک مدل ترکیبی مبتنی بر یادگیری عمیق معرفی کرده‌اند که قابلیت سازگاری با ارزهای مختلف را دارد. این مدل در ۲۰ نسخه مختلف توسعه یافته و از داده‌های تاریخی قیمت به همراه توییت‌های منتشرشده در بازه ژانویه تا دسامبر ۲۰۲۱ به عنوان ورودی استفاده شده است. یافته‌های این تحقیق نشان می‌دهد که افزایش طول توالی داده‌های ورودی موجب بهبود دقت پیش‌بینی می‌شود و داده‌های ۱۴ روز گذشته، در مقایسه با ۷ یا ۲۱ روز، بهترین عملکرد را داشته‌اند. همچنین افزودن لایه کانولوشنی و لایه توجه<sup>۸۶</sup> در توالی‌های بلندتر، دقت پیش‌بینی را افزایش داده است. از سوی دیگر، نتایج نشان داده‌اند که در بیش از ۷۰ درصد موارد، ترکیب داده‌های قیمتی با داده‌های احساسات استخراج‌شده از تویتر (ایکس فعلی) دقت پیش‌بینی را بهبود بخشیده است. این یافته اهمیت نقش شبکه‌های اجتماعی، به‌ویژه تویتر، در شکل‌گیری تصمیمات معاملاتی را برجسته می‌سازد. البته محدودیت‌هایی نیز گزارش شده است؛ از جمله ضعف روش‌های تحلیل احساسات در تشخیص طنز و کنایه، وجود محتوای نامرتبط یا تبلیغاتی در توییت‌ها و همچنین تأثیر منفی داده‌های تولیدشده توسط ربات‌ها.

---

<sup>۸۴</sup> Train

<sup>۸۵</sup> Test

<sup>۸۶</sup> Attention layer

## ۳-۲ فرصت‌ها و شکاف تحقیقاتی

در حوزه پیش‌بینی قیمت رمزارزها، روش‌های کلاسیک معمولاً بر پایه این فرضیه عمل می‌کردند که حرکت قیمت‌ها خطی است و تغییرات سری‌های زمانی را با استفاده از مدل‌های آماری ساده پیش‌بینی می‌کنند. این رویکردها گرچه در بسیاری از بازارهای سنتی کاربردی بودند، اما در بازار رمزارزها که به شدت نوسانی، غیرخطی و پیچیده است، توانایی کافی برای شناسایی الگوهای پنهان و غیرخطی موجود در داده‌ها را ندارند. به همین دلیل، در سال‌های اخیر، پژوهشگران به سمت استفاده از روش‌های مبتنی بر یادگیری ماشین و یادگیری عمیق سوق یافته‌اند که قابلیت استخراج ویژگی‌های پیچیده و روابط غیرخطی داده‌ها را دارند و می‌توانند پیش‌بینی‌های دقیق‌تری ارائه دهند.

روش‌های رگرسیونی سنتی و ساده، توانایی لازم برای شناسایی الگوهای پیچیده و پویای بازار ارزهای دیجیتال را ندارند. به همین منظور، شبکه‌های عصبی بازگشتی به‌عنوان یکی از الگوریتم‌های مؤثر برای داده‌های سری‌زمانی به کار گرفته شده‌اند. با این حال، شبکه‌های عصبی بازگشتی کلاسیک با مشکلاتی از جمله گرادیان محوشونده<sup>۸۷</sup> و گرادیان انفجاری<sup>۸۸</sup> مواجه هستند که موجب کاهش دقت مدل در یادگیری وابستگی‌های بلندمدت می‌شود. برای رفع این محدودیت، الگوریتم‌هایی مانند حافظه طولانی کوتاه‌مدت و واحد بازگشتی دروازه‌ای معرفی شدند که به دلیل قابلیت حفظ اطلاعات بلندمدت و مدیریت وابستگی‌های پیچیده، برای پیش‌بینی داده‌های سری‌زمانی و به ویژه قیمت رمزارزها بسیار مناسب هستند.

علاوه بر پیش‌بینی قیمت، تحلیل احساسات نیز نقش مهمی در تعیین نوسانات و رفتار بازار دارد، زیرا احساسات سرمایه‌گذاران و اخبار منتشرشده در رسانه‌ها می‌توانند تأثیر قابل توجهی بر تصمیمات خرید و فروش داشته باشند. در این زمینه، روش‌های متنوعی مانند کریپتوBERT<sup>۸۹</sup>، دیستیل‌روبرت<sup>۹۰</sup>، فاین‌برت<sup>۹۱</sup> و سایر الگوریتم‌های مبتنی بر یادگیری عمیق برای استخراج و تحلیل احساسات کاربران و پیش‌بینی واکنش بازار مورد استفاده قرار گرفته‌اند. همچنین، شبکه عصبی کانولوشنی به دلیل توانایی بالای خود در استخراج ویژگی‌های مهم و مفید از داده‌ها و شبکه‌های

---

<sup>۸۷</sup> Vanishing Gradient

<sup>۸۸</sup> Exploding Gradient

<sup>۸۹</sup> CryptoBert

<sup>۹۰</sup> DistilRoBerta

<sup>۹۱</sup> FinBert

عصبی بازگشتی به دلیل درک وابستگی‌های طولانی، در پیش‌بینی قیمت و تحلیل احساسات کاربرد فراوان دارند و می‌توانند اطلاعات پنهان و روابط پیچیده میان متغیرها را شناسایی کنند.

با توجه به مرور تحقیقات انجام‌شده، هرچند مطالعات متعددی در زمینه پیش‌بینی رمزارزها وجود دارد، اما هنوز شکاف‌های پژوهشی قابل توجهی مشاهده می‌شود. به‌ویژه، استفاده از تکنیک‌های ترکیبی که در آن الگوریتم‌های یادگیری عمیق برای پیش‌بینی قیمت با تحلیل احساسات کاربران و اخبار تلفیق شوند، به نسبت کمتر مورد بررسی قرار گرفته است و این زمینه در اکثر پژوهش‌های آینده به عنوان حوزه‌ای با پتانسیل بالا برای تحقیق ذکر شده است.

## ۴-۲ جمع بندی

در این فصل به پیشینه و بررسی و مقایسه تحقیقات و پژوهش‌های انجام شده با این تحقیق پرداخته شد. نکات مهم و اساس هر مطالعه و تحقیق ذکر شد و مزایا و معایب آن گفته شد. در فصل بعد یعنی فصل سوم، به مبانی تحقیق و روش پژوهش پرداخته خواهد شد.

## فصل سوم

## مبانی نظری و روش پژوهش

### ۱-۳ مقدمه

در این فصل، ابتدا مبانی نظری و مفاهیم کلیدی مورد نیاز برای درک کامل مدل‌های به کار رفته در این پژوهش تشریح می‌شوند. این مبانی شامل اصول شبکه‌های عصبی، روش‌های یادگیری عمیق و تکنیک‌های پیش‌بینی سری‌های زمانی می‌باشند که در فهم بهتر معماری پیشنهادی و توانمندی‌های مدل‌ها اهمیت دارند. پس از آن، معیارهای ارزیابی عملکرد مدل‌ها برای مسائل رگرسیون مورد بحث قرار خواهند گرفت. این معیارها، از جمله خطای میانگین مطلق، خطای میانگین مربعات، ریشه خطای میانگین مربعات، خطای میانگین درصدی مطلق و ضریب تعیین به منظور سنجش دقیق عملکرد مدل‌ها در پیش‌بینی قیمت رمزارزها استفاده می‌شوند و امکان مقایسه کمی بین مدل‌های مختلف را فراهم می‌کنند. داده‌های تاریخی قیمت‌ها شامل قیمت بسته شدن، حجم معاملات<sup>۹۲</sup> و سایر شاخص‌های مالی، شاخص حرص و طمع<sup>۹۳</sup>، تأثیر تغییرات قیمت بیت‌کوین بر سایر ارزها، داده‌های تحلیل احساسات اخبار از داده‌های استفاده شده، می‌باشند. سپس، مدل‌های یادگیری عمیق پیاده‌سازی شده به ترتیب بررسی می‌شوند و عملکرد آن‌ها با مدل پیشنهادی پژوهش مقایسه خواهد شد. الگوریتم‌های به کار رفته شامل پرسپترون چندلایه، شبکه‌های عصبی پیچشی، شبکه‌های عصبی بازگشتی، حافظه طولانی کوتاه‌مدت و واحد بازگشتی دروازه‌ای و نسخه‌های دوطرفه آن‌ها می‌باشند. علاوه بر این، مدل‌ها و نتایج ارائه شده در مقالات مرتبط نیز مرور و مقایسه می‌شوند تا مزایا، محدودیت‌ها و کاربردهای هر روش در پیش‌بینی قیمت رمزارزها مشخص گردد.

---

<sup>۹۲</sup> Volume

<sup>۹۳</sup> Fear & Greed Index

برای بخش تحلیل احساسات اخبار و متون مرتبط با رمزارزها، از الگوریتم‌های پیشرفته پردازش زبان طبیعی شامل دیستیل‌روبرتا، فاین‌برت و کریپتوبرت استفاده شده است. این الگوریتم‌ها قادرند احساسات و هیجانات موجود در متن‌ها را شناسایی کنند و اثر آن‌ها را بر نوسانات بازار تحلیل نمایند، که به بهبود دقت پیش‌بینی قیمت و تحلیل رفتار بازار کمک شایانی می‌کند.

## ۲-۳ مبانی نظری

### ۱-۲-۳ بازارهای مالی

انسان همواره در تلاش بوده است تا آینده را پیش‌بینی کند؛ اما در حوزه اقتصاد و مالی، این امر پیچیدگی‌های خاص خود را دارد. پویایی و غیرقابل پیش‌بینی بودن بازارهای مالی باعث شده است که پیش‌بینی روند قیمت‌ها به یکی از چالش‌های اساسی در اقتصاد تبدیل شود. با این حال، ظهور تکنیک‌های هوش مصنوعی و مدل‌های داده‌محور این امکان را فراهم کرده است که با دقت قابل قبولی، رفتار احتمالی بازار را تحلیل و پیش‌بینی کنیم. پیش‌بینی در بازارهای مالی تنها به بررسی داده‌های تاریخی محدود نمی‌شود؛ بلکه تحت تأثیر مجموعه‌ای از عوامل متنوع از جمله شرایط اقتصادی کلان، رفتار و روانشناسی سرمایه‌گذاران، تغییرات محیطی، رخداد‌های سیاسی، بلایای طبیعی و حتی جریان‌های اجتماعی قرار دارد. این عوامل، به‌صورت سیستماتیک نوسانات بازار را شکل می‌دهند و تحلیل آن‌ها مستلزم رویکردی چندبعدی است. بازارهای مالی در واقع زیرساخت‌هایی هستند که جریان سرمایه را میان افراد، شرکت‌ها و دولت‌ها تسهیل می‌کنند. این بازارها با فراهم کردن بستر خرید و فروش انواع دارایی‌های مالی، نقش کلیدی در تخصیص بهینه منابع و پایداری اقتصادی ایفا می‌کنند (Zhong et al., ۲۰۲۳). به طور کلی، بازارهای مالی به بخش‌های زیر تقسیم می‌شوند:

- بازار سهام<sup>۹۴</sup>: بستری برای خرید و فروش سهام شرکت‌های عمومی که در بورس‌های رسمی عرضه می‌شوند. این بازار نه تنها امکان مشارکت در مالکیت شرکت‌ها را فراهم می‌کند، بلکه شاخصی مهم برای سلامت اقتصادی نیز محسوب می‌شود. نمونه‌های بارز آن، بورس اوراق بهادار نیویورک<sup>۹۵</sup> و نزدک<sup>۹۶</sup> هستند.
- بازار اوراق بدهی<sup>۹۷</sup>: مکانی برای معامله ابزارهای بدهی نظیر اوراق قرضه دولتی، اوراق بدهی شرکتی و اوراق شهرداری. این بازار به سرمایه‌گذاران امکان می‌دهد در قبال تأمین مالی، بازدهی ثابت و بلندمدت دریافت کنند.
- بازار ارز خارجی<sup>۹۸</sup>: یکی از بزرگ‌ترین و نقدشونده‌ترین بازارهای جهان که در آن ارزهای مختلف مورد معامله قرار می‌گیرند. بانک‌ها، شرکت‌های چندملیتی، دولت‌ها و معامله‌گران فردی در این بازار نقش‌آفرینی می‌کنند.
- بازار کالا<sup>۹۹</sup>: بازاری برای خرید و فروش کالاهای اساسی همچون طلا، نفت، گاز طبیعی و محصولات کشاورزی. بورس‌های کالایی مانند بورس کالای شیکاگو<sup>۱۰۰</sup> بستری برای پوشش ریسک و کشف قیمت این دارایی‌ها ایجاد کرده‌اند.
- بازار سرمایه<sup>۱۰۱</sup>: شامل صدور و معامله اوراق بهادار بلندمدت نظیر سهام و اوراق قرضه است. هدف اصلی این بازار، تأمین مالی شرکت‌ها و دولت‌ها برای اجرای پروژه‌های توسعه‌ای و سرمایه‌گذاری‌های کلان است.

---

<sup>۹۴</sup> Stock Market

<sup>۹۵</sup> NYSE

<sup>۹۶</sup> NASDAQ

<sup>۹۷</sup> Bond Market

<sup>۹۸</sup> Foreign Exchange Market – Forex

<sup>۹۹</sup> Commodities Market

<sup>۱۰۰</sup> CME

<sup>۱۰۱</sup> Capital Market

### ۲-۲-۳ بازار ارزهای دیجیتال

پس از بحران مالی جهانی سال ۲۰۰۸، بانک‌های مرکزی بزرگ جهان با اتخاذ سیاست‌های تسهیل کمی<sup>۱۰۲</sup> اقدام به افزایش گسترده پایه پولی کردند؛ اقدامی که بدون نیاز به چاپ اسکناس فیزیکی و صرفاً از طریق ایجاد نقدینگی دیجیتال در سیستم‌های بانکی انجام شد. درست در همین مقطع تاریخی، شاهد ظهور یک پدیده مالی نوآورانه و انقلابی بودیم: بیت‌کوین. بیت‌کوین نخستین ارز دیجیتال غیرمتمرکز است که توانست مجموعه‌ای از فناوری‌های موجود را در قالبی نوین و یکپارچه تلفیق کند. این سیستم با بهره‌گیری از رمزنگاری کلید نامتقارن، دفترکل توزیع‌شده<sup>۱۰۳</sup> و مکانیزم اجماع اثبات کار<sup>۱۰۴</sup>، زیرساختی شفاف، امن و غیرمتمرکز را برای ثبت و انتقال ارزش فراهم ساخت. به این ترتیب، بلاکچین به عنوان بستر بنیادین بیت‌کوین نه تنها امکان جابه‌جایی دارایی‌های مالی را بدون نیاز به واسطه‌ها مهیا کرد، بلکه بستری مطمئن برای اعتمادسازی میان مشارکت‌کنندگان ناشناس در سطح جهانی به وجود آورد. اما کاربردهای فناوری بلاکچین صرفاً به مبادلات مالی محدود نشد.

در اواخر سال ۲۰۱۳، ایده‌ای فراتر از انتقال ارزش مطرح گردید: استفاده از بلاکچین به عنوان ماشین مجازی توزیع‌شده برای اجرای کدهای کامپیوتری. این ایده با پروژه‌ای تحت عنوان اتریوم در سال ۲۰۱۵ تحقق یافت. اتریوم نه تنها انتقال ارز دیجیتال بومی خود اتر<sup>۱۰۵</sup> را امکان‌پذیر کرد، بلکه محیطی برای توسعه و اجرای برنامه‌های غیرمتمرکز<sup>۱۰۶</sup> فراهم آورد. این برنامه‌ها به‌گونه‌ای طراحی شده‌اند که در برابر سانسور، توقف، تقلب یا تغییر غیرمجاز مقاوم باشند. یکی از نوآوری‌های بنیادین

---

<sup>۱۰۲</sup> Quantitative Easing

<sup>۱۰۳</sup> Ledger

<sup>۱۰۴</sup> Proof of Work

<sup>۱۰۵</sup> Ether

<sup>۱۰۶</sup> DApps



اتریوم، معرفی قراردادهای هوشمند<sup>۱۰۷</sup> است؛ کدهایی خوداجرا که شرایط توافقات را به صورت الگوریتمی و بدون نیاز به واسطه اجرا می کنند. این قابلیت، زمینه ساز پیدایش ابزارهای مالی نوین از جمله انتشار توکن ها<sup>۱۰۸</sup> و پیشنهاد اولیه سکه<sup>۱۰۹</sup> شد (Liu et al., ۲۰۲۳).

### ۳-۲-۳ تحلیل بازارهای مالی

از قدیم تحلیل بازارهای مالی، امری مهم و تخصصی بوده است از دیرباز تحلیل و ارزیابی بازارهای مالی به عنوان یکی از ارکان تصمیم گیری اقتصادی و سرمایه گذاری مطرح بوده است. در طول زمان، رویکردهای متعددی برای بررسی روندها و پیش بینی رفتار بازارها توسعه یافته اند که در میان آنها، تحلیل تکنیکال<sup>۱۱۰</sup> و تحلیل بنیادی<sup>۱۱۱</sup> جایگاه ویژه ای دارند. یکی از شکاف های قابل توجه میان فضای دانشگاهی و کاربرد عملی، اختلاف دیدگاه نسبت به این دو روش تحلیلی است. در حالی که تحلیل بنیادی به سرعت مورد پذیرش محققان و متخصصان مالی قرار گرفت، تحلیل تکنیکال همواره با بدبینی و حتی بی اعتنائی از سوی محافل دانشگاهی مواجه بوده است. تحلیل تکنیکال که اغلب با عنوان «نمودارخوانی» نیز شناخته می شود، دهه هاست به طور گسترده توسط معامله گران و فعالان بازارهای مالی مورد استفاده قرار می گیرد و همچنان یکی از ابزارهای اصلی تصمیم گیری در معاملات محسوب می شود.

در حوزه ارزهای دیجیتال، تحلیل بنیادی مفهومی فراتر از بررسی داده های مالی سنتی دارد. این نوع تحلیل به ارزیابی ارزش ذاتی دارایی های دیجیتال بر اساس عوامل بنیادین و ساختاری آنها می پردازد. متغیرهایی همچون فناوری و معماری پروژه،

---

<sup>۱۰۷</sup> Smart Contracts

<sup>۱۰۸</sup> Token

<sup>۱۰۹</sup> Initial Coin Offering - ICO

<sup>۱۱۰</sup> Technical Analysis

<sup>۱۱۱</sup> Fundamental Analysis

توانمندی و اعتبار تیم توسعه‌دهنده، مشارکت‌ها و همکاری‌های استراتژیک، میزان پذیرش و نرخ استفاده در اکوسیستم، تقاضای بازار و شرایط اقتصادی و نهادی پیرامونی از جمله شاخص‌های کلیدی در این رویکرد به شمار می‌روند. هدف اصلی تحلیل بنیادی در رمزارزها، شناسایی شکاف میان ارزش واقعی<sup>۱۱۲</sup> و قیمت بازار<sup>۱۱۳</sup> است؛ به این معنا که آیا یک دارایی دیجیتال بیش‌ازحد ارزش‌گذاری شده است یا کمتر از ارزش ذاتی خود معامله می‌شود. نتایج این نوع تحلیل می‌تواند مبنای تصمیم‌گیری‌های آگاهانه و استراتژیک برای سرمایه‌گذاران و فعالان حوزه بلاکچین باشد و نقش مهمی در کاهش ریسک‌های ناشی از نوسانات شدید بازار ایفا کند.

#### ۳-۲-۴ هوش مصنوعی و یادگیری ماشین

یادگیری ماشین یک حوزه در حال تکامل از الگوریتم‌های هوش مصنوعی شاخه‌ای از علوم کامپیوتر است که هدف اصلی آن طراحی سیستم‌هایی با قابلیت شبیه‌سازی فرآیندهای شناختی انسان مانند درک، استدلال، تصمیم‌گیری و یادگیری است. در میان زیرشاخه‌های متنوع این حوزه، یادگیری ماشین جایگاه ویژه‌ای دارد و به‌عنوان موتور محرک بسیاری از پیشرفت‌های اخیر در فناوری شناخته می‌شود. یادگیری ماشین در واقع مجموعه‌ای از الگوریتم‌های محاسباتی است که به سیستم‌ها این امکان را می‌دهد تا از داده‌ها بیاموزند و بدون برنامه‌ریزی صریح، عملکرد خود را بهبود بخشند. در عصر حاضر که حجم عظیمی از داده‌ها موسوم به داده‌های بزرگ<sup>۱۱۴</sup> در دسترس است، الگوریتم‌های یادگیری ماشین به‌عنوان ابزار اصلی برای تحلیل، پیش‌بینی و استخراج الگوهای پنهان از اطلاعات شناخته می‌شوند.

کاربردهای یادگیری ماشین گستره‌ای وسیع دارند: از تشخیص الگو<sup>۱۱۵</sup> و پردازش تصویر<sup>۱۱۶</sup> در بینایی ماشین<sup>۱۱۷</sup> گرفته تا تشخیص بیماری‌ها در پزشکی

---

<sup>۱۱۲</sup> Intrinsic Value

<sup>۱۱۳</sup> Market Price

<sup>۱۱۴</sup> Big Data

<sup>۱۱۵</sup> Pattern Recognition

<sup>۱۱۶</sup> Image Processing

<sup>۱۱۷</sup> Machine Vision

هوشمند، از تحلیل ریسک و پیش‌بینی بازارهای مالی تا کاوش‌های فضایی، سیستم‌های سرگرمی، و حتی خودروهای خودران وجه مشترک تمام این کاربردها، توانایی سیستم در یادگیری از محیط و به‌روزرسانی دانش خود بر اساس داده‌های ورودی است.

ارتباط میان داده‌کاوی<sup>۱۱۸</sup> و یادگیری ماشین بسیار عمیق است. داده‌کاوی بر کشف الگوها و روابط پنهان در پایگاه‌های عظیم داده تمرکز دارد و در این مسیر به‌شدت به الگوریتم‌های یادگیری ماشین متکی است. در مقابل، بسیاری از مدل‌های یادگیری ماشین نیز از تکنیک‌های داده‌کاوی برای آماده‌سازی و پیش‌پردازش داده‌ها بهره می‌برند. با این حال، دامنه یادگیری ماشین فراتر از تحلیل داده است و بخش مهمی از آن به حل مسائل بنیادین هوش مصنوعی و شبیه‌سازی فرآیندهای شناختی اختصاص دارد. یادگیری ماشین ترکیبی میان علوم مهندسی و علوم انسانی است؛ زیرا از یک‌سو به مفاهیم ریاضی مانند آمار، احتمال، نظریه اطلاعات، الگوریتم‌ها و ساختار داده‌ها وابسته است و از سوی دیگر، از حوزه‌هایی چون روان‌شناسی شناختی و فلسفه ذهن الهام می‌گیرد (Tanwar et al., ۲۰۲۱). از منظر رویکردهای یادگیری، الگوریتم‌های یادگیری ماشین به سه دسته اصلی تقسیم می‌شوند:

- یادگیری با نظارت<sup>۱۱۹</sup>: مدل از داده‌های برچسب‌دار<sup>۱۲۰</sup> آموزش می‌بیند تا بتواند خروجی‌های جدید را پیش‌بینی کند. مسائل طبقه‌بندی و رگرسیون نمونه‌های بارز این روش هستند.
- یادگیری بدون نظارت<sup>۱۲۱</sup>: در این رویکرد داده‌ها برچسب‌گذاری نشده‌اند<sup>۱۲۲</sup> و هدف اصلی کشف ساختار یا الگوهای پنهان در داده‌هاست. خوشه‌بندی<sup>۱۲۳</sup> از شناخته‌شده‌ترین کاربردهای آن است.

---

<sup>۱۱۸</sup> Data Mining

<sup>۱۱۹</sup> Supervised Learning

<sup>۱۲۰</sup> Labeled Data

<sup>۱۲۱</sup> Unsupervised Learning

<sup>۱۲۲</sup> Unlabeled Data

<sup>۱۲۳</sup> Clustering

- یادگیری نیمه‌نظارتی<sup>۱۲۴</sup>: ترکیبی از دو روش قبلی است؛ بخشی از داده‌ها برچسب‌دار هستند و بخشی دیگر بدون برچسب. این شیوه در کاربردهایی همچون بازیابی متن<sup>۱۲۵</sup> و تصویر بسیار مؤثر است.

در مجموع، یادگیری ماشین را می‌توان ستون فقرات هوش مصنوعی مدرن دانست؛ فناوری‌ای که با اتکا به داده، محاسبات و الگوریتم‌های پیچیده، توانسته است ماشین‌ها را از سطح یک ابزار صرف به سیستم‌هایی هوشمند و تصمیم‌گیرنده ارتقا دهد.

### ۳-۲-۵ یادگیری عمیق

روش‌های یادگیری زیرشاخه‌ای پیشرفته از یادگیری ماشین است که بر استفاده از شبکه‌های عصبی مصنوعی با لایه‌های متعدد تمرکز دارد. برخلاف الگوریتم‌های کلاسیک یادگیری ماشین که معمولاً نیازمند استخراج ویژگی‌ها به صورت دستی هستند، یادگیری عمیق قادر است ویژگی‌های پیچیده و چندسطحی داده‌ها را به صورت خودکار استخراج و یاد بگیرد. این ویژگی باعث می‌شود مدل‌های یادگیری عمیق در مواجهه با داده‌های پیچیده و با ابعاد بالا، عملکردی بسیار برتر نسبت به روش‌های سنتی داشته باشند (Tanwar et al., 2021).

یکی از مهم‌ترین برتری‌های یادگیری عمیق نسبت به یادگیری ماشین، توانایی آن در مدیریت داده‌های غیرساخت‌یافته<sup>۱۲۶</sup> مانند تصاویر، متن‌ها و سیگنال‌های صوتی است. در حالی که الگوریتم‌های یادگیری ماشین معمولی برای داده‌های جدولی و ساخت‌یافته طراحی شده‌اند، شبکه‌های عصبی عمیق قادرند روابط پنهان و الگوهای غیرخطی بسیار پیچیده را در داده‌های متنوع شناسایی کنند. همین امر موجب شده است که یادگیری عمیق در حوزه‌هایی چون بینایی ماشین، پردازش زبان طبیعی، شناسایی گفتار<sup>۱۲۷</sup> و سیستم‌های توصیه‌گر به نتایج بی‌سابقه دست پیدا کند.

در حوزه مالی و بازارهای سرمایه، یادگیری عمیق توانسته تحولی اساسی ایجاد کند. الگوریتم‌های سنتی اغلب در برابر نوسانات شدید و ماهیت غیرایستا بازارهای مالی

<sup>۱۲۴</sup> Semi-Supervised Learning

<sup>۱۲۵</sup> Text Retrieval

<sup>۱۲۶</sup> Unstructured Data

<sup>۱۲۷</sup> Speech Recognition

دچار ضعف هستند. اما شبکه‌های عصبی عمیق به دلیل قابلیت مدل‌سازی روابط غیرخطی و پویا<sup>۱۲۸</sup>، می‌توانند روندها، همبستگی‌ها و الگوهای پنهان در داده‌های مالی را شناسایی کنند. این موضوع به‌ویژه در بازارهای پرنوسانی مانند ارزهای دیجیتال اهمیت دارد، جایی که رفتار بازار نه‌تنها تحت تأثیر داده‌های تاریخی قیمت، بلکه متغیرهای بیرونی همچون اخبار و احساسات سرمایه‌گذاران نیز قرار دارد.

کاربرد یادگیری عمیق در پیش‌بینی قیمت رمزارزها روزبه‌روز در حال گسترش است. مدل‌هایی نظیر شبکه‌های عصبی بازگشتی و به‌ویژه حافظه طولانی کوتاه‌مدت و واحد بازگشتی دروازه‌ای به دلیل توانایی در درک وابستگی‌های زمانی، برای تحلیل سری‌های زمانی قیمت ارزهای دیجیتال بسیار کارآمد هستند. همچنین، با ترکیب داده‌های قیمتی با شاخص‌های تحلیل احساسات از اخبار می‌توان دقت پیش‌بینی‌ها را به‌طور چشمگیری افزایش داد. در نتیجه، یادگیری عمیق ابزاری کلیدی برای معامله‌گران، سرمایه‌گذاران و پژوهشگران در مدیریت ریسک، کشف فرصت‌های معاملاتی و تصمیم‌گیری‌های استراتژیک در بازار ارز دیجیتال به شمار می‌رود (Aslam et al., 2022).

### ۳-۲-۶ پرسپترون چند لایه

پرسپترون چندلایه نوعی شبکه عصبی مصنوعی<sup>۱۲۹</sup> است که حداقل از سه لایه تشکیل می‌شود: یک لایه ورودی<sup>۱۳۰</sup>، یک یا چند لایه پنهان<sup>۱۳۱</sup> و یک لایه خروجی<sup>۱۳۲</sup>. آموزش این مدل معمولاً بر پایه روش یادگیری با نظارت و الگوریتم پس‌انتشار خطا<sup>۱۳۳</sup> انجام می‌گیرد؛ به همین دلیل، این الگوریتم در دسته شبکه‌های مبتنی بر پس‌انتشار قرار می‌گیرد. یکی از تفاوت‌های کلیدی این مدل با مدل‌های سنتی مانند رگرسیون لجستیک<sup>۱۳۴</sup> در این است که شبکه عصبی پرسپترون چندلایه قابلیت استفاده از لایه‌های میانی غیرخطی را دارد. در این ساختار، ورودی‌ها که شامل

---

<sup>۱۲۸</sup> Non-Linear Dynamic Dependency

<sup>۱۲۹</sup> Artificial Neural Network (ANN)

<sup>۱۳۰</sup> Input Layer

<sup>۱۳۱</sup> Hidden Layer(s)

<sup>۱۳۲</sup> Output Layer

<sup>۱۳۳</sup> Backpropagation

<sup>۱۳۴</sup> Logistic Regression

برداری از ویژگی‌ها هستند، به نورون‌های لایه نخست متصل می‌شوند. سپس در هر نورون، ابتدا ترکیبی خطی از ورودی‌ها محاسبه شده و در ادامه یک تابع فعال‌سازی غیرخطی<sup>۱۳۵</sup> بر آن اعمال می‌گردد. این فرایند در لایه‌های پنهان تکرار می‌شود تا در نهایت لایه خروجی مقادیر نهایی را بر اساس آخرین بازنمایی داده‌ها تولید کند.

کاربرد مؤثر پرسپترون چندلایه مستلزم طراحی معماری شبکه است. این طراحی شامل انتخاب تعداد لایه‌ها و تعیین تعداد نورون‌ها در هر لایه می‌شود. تعداد کم لایه‌ها و نورون‌ها ممکن است باعث کم‌برآوردی<sup>۱۳۶</sup> شود، در حالی که استفاده بیش از حد می‌تواند به بیش‌برازش بینجامد. از این رو، انتخاب ساختار بهینه نیازمند توجه به حجم داده‌های آموزشی، ماهیت مسئله و پیچیدگی الگوهای موجود در داده است. به طور کلی، پرسپترون چندلایه به دلیل توانایی در یادگیری روابط غیرخطی میان داده‌ها و استخراج ویژگی‌های پنهان، یکی از پرکاربردترین معماری‌ها در شبکه‌های عصبی به شمار می‌رود. این مدل در مسائلی نظیر طبقه‌بندی، رگرسیون، پیش‌بینی سری‌های زمانی و پردازش سیگنال به‌طور گسترده مورد استفاده قرار گرفته و همچنان یکی از ارکان اصلی یادگیری عمیق محسوب می‌شود (Valencia et al., 2019).

### ۳-۲-۷ شبکه‌های عصبی کانولوشنی

شبکه‌های عصبی کانولوشنی نوعی مدل یادگیری عمیق هستند که در پردازش و تحلیل داده‌های تصویری و همچنین داده‌های سری‌های زمانی کارایی بالایی دارند. هرچند کاربرد اصلی شبکه‌های عصبی کانولوشنی در حوزه بینایی ماشین و پردازش تصویر است، اما این مدل‌ها در سایر حوزه‌ها از جمله پیش‌بینی قیمت ارزهای دیجیتال نیز مورد استفاده قرار گرفته‌اند. یکی از ویژگی‌های کلیدی شبکه‌های عصبی کانولوشنی توانایی آن‌ها در استخراج ویژگی‌ها است. ساختار یک شبکه عصبی کانولوشنی معمولاً از سه نوع لایه اصلی تشکیل می‌شود: لایه‌های کانولوشن<sup>۱۳۷</sup>، لایه‌های تجمیع یا کاهش ابعاد و در نهایت لایه‌های کاملاً متصل<sup>۱۳۸</sup>. در لایه‌های

---

<sup>۱۳۵</sup> Non-Linear Activation Function

<sup>۱۳۶</sup> Underfitting

<sup>۱۳۷</sup> Convolutional Layers

<sup>۱۳۸</sup> Fully Connected Layers

کانولوشن، ویژگی‌های ابتدایی مانند لبه‌ها<sup>۱۳۹</sup> یا تغییرات محلی استخراج می‌شوند. لایه‌های تجمیع ابعاد و تعداد پارامترها را کاهش داده و کارایی مدل را افزایش می‌دهند. در نهایت، لایه کاملاً متصل داده‌های چندبعدی را به یک نمایش یک‌بعدی تبدیل کرده و ارتباط میان نوروها را برای تولید خروجی برقرار می‌سازد.

در زمینه پیش‌بینی قیمت رمزارزها، شبکه‌های عصبی کانولوشنی می‌توانند داده‌های تاریخی قیمت را تحلیل کرده و الگوهای مرتبط را استخراج کنند. این شبکه‌ها قادرند الگوهای پیچیده و پنهان موجود در داده‌های سری زمانی را شناسایی کرده و بر اساس روابطی که میان متغیرهای ورودی و متغیر خروجی (در اینجا قیمت ارزهای دیجیتال) یاد گرفته‌اند، پیش‌بینی انجام دهند. با پردازش داده‌های سری زمانی از طریق لایه‌های کانولوشن، شبکه‌های عصبی کانولوشنی به‌طور خودکار ویژگی‌هایی را می‌آموزند که می‌توانند نشانگر تغییرات احتمالی قیمت باشند. ماهیت سلسله‌مراتبی این شبکه‌ها موجب می‌شود که هم وابستگی‌های محلی و هم وابستگی‌های کلی داده‌ها را استخراج کرده و بدین ترتیب به ابزاری کارآمد برای درک و مدل‌سازی الگوهای پیچیده در بازار ارزهای دیجیتال تبدیل شوند (Tabe et al., 2024).

### ۳-۲-۸ شبکه‌های عصبی بازگشتی

شبکه‌های عصبی بازگشتی یکی از مهم‌ترین معماری‌های یادگیری عمیق هستند که به‌طور ویژه برای پردازش داده‌های متوالی و سری‌های زمانی طراحی شده‌اند. برخلاف شبکه‌های عصبی کلاسیک که ورودی‌ها را مستقل از یکدیگر در نظر می‌گیرند، شبکه‌های عصبی بازگشتی توانایی نگهداری و انتقال اطلاعات از گذشته به آینده را دارند. این ویژگی منحصر به فرد، آن‌ها را به ابزاری قدرتمند برای تحلیل داده‌هایی تبدیل می‌کند که وابستگی زمانی یا پیوستگی توالی در آن‌ها وجود دارد. ساختار و عملکرد شبکه‌های عصبی بازگشتی از سه بخش اصلی تشکیل شده‌اند: لایه ورودی، لایه پنهان بازگشتی<sup>۱۴۰</sup> و لایه خروجی. لایه ورودی وظیفه دریافت داده‌های متوالی

---

<sup>۱۳۹</sup> Edge

<sup>۱۴۰</sup> Recurrent Layer

(مانند قیمت روزانه یا ساعتی ارز دیجیتال) را بر عهده دارد. لایه پنهان بازگشتی با استفاده از اتصالات حلقوی قادر است وابستگی میان داده‌های گذشته و حال را مدل‌سازی کند. این مکانیزم باعث می‌شود شبکه در هر لحظه علاوه بر اطلاعات جاری، دانش مربوط به حالت‌های قبلی را نیز در پردازش لحاظ نماید. در نهایت، لایه خروجی نتایج پردازش‌شده را به پیش‌بینی یا طبقه‌بندی نهایی تبدیل می‌کند.

مدل‌های آماری و کلاسیک مانند آریما<sup>۱۴۱</sup> یا رگرسیون خطی تنها قادرند روابط ساده و ایستا را میان داده‌ها شناسایی کنند و اغلب در برابر نوسانات شدید یا الگوهای پیچیده بازارهای مالی ناتوان هستند. در مقابل، شبکه‌های عصبی بازگشتی با بهره‌گیری از حافظه داخلی<sup>۱۴۲</sup> می‌توانند وابستگی‌های بلندمدت<sup>۱۴۳</sup> و کوتاه‌مدت<sup>۱۴۴</sup> را به‌طور هم‌زمان استخراج کنند. این قابلیت در بازارهایی همچون ارزهای دیجیتال که رفتار قیمت به شدت پویا، غیرخطی و غیرایستا است، اهمیت دوچندان دارد. یکی از چالش‌های اصلی در پیش‌بینی قیمت ارزهای دیجیتال، وجود الگوهای پنهان و ناپایداری شدید در داده‌های قیمتی است.

شبکه‌های عصبی بازگشتی با توانایی تحلیل توالی داده‌ها می‌توانند روندهای قیمتی گذشته را درک کرده و بر اساس آن‌ها مسیر حرکت آینده را تخمین بزنند. برای مثال، شبکه می‌تواند از تغییرات متوالی قیمت، حجم معاملات و شاخص‌های تکنیکال یاد بگیرد که چه شرایطی احتمال رشد یا سقوط قیمت را افزایش می‌دهد. علاوه بر داده‌های تاریخی قیمت، شبکه‌های عصبی بازگشتی امکان ترکیب داده‌های متنی و غیرساختاریافته مانند تحلیل احساسات کاربران را نیز دارند. از آنجا که احساسات عمومی نقش مهمی در نوسانات ارزهای دیجیتال ایفا می‌کند، ترکیب داده‌های مالی و متنی در یک مدل شبکه عصبی بازگشتی می‌تواند دقت پیش‌بینی را به شکل قابل توجهی افزایش دهد. نتیجه‌گیری به طور کلی، این مدل‌ها به دلیل توانایی درک روابط زمانی و استخراج وابستگی‌های توالی، رویکردی قدرتمند در پیش‌بینی

---

<sup>۱۴۱</sup> ARIMA

<sup>۱۴۲</sup> Internal Memory

<sup>۱۴۳</sup> Long Term Dependency

<sup>۱۴۴</sup> Short Term Dependency



سری‌های زمانی مالی محسوب می‌شوند. به‌ویژه در بازار پرنوسان و غیرقابل‌پیش‌بینی ارزهای دیجیتال، این شبکه‌ها امکان شناسایی الگوهای پیچیده را فراهم می‌کنند و نسبت به روش‌های سنتی مزیت‌های چشمگیری دارند. ترکیب این معماری با سایر روش‌های یادگیری عمیق مانند حافظه طولانی کوتاه‌مدت و شبکه بازگشتی دروازه‌ای نیز می‌تواند به بهبود پایداری و دقت پیش‌بینی منجر شود که در ادامه این موارد بررسی خواهند شد (Tabe et al., ۲۰۲۴).

### ۳-۲-۹ حافظه طولانی کوتاه مدت

حافظه طولانی کوتاه‌مدت به‌عنوان یکی از مهم‌ترین انواع شبکه‌های عصبی بازگشتی، پاسخی به مشکل بنیادی محوشوندگی گرادیان است. این معماری با طراحی ویژه خود قادر است وابستگی‌های بلندمدت در داده‌های ترتیبی را بهتر از مدل‌های بازگشتی کلاسیک فراگیرد. در حالی که شبکه‌های بازگشتی معمولی در حفظ و انتقال اطلاعات در طول زمان دچار ضعف می‌شوند، مدل حافظه طولانی کوتاه‌مدت با بهره‌گیری از ساختار سلول حافظه و سه دروازه کنترلی، امکان ذخیره‌سازی، فراموشی یا به‌کارگیری گزینشی اطلاعات را فراهم می‌آورد. این سه دروازه کلیدی در این نوع شبکه عبارت‌اند از:

- دروازه ورودی<sup>۱۴۵</sup>: وظیفه دارد تعیین کند چه بخش‌هایی از داده جدید باید وارد حافظه سلولی شوند. این فرآیند معمولاً توسط تابع سیگموید<sup>۱۴۶</sup> انجام می‌شود. در زمینه داده‌های مالی، این دروازه می‌تواند مشخص کند که تغییرات ناگهانی در حجم معاملات اهمیت بیشتری نسبت به نوسانات جزئی قیمت دارد و بنابراین باید در حافظه نگهداری شود.
- دروازه فراموشی<sup>۱۴۷</sup>: این بخش مسئول حذف اطلاعات غیرضروری از وضعیت قبلی شبکه است. به‌طور مثال، اگر یک روند بازار در گذشته برای پیش‌بینی مفید بوده اما در شرایط فعلی بی‌ارتباط باشد، این دروازه آن را از حافظه حذف می‌کند. این

---

<sup>۱۴۵</sup> Input Gate

<sup>۱۴۶</sup> Sigmoid Function

<sup>۱۴۷</sup> Forget Gate

قابلیت به حافظه طولانی کوتاه مدت انعطاف پذیری می دهد تا در هر لحظه تنها داده های مرتبط را در فرآیند یادگیری نگه دارد.

- دروازه خروجی<sup>۱۴۸</sup>: تعیین می کند کدام اطلاعات ذخیره شده در حافظه سلولی باید در تولید خروجی نهایی نقش ایفا کنند. در کاربردهایی مانند پیش بینی قیمت رمزارز، این دروازه اطمینان حاصل می کند که تنها ویژگی های اثرگذار (مانند اخبار یا شاخص های کلان مرتبط) در پیش بینی نهایی لحاظ شوند.

این معماری با توانایی در انتخاب گزینشی داده ها، فراموش کردن اطلاعات غیرکاربردی و تمرکز بر الگوهای مهم، یک چارچوب قدرتمند برای تحلیل داده های غیرایستا و پیچیده به ویژه در حوزه هایی مانند پیش بینی سری های زمانی مالی و رمزارزها فراهم می آورد. به همین دلیل حافظه طولانی کوتاه مدت در مقایسه با شبکه های بازگشتی کلاسیک، دقت بالاتری در مدل سازی روابط بلندمدت و وابستگی های پیچیده ارائه می دهد (Mansourabady et al., 2024).

### ۳-۲-۱۰ حافظه طولانی کوتاه مدت دوطرفه

حافظه طولانی کوتاه مدت دوطرفه نسخه ی توسعه یافته ای از حافظه طولانی کوتاه مدت است که با هدف افزایش توانایی مدل در استخراج وابستگی های زمانی از داده ها معرفی شده است. در حالی که حافظه طولانی کوتاه مدت متعارف تنها قادرند وابستگی ها را در یک جهت (معمولاً از گذشته به آینده) یاد بگیرند، حافظه طولانی کوتاه مدت دوطرفه با استفاده از دو لایه بازگشتی موازی، امکان یادگیری همزمان در دو جهت زمانی را فراهم می سازد:

- لایه روبه جلو<sup>۱۴۹</sup>: داده ها را از ابتدای توالی به انتها پردازش کرده و وابستگی های متوالی را در جهت پیش رونده ثبت می کند.

---

<sup>۱۴۸</sup> Output Gate

<sup>۱۴۹</sup> Forward Layer

- لایه روبه عقب<sup>۱۵۰</sup>: همان داده‌ها را از انتها به ابتدا بررسی کرده و به شبکه اجازه می‌دهد اطلاعات آینده را نیز در فرایند تصمیم‌گیری لحاظ کند.

در نهایت، خروجی این دو لایه با یکدیگر ترکیب شده و نمایش غنی‌تر و دقیق‌تری از توالی داده‌ها تولید می‌شود. این معماری به‌طور ویژه در مسائلی که وابستگی‌های دوطرفه و زمینه‌ای نقش کلیدی دارند (مانند پردازش زبان طبیعی، تشخیص احساسات، برچسب‌گذاری متون، و همچنین پیش‌بینی سری‌های زمانی مالی) عملکرد قابل توجهی نشان می‌دهد.

از منظر ریاضی، حافظه طولانی کوتاه مدت دوطرفه مزیتی اساسی نسبت به حافظه طولانی کوتاه مدت استاندارد دارد: در حالی که حافظه طولانی کوتاه مدت تنها به اطلاعات گذشته متکی است، حافظه طولانی کوتاه مدت دوطرفه قادر است همزمان وابستگی‌های پیشین و آینده را مدل‌سازی کند. این ویژگی موجب افزایش دقت و پایداری در پیش‌بینی‌های مبتنی بر داده‌های پیچیده می‌شود. به عنوان مثال در پیش‌بینی قیمت رمزارزها، در حالی که حافظه طولانی کوتاه مدت صرفاً نوسانات تاریخی را لحاظ می‌کند، حافظه طولانی کوتاه مدت دوطرفه قادر است با تحلیل روندهای بعدی در توالی داده (مانند تغییرات ناگهانی حجم معاملات یا اخبار پس از یک بازه زمانی خاص)، برآورد دقیق‌تری ارائه دهد.

به‌طور کلی، حافظه طولانی کوتاه مدت دوطرفه را می‌توان یک معماری پیشرفته و دوطرفه برای تحلیل داده‌های ترتیبی دانست که ترکیب بهینه‌ای از یادگیری وابستگی‌های گذشته و آینده را فراهم کرده و در حوزه‌های مختلف، به‌ویژه در پردازش زبان و پیش‌بینی‌های مالی، به‌عنوان یکی از قدرتمندترین ابزارهای مبتنی بر شبکه‌های عصبی بازگشتی شناخته می‌شود (Hamayel & Owda, 2021).

### ۳-۲-۱۱ واحد بازگشتی دروازه‌ای

واحدهای بازگشتی دروازه‌ای گونه‌ای از شبکه‌های عصبی بازگشتی هستند که نخستین بار در سال ۲۰۱۴ توسط معرفی شدند و هدف از ارائه آن‌ها، بهبود عملکرد در مقایسه با شبکه‌های حافظه طولانی کوتاه‌مدت بوده است. مشابه با حافظه‌های

---

<sup>۱۵۰</sup> Backward Layer

طولانی کوتاه‌مدت، واحدهای بازگشتی دروازه‌ای قادرند توالی‌های ورودی با طول دلخواه را پردازش کنند و حالتی درونی<sup>۱۵۱</sup> را حفظ کنند که بازنمایی‌کننده اطلاعات گذشته است. با این حال، تفاوت کلیدی واحد بازگشتی دروازه‌ای با حافظه طولانی کوتاه‌مدت در معماری آن‌ها نهفته است؛ در حالی که حافظه طولانی کوتاه‌مدت از چندین دروازه و یک سلول حافظه داخلی برای کنترل جریان اطلاعات بهره می‌برد، واحد بازگشتی دروازه‌دار تنها از دو سازوکار کنترلی استفاده می‌کند: یک دروازه به‌روزرسانی<sup>۱۵۲</sup> برای تصمیم‌گیری در مورد نگهداری اطلاعات و یک دروازه بازنشانی<sup>۱۵۳</sup> برای تعیین اینکه کدام بخش از اطلاعات باید فراموش شود. این سادگی معماری موجب می‌شود واحدهای بازگشتی دروازه‌دار سبک‌تر، سریع‌تر و آسان‌تر برای آموزش باشند، در عین حال که عملکردی قابل مقایسه با شبکه‌های حافظه طولانی کوتاه‌مدت در بسیاری از وظایف ارائه می‌دهند.

مطالعات متعددی به مقایسه این دو معماری پرداخته‌اند. یکی از مزیت‌های برجسته واحدهای بازگشتی دروازه‌ای، توانایی بالای آن‌ها در یادگیری و بازنمایی وابستگی‌های بلندمدت در داده‌های ترتیبی است. این قابلیت از سازوکار انتخابی دروازه‌های به‌روزرسانی و بازنشانی ناشی می‌شود که به شبکه امکان می‌دهد اطلاعات گذشته را بسته به ورودی کنونی و وضعیت درونی، به‌صورت پویا حفظ یا حذف کند. از این رو، واحدهای بازگشتی دروازه‌ای به‌ویژه برای مسائلی مانند ترجمه ماشینی، مدل‌سازی زبان و سایر کاربردهایی که نیازمند بهره‌گیری از توالی‌های طولانی هستند، کارایی بالایی دارند (Hamayel & Owda, 2021).

## ۳-۲-۱۲ تحلیل احساسات

رشد سریع و روزافزون اینترنت منجر به تولید حجم عظیمی از داده‌های متنی شامل اخبار، دیدگاه‌ها و نظرات شده است. تحلیل احساسات به عنوان روشی نظام‌مند برای استخراج و تفسیر نگرش‌ها و عواطف افراد درباره موضوعات، محصولات و خدمات،

---

<sup>۱۵۱</sup> Hidden State

<sup>۱۵۲</sup> Update Gate

<sup>۱۵۳</sup> Reset Gate

نقش مهمی در پشتیبانی از تصمیم‌گیری‌های سازمان‌ها، دولت‌ها و سرمایه‌گذاران ایفا می‌کند. با این حال، پیچیدگی زبان طبیعی، ساختار جملات و تفاوت‌های حوزه‌ای، فرایند تحلیل و تعیین قطبیت احساس را با چالش‌هایی جدی مواجه ساخته است. در سال‌های اخیر، تحلیل احساسات به‌ویژه در حوزه مالی و رمزارزها اهمیت ویژه‌ای یافته است. نوسانات بازار رمزارزها به شدت تحت تأثیر اخبار، سیاست‌های کلان و واکنش‌های عمومی قرار دارد و بررسی احساسات منتشرشده در شبکه‌های اجتماعی و خبرگزاری‌ها می‌تواند پیش‌بینی روند صعود یا نزول بازار را تسهیل کند. مطالعات نشان می‌دهند که محتوای مثبت در رسانه‌ها سبب افزایش تقاضا برای رمزارزها و محتوای منفی موجب افت آن‌ها می‌شود. روش‌های متنوعی برای تحلیل احساسات وجود دارد؛ از رویکردهای مبتنی بر قواعد و الگوریتم‌های کلاسیک یادگیری ماشین گرفته تا مدل‌های پیشرفته یادگیری عمیق و ترانسفورمرها. با وجود پیشرفت‌ها، مسائلی چون ابهام معنایی و محدودیت انتقال‌پذیری مدل‌ها بین حوزه‌های مختلف، همچنان از چالش‌های اصلی این حوزه محسوب می‌شوند (Valencia et al., ۲۰۱۹). در این تحقیق از سه روش نوین برای این امر استفاده شده است که در ادامه مورد بررسی قرار می‌گیرد.

### 13-2-3 متد های تحلیل احساسات استفاده شده

ظهور مدل‌های مبتنی بر ترانسفورمر، به‌ویژه برت<sup>۱۵۴</sup>، تحولی بنیادین در حوزه پردازش زبان طبیعی ایجاد کرد. با این حال، برت در نسخه‌ی پایه‌ی خود بر روی داده‌های عمومی نظیر ویکیپدیا<sup>۱۵۵</sup> و بوک‌کورپس<sup>۱۵۶</sup> آموزش دیده و از این‌رو، درک دقیقی از متون تخصصی مرتبط با بازارهای مالی و رمزارزها ندارد. برای رفع این محدودیت، مدل‌های برت حوزه‌محور<sup>۱۵۷</sup> معرفی شدند که چند مورد از مهم‌ترین آن‌ها در زمینه رمزارز در ادامه بررسی می‌شوند که در این تحقیق استفاده شده‌اند:

---

<sup>۱۵۴</sup> Bidirectional Encoder Representations from Transformers (BERT)

<sup>۱۵۵</sup> Wikipedia

<sup>۱۵۶</sup> BookCorpus

<sup>۱۵۷</sup> Domain-Specific BERT

- کریپتوبرت<sup>۱۵۸</sup>: این مدل در واقع نسخه‌ای بازآموزی شده<sup>۱۵۹</sup> از برت است که بر روی حجم عظیمی از متون مرتبط با رمزارزها و فناوری بلاکچین آموزش دیده است. داده‌های آموزشی این مدل شامل اخبار مالی، مقالات علمی تخصصی، انجمن‌های رمزارزی و گزارش‌های رسمی پروژه‌های بلاکچینی می‌باشد. این داده‌ها سبب می‌شوند که کریپتوبرت قادر به درک دقیق‌تر واژگان و همچنین اصطلاحات استعاری حوزه مالی باشد که در متون عمومی معنای متفاوتی دارند. از کاربردهای اصلی کریپتوبرت در حوزه رمزارز را می‌توان تحلیل احساسات اشاره کرد که در این تحقیق استفاده شده است. مزیت اصلی کریپتوبرت نسبت به برت، توانایی درک معنایی عمیق‌تر در متون تخصصی رمزارزی است. این ویژگی موجب افزایش دقت در وظایفی چون تحلیل احساسات و پیش‌بینی رفتار بازار می‌شود. با این حال، چالش‌هایی همچنان وجود دارد از جمله پویایی سریع حوزه رمزارز، نویز داده‌ها و انتقال‌پذیری محدود. به طور کلی، کریپتوبرت گامی مهم در جهت بهره‌گیری از مدل‌های زبانی حوزه‌محور برای تحلیل رفتار بازارهای مالی دیجیتال محسوب می‌شود و می‌تواند به عنوان ابزاری کلیدی در مطالعات مرتبط با تحلیل احساسات و پیش‌بینی بازار رمزارزها مورد استفاده قرار گیرد.

- فاین‌برت<sup>۱۶۰</sup>: یک مدل زبانی مبتنی بر معماری برت است که به‌طور خاص برای حوزه‌ی متون مالی و اقتصادی طراحی و بازآموزی شده است. این مدل ابتدا بر روی مجموعه داده‌های عمومی همانند نسخه اصلی برت آموزش دیده، سپس با بهره‌گیری از داده‌های مالی تخصصی شامل گزارش‌های سالانه شرکت‌ها، اخبار اقتصادی، تحلیل‌های بازار سرمایه و متون بورس اوراق بهادار بازآموزی شده است. ویژگی‌های اصلی برت عبارت‌اند از تحلیل احساسات مالی و واژگان تخصصی اقتصادی. مزیت فاین‌برت این است که بر خلاف مدل‌های عمومی پردازش زبان طبیعی، قادر به تشخیص ظرایف معنایی در متون اقتصادی است؛ برای مثال، واژه‌ی ناپایدار<sup>۱۶۱</sup> در متون عمومی بار معنایی

---

<sup>۱۵۸</sup> CryptoBERT

<sup>۱۵۹</sup> Fine-Tuned

<sup>۱۶۰</sup> FinBERT

<sup>۱۶۱</sup> Volatile

منفی دارد، اما در حوزه مالی لزوماً نشانه‌ی بد بودن نیست بلکه بیانگر یک ویژگی بازار است.

- دیستیل‌روبرتا<sup>۱۶۲</sup>: این مدل نسخه‌ی فشرده و بهینه‌شده‌ی روبرتا<sup>۱۶۳</sup> است. روبرتا خود بر پایه معماری برت ساخته شده اما با داده‌های بسیار بزرگ‌تر و تنظیمات بهینه‌تر آموزش دیده است. دیستیل‌روبرتا با استفاده از روش خاصی تولید شده که تلاش می‌کند با حفظ بیشترین میزان دانش مدل اصلی، اندازه و پیچیدگی آن را کاهش دهد. نسخه‌ی بازآموزی‌شده آن بدین معناست که مدل دیستیل‌روبرتا پس از مرحله فشرده‌سازی، بر روی یک وظیفه خاص مثل تحلیل احساسات، دسته‌بندی متون یا تشخیص عواطف بازآموزی شده است. از ویژگی‌های اصلی این مدل می‌شود به سبک‌تر و سریع‌تر بودن و حفظ کارایی قابل مقایسه با مدل‌های بزرگ‌تر اشاره کرد.

### ۳-۳ معیارهای ارزیابی

برای ارزیابی نتایج پیش‌بینی ارزش‌های دیجیتال توسط مدل‌ها، معیارهای مختلفی مورد استفاده قرار می‌گیرد که در این تحقیق از پنج مورد از معروف‌ترین آن‌ها استفاده شده است.

میانگین مطلق خطا اولین نوع معیار است که ساده‌ترین و پایه‌ای‌ترین معیار به شمار می‌آید. این معیار در اصل اختلاف بین مقادیر واقعی و پیش‌بینی شده را می‌دهد که در فرمول (۱) نشان داده شده است (Tabe et al., ۲۰۲۴). میزان کمتر در این معیار، بهتر بودن عملکرد مدل را نشان می‌دهد.

$$MAE = \frac{\sum |y_i - \hat{y}_i|}{n} \quad (1)$$

---

<sup>۱۶۲</sup> Distilroberta

<sup>۱۶۳</sup> RoBERTa (Robustly Optimized BERT Pretraining Approach)

خطای میانگین مربعات نوع دیگری از معیارهای معرف استفاده شده در موارد رگرسیون است (Tabe et al., ۲۰۲۴). در این معیار، ابتدا اختلاف بین مقدار واقعی و مقدار پیش‌بینی شده حساب می‌شود، سپس آن را به توان ۲ رسانده و در آخر هم میانگین آن در حساب می‌شود. خطای میانگین مربعات در فرمول (۲) نشان داده شده است. مقدار خطای میانگین مربعات هرچه که نزدیک‌تر به صفر باشد، نشان دهنده عملکرد بهتر در پیش‌بینی است.

$$MSE = \frac{\sum (y_i - \hat{y}_i)^2}{n} \quad (۲)$$

جذر میانگین مربعات خطا در فرمول (۳) نشان داده شده است که می‌توان آن را به عنوان انحراف معیار تفسیر کرد. طبق این معیار هر چه نتیجه به صفر نزدیک‌تر باشد نشان دهنده عملکرد بهتر مدل است. اگر در مجموعه داده اعداد بزرگ باشند، عموماً این معیار، نتایج بهتری را نسبت به خطای میانگین مربعات ارائه می‌دهد (Mansourabady et al., ۲۰۲۴).

$$RMSE = \sqrt{\frac{\sum (y_i - \hat{y}_i)^2}{n}} \quad (۳)$$

میانگین درصد خطا مطلق نسبی برای اندازه‌گیری درصدی میانگین تفاوت مطلق بین مقادیر پیش‌بینی شده و مقادیر واقعی مدل استفاده می‌شود. تفاوت مطلق درصدی برای هر نقطه داده، با محاسبه تفاوت مطلق بین مقدار پیش‌بینی شده و مقدار واقعی محاسبه می‌شود؛ سپس بر مقدار واقعی تقسیم شده و در نهایت در ۱۰۰ ضرب می‌شود تا به درصد تبدیل شود. استفاده از قدرمطلق برای این است که مقادیر منفی در جمع کنترل شوند (Mansourabady et al., ۲۰۲۴).

$$MAPE = \frac{1}{n} * \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| * 100 \quad (۴)$$



در هر چهار فرمول نوشته شده،  $y_i$  مقدار واقعی،  $\hat{y}_i$  مقدار پیش‌بینی شده توسط مدل و  $n$  تعداد کل داده‌ها است.

### ۴-۳ روش پژوهش

برنامه نویسی این تحقیق توسط زبان پایتون نسخه ۳.۱۳ و در بستر Visual Code نوشته شده است. زیرساخت مورد استفاده شامل پردازنده Intel Core i7 12700K، کارت گرافیک Nvidia GeForce RTX 3070Ti و 32 گیگابایت رم بوده است. داده‌های جمع‌آوری شده برای این تحقیق در ادامه بررسی خواهد شد که به دو قسمت تقسیم می‌شود: داده‌های تاریخی به همراه سایر ویژگی‌ها و اندیکاتور و اخبار. سپس مدل‌ها و مدل پیشنهادی شرح داده خواهند شد.

### ۱-۴-۳ داده‌های تاریخی به همراه سایر ویژگی‌ها و اندیکاتور

اولین دسته داده‌ها، داده‌های تاریخی ارزش‌های دیجیتال اتریوم و بایننس است. بخشی از داده‌ها که مربوط به قیمت هستند به صورت مستقیم از سایت کوین مارکت کپ گرفته شده‌اند که شامل اطلاعات اصلی شمع‌ها<sup>۱۶۴</sup> هستند به همراه حجم معاملات<sup>۱۶۵</sup>. علاوه بر این داده‌ها، در این تحقیق از شاخص حرص و طمع نیز استفاده شده است که نتیجه گرفته شده، تاثیر مثبت این ویژگی را اثبات می‌کند. علاوه بر موارد ذکر شده، از آنجایی که بیت‌کوین حکم مادر ارزش‌های دیجیتال را دارد، از قیمت بسته‌شدن و حجم معاملات این ارز هم برای پیش‌بینی بایننس و اتریوم استفاده شده است تا تاثیر این ارزش دیجیتال هم حساب شود. تمام موارد ذکر شده از ویژگی‌های اضافه شده گرفته تا تاثیر قیمت بیت‌کوین همگی نوآوری‌های این تحقیق به شمار می‌آیند. به عنوان آخرین ویژگی این دسته می‌توان به اندیکاتور

---

<sup>۱۶۴</sup> Candle Stick

<sup>۱۶۵</sup> Volume

شاخص قدرت نسبی با مقدار <sup>۱۶۶</sup>۱۴ اشاره کرد. طبق تحقیق‌های صورت گرفته مقدار ۱۴ از این اندیکاتور طبق تحقیق و تجربه کردن بدست آمده‌است و انتخاب اندیکاتور هم دقیقاً بر همین اساس بوده است.

اتریوم به عنوان دومین ارز دیجیتال بزرگ پس از بیت‌کوین، نه تنها یک دارایی سرمایه‌ای است، بلکه به دلیل ماهیت پلتفرمی خود، شاخصی کلیدی در کل اکوسیستم بلاکچین محسوب می‌شود. نوسانات قیمتی اتریوم به شدت بر روی بازارهای فرعی و قراردادهای هوشمند اثرگذار است و همین امر موجب می‌شود پیش‌بینی دقیق قیمت آن برای سرمایه‌گذاران، توسعه‌دهندگان و حتی سیاست‌گذاران حوزه مالی غیرمتمرکز اهمیت مضاعف پیدا کند. برخلاف بیت‌کوین که عمدتاً یک ذخیره ارزش و ابزار مبادله تلقی می‌شود، ارزش اتریوم به شدت با کاربردپذیری شبکه و حجم تراکنش‌های درون‌زنجیره‌ای گره خورده است، بنابراین پیش‌بینی قیمت آن نیازمند مدلسازی پیچیده‌تر و تحلیل چندبعدی داده‌هاست.

از منظر تحقیقاتی، پیش‌بینی قیمت اتریوم تنها به عنوان یک مسئله مالی مطرح نیست، بلکه می‌تواند نشان‌دهنده‌ی روند تکامل فناوری بلاکچین و شاخصی از پذیرش عمومی قراردادهای هوشمند در صنایع مختلف باشد. الگوریتم‌های یادگیری عمیق و مدل‌های پیشرفته سری‌های زمانی مانند واحد بازگشتی دروازه‌ای نقش مهمی در استخراج الگوهای نهفته از داده‌های تاریخی، شاخص‌های احساسات بازار و متغیرهای کلان اقتصادی مرتبط با اتریوم دارند. دقت بالا در پیش‌بینی این ارز نه تنها موجب بهبود استراتژی‌های معاملاتی و کاهش ریسک سرمایه‌گذاری می‌شود، بلکه درک عمیق‌تری از پویایی بازارهای مالی غیرمتمرکز را فراهم می‌سازد و می‌تواند مبنای علمی برای تصمیم‌سازی در سطح کلان باشد (Kaur et al., ۲۰۲۵).

بایننس کوین توکن بومی اکوسیستم بایننس <sup>۱۶۷</sup> است که ابتدا در شبکه اتریوم راه‌اندازی شد و سپس به بلاکچین اختصاصی خود منتقل گردید. این توکن در ابتدا به عنوان ابزاری برای کاهش کارمزدهای معاملاتی در صرافی بایننس عرضه شد، اما

---

<sup>۱۶۶</sup> Relative Strength Index (RSI)

<sup>۱۶۷</sup> The Binance Ecosystem

امروزه کارکردهای آن به مراتب گسترده‌تر شده است و اکنون نقشی کلیدی در پرداخت هزینه تراکنش‌های شبکه، مشارکت در رأی‌گیری‌های حاکمیتی، استیکینگ، اجرای قراردادهای هوشمند و همچنین تأمین نقدینگی در برنامه‌های غیرمتمرکز ایفا می‌کند. این تنوع کاربرد، این ارز را از یک ابزار صرفاً معاملاتی به یک عنصر زیرساختی در اکوسیستم وب ۳ و دیفای تبدیل کرده است. در واقع، بایننس نه تنها ابزاری برای کارایی بیشتر صرافی بایننس محسوب می‌شود، بلکه به‌عنوان ستون اصلی یک اکوسیستم بلاک‌چینی چندوجهی عمل می‌کند که رقابتی جدی با اتریوم و سایر پلتفرم‌های قرارداد هوشمند دارد.

داده‌های قیمت این دو ارز دیجیتال که از کوین‌مارکت‌کپ گرفته شده‌اند شامل ویژگی‌های قیمت بازشدن، قیمت بسته شدن، بیشترین قیمت، کمترین قیمت، حجم معاملات و ارزش بازار آن‌ها است که در شکل زیر نمونه‌ای از آن مشاهده می‌شود. داده‌های دو ارز دیجیتال استفاده شده در این تحقیق یعنی بایننس و اتریوم، از ابتدای ماه دوم سال ۲۰۱۸ تا اواسط ماه هفتم سال ۲۰۲۵ جمع‌آوری شده‌اند که در شکل زیر نمونه از داده اتریوم نمایش داده شده‌است.

open	high	low	close	volume	marketCap	timestamp
1119.369995	1161.349976	984.8189697	1036.790039	5261680128	1.00935E+11	2018-02-01 23:59:59.999000+00:00
1035.77002	1035.77002	757.9799805	915.7849731	6713290240	89173962074	2018-02-02 23:59:59.999000+00:00
919.2109985	991.9429932	847.6900024	964.0189819	3243480064	93890299032	2018-02-03 23:59:59.999000+00:00
964.6669922	969.0319824	805.0640259	834.6820068	2997090048	81310521832	2018-02-04 23:59:59.999000+00:00
834.9580078	856.6459961	644.598999	697.9509888	4269530112	68005284183	2018-02-05 23:59:59.999000+00:00
707.7369995	796.4390259	574.4190063	793.1220093	6518269952	77294507868	2018-02-06 23:59:59.999000+00:00
790.4279785	851.2000122	723.4329834	757.0679932	3896179968	73796288509	2018-02-07 23:59:59.999000+00:00
755.8430176	845.0859985	755.8430176	817.8070068	3708189952	79733609806	2018-02-08 23:59:59.999000+00:00
818.4799805	884.0040283	788.8339844	883.8649902	2495820032	86191922699	2018-02-09 23:59:59.999000+00:00
882.46698	917.4000244	825.5770264	860.414978	2930530048	83922989198	2018-02-10 23:59:59.999000+00:00
859.2880249	859.2880249	788.2219849	814.6599731	2486650112	79476512347	2018-02-11 23:59:59.999000+00:00
817.5079956	875.9370117	817.5079956	868.7069702	2243450112	84767037716	2018-02-12 23:59:59.999000+00:00
869.2930298	870.7089844	828.8369751	845.2579956	2081170048	82496189206	2018-02-13 23:59:59.999000+00:00
844.2789917	926.4290161	844.2789917	923.5609741	2818370048	90157005929	2018-02-14 23:59:59.999000+00:00
923.7280273	951.947998	911.1110229	936.9760132	2900100096	91485862822	2018-02-15 23:59:59.999000+00:00
934.7860107	950.0050049	917.8480225	944.210022	2369449984	92211437654	2018-02-16 23:59:59.999000+00:00
944.7479858	976.5949707	940.7540283	974.1149902	2525720064	95151956513	2018-02-17 23:59:59.999000+00:00
973.348999	982.9329834	915.4450073	923.9210205	2567290112	90267805476	2018-02-18 23:59:59.999000+00:00
921.6680298	957.7769775	921.5540161	943.8649902	2169019904	92235641556	2018-02-19 23:59:59.999000+00:00
943.5670166	965.2650146	892.9539795	895.3709717	2545260032	87514997546	2018-02-20 23:59:59.999000+00:00
894.1350098	912.375	830.5629883	849.9710083	2531729920	83095081059	2018-02-21 23:59:59.999000+00:00
849.2620239	875.9260254	802.6680298	812.8449707	2150370048	79482140044	2018-02-22 23:59:59.999000+00:00
811.585022	886.3179932	794.7910156	864.1890259	2334820096	84520567485	2018-02-23 23:59:59.999000+00:00
861.5930176	879.5310059	818.5499878	840.5150146	1926579968	82222377928	2018-02-24 23:59:59.999000+00:00
839.4589844	853.1459961	822.3809814	844.8099976	1646960000	82659602549	2018-02-25 23:59:59.999000+00:00
845.2780151	880.3920288	842.3189697	869.3150024	2044480000	85074973200	2018-02-26 23:59:59.999000+00:00
870.3649902	896.2589722	867.0969849	878.2650146	2053980032	85968788108	2018-02-27 23:59:59.999000+00:00

شکل ۳-۴-۱ - نمونه‌ای از داده‌های خام تاریخی اتریوم

### ۲-۴-۳ اخبار

اخبار استفاده شده برای بخش دوم یعنی تحلیل احساسات از اخبار گوگل<sup>۱۶۸</sup> توسط کتابخانه موجود در پایتون دریافت شده‌است. تعداد 30 عنوان اخبار برای بازه داده های قیمت تاریخی گرفته شده‌اند. بدین صورت مجموعه داده بزرگی برای اخبار تشکیل شده‌است. این عناوین عبارت‌اند از: bitcoin، btc، cryptocurrency، bitcoin market، dumps، DeFi، ETF، ban، pump، crash، crash، explodes، crashes، adoption، Web3، panic، liquidation، whale، eth، ethereum، greed، fear، optimism، bearish، bullish، bnb و binance coin، sol، solana، xrp، ripple. دیتاست تشکیل شده شامل

<sup>۱۶۸</sup> Google Trends

عنوان، سایت مرجع، تاریخ انتشار و آدرس سایت خبر است. نمونه‌ای از این داده‌ها در شکل زیر مشاهده می‌شود.

date	title	source	link
Fri, 02 Feb 2018 08:00:00 GMT	Making a Crypto Utopia in Puerto Rico (Published 2018)	The New York Times	<a href="https://news.google.com/rss/articles/CBMiGwFBV95cUxQVepC02yUf3eJhwQ3Z5Zl">https://news.google.com/rss/articles/CBMiGwFBV95cUxQVepC02yUf3eJhwQ3Z5Zl</a>
Thu, 01 Feb 2018 08:00:00 GMT	Can cryptocurrencies and blockchain help fight corruption?	Brookings	<a href="https://news.google.com/rss/articles/CBMiAFBV95cUxP5IEJR3RQZ5seU0MMW4Yl">https://news.google.com/rss/articles/CBMiAFBV95cUxP5IEJR3RQZ5seU0MMW4Yl</a>
Thu, 01 Feb 2018 08:00:00 GMT	Cryptocurrency Regulation in 2018: Where The World Stands Right Now	Bitcoin Magazine	<a href="https://news.google.com/rss/articles/CBMiAFBV95cUxQZ0uQZ7GNVhW4V2S3W">https://news.google.com/rss/articles/CBMiAFBV95cUxQZ0uQZ7GNVhW4V2S3W</a>
Fri, 02 Feb 2018 08:00:00 GMT	Over \$100 billion wiped off global cryptocurrency market in 24 hours	CNBC	<a href="https://news.google.com/rss/articles/CBMiGwFBV95cUxNS4JtFtWNTN4Z2dQZ5Ux">https://news.google.com/rss/articles/CBMiGwFBV95cUxNS4JtFtWNTN4Z2dQZ5Ux</a>
Fri, 02 Feb 2018 08:00:00 GMT	Bitcoin briefly tumbles below \$8,000, as crypto crater	MarketWatch	<a href="https://news.google.com/rss/articles/CBMiAFBV95cUxQZ2F0cUhgJf58fyQJNk4Df">https://news.google.com/rss/articles/CBMiAFBV95cUxQZ2F0cUhgJf58fyQJNk4Df</a>
Fri, 02 Feb 2018 08:00:00 GMT	Why the Bitcoin Bubble is Bursting, but Cryptocurrency's Future is Still Bright	Inc.com	<a href="https://news.google.com/rss/articles/CBMiGwFBV95cUxNq3IOVxeEzMMWMyNDYfb">https://news.google.com/rss/articles/CBMiGwFBV95cUxNq3IOVxeEzMMWMyNDYfb</a>
Fri, 02 Feb 2018 08:00:00 GMT	Behind the scenes of a modern-day Gold Rush	oregonbusiness.com	<a href="https://news.google.com/rss/articles/CBMiGwFBV95cUxNM3BZUcUxV9H01UJZT2T">https://news.google.com/rss/articles/CBMiGwFBV95cUxNM3BZUcUxV9H01UJZT2T</a>
Fri, 02 Feb 2018 08:00:00 GMT	Bitcoin's Big Wipeout Erased \$46 Billion of Value Last Month	Bloomberg	<a href="https://news.google.com/rss/articles/CBMiAFBV95cUxN8QDM1V4x0c0d02S8ka">https://news.google.com/rss/articles/CBMiAFBV95cUxN8QDM1V4x0c0d02S8ka</a>
Fri, 02 Feb 2018 08:00:00 GMT	Bank Of America Bans Credit Card Crypto Purchases	PYMNTS.com	<a href="https://news.google.com/rss/articles/CBMiAFBV95cUxQM0XYJDZ2HhJdmi3TTQ2cI">https://news.google.com/rss/articles/CBMiAFBV95cUxQM0XYJDZ2HhJdmi3TTQ2cI</a>
Fri, 02 Feb 2018 08:00:00 GMT	Bitcoin, bitcoin, ponziCoin: jokes and scams fuel a cryptocurrency gold rush	The Guardian	<a href="https://news.google.com/rss/articles/CBMiGwFBV95cUxOWGZYZfG5GZ0N0x1YQ3YI">https://news.google.com/rss/articles/CBMiGwFBV95cUxOWGZYZfG5GZ0N0x1YQ3YI</a>
Thu, 01 Feb 2018 08:00:00 GMT	Bitcoin bubble is starting to look a lot like the tulip speculative bubble	Monash Lens	<a href="https://news.google.com/rss/articles/CBMiGwFBV95cUxDTnZZN1NpOfU1avHq044F">https://news.google.com/rss/articles/CBMiGwFBV95cUxDTnZZN1NpOfU1avHq044F</a>
Thu, 01 Feb 2018 08:00:00 GMT	Massive Simonioy Cryptocurrency Botnet Rakes In Millions	Threat Post	<a href="https://news.google.com/rss/articles/CBMiAFBV95cUxOMgYfT7N4J0S3VEUxU4S">https://news.google.com/rss/articles/CBMiAFBV95cUxOMgYfT7N4J0S3VEUxU4S</a>
Fri, 02 Feb 2018 08:00:00 GMT	Texas regulators take swing at another cryptocurrency company	Austin American-Statesman	<a href="https://news.google.com/rss/articles/CBMiAFBV95cUxQaGqNNH0XGHDf0FVWVJFV">https://news.google.com/rss/articles/CBMiAFBV95cUxQaGqNNH0XGHDf0FVWVJFV</a>
Thu, 01 Feb 2018 08:00:00 GMT	The Multi-Billion Dollar Plagiarism Scandal	Plagiarism Today	<a href="https://news.google.com/rss/articles/CBMiAFBV95cUxOVks1MU4Nsa1Q2Yk4yam96">https://news.google.com/rss/articles/CBMiAFBV95cUxOVks1MU4Nsa1Q2Yk4yam96</a>
Thu, 01 Feb 2018 08:00:00 GMT	Real estate cryptocurrency startup Deadcoin secures SEC registration	Inman	<a href="https://news.google.com/rss/articles/CBMiAFBV95cUxQJfJ0ZCxc0h4LXZYNEcyNv">https://news.google.com/rss/articles/CBMiAFBV95cUxQJfJ0ZCxc0h4LXZYNEcyNv</a>
Thu, 01 Feb 2018 08:00:00 GMT	BITCOIN 101: A beginner's guide to understanding the cryptocurrency, illustrated like a children's book	Business Insider	<a href="https://news.google.com/rss/articles/CBMiGwFBV95cUxN4u1J1M4WZVAbnlg1X29J2T1">https://news.google.com/rss/articles/CBMiGwFBV95cUxN4u1J1M4WZVAbnlg1X29J2T1</a>
Fri, 02 Feb 2018 08:00:00 GMT	19-year-old bitcoin millionaire: Here's how much you should invest in cryptocurrencies	CNBC	<a href="https://news.google.com/rss/articles/CBMiGwFBV95cUxP7Gds5W9yTtB4HYVNRFA25S">https://news.google.com/rss/articles/CBMiGwFBV95cUxP7Gds5W9yTtB4HYVNRFA25S</a>
Thu, 01 Feb 2018 08:00:00 GMT	Peter Thiel Says, 'Bitcoin' Is Libertarian, A.I. Is Communist, 'Bitcoin' What the Heck Does That Mean?	Inc.com	<a href="https://news.google.com/rss/articles/CBMiAFBV95cUxQV3kTE9MQJZ5DfYOFBDS2IeHGN1">https://news.google.com/rss/articles/CBMiAFBV95cUxQV3kTE9MQJZ5DfYOFBDS2IeHGN1</a>
Thu, 01 Feb 2018 08:00:00 GMT	Bitcoin's January fall wipes off \$44bn in value	The Guardian	<a href="https://news.google.com/rss/articles/CBMiAFBV95cUxOeThdU9VehNpJdKefBwQ2">https://news.google.com/rss/articles/CBMiAFBV95cUxOeThdU9VehNpJdKefBwQ2</a>
Fri, 02 Feb 2018 08:00:00 GMT	Bitcoin biggest bubble in history, says economist who predicted 2008 crash	The Guardian	<a href="https://news.google.com/rss/articles/CBMiGwFBV95cUxNTlyMgy6V4bm2wdbJ3nB">https://news.google.com/rss/articles/CBMiGwFBV95cUxNTlyMgy6V4bm2wdbJ3nB</a>
Fri, 02 Feb 2018 08:00:00 GMT	Bitcoin's 'Bitcoin' Premium Has Vanished	Bloomberg	<a href="https://news.google.com/rss/articles/CBMiGwFBV95cUxP5W5Gv9fRfVp4gJ8FNe">https://news.google.com/rss/articles/CBMiGwFBV95cUxP5W5Gv9fRfVp4gJ8FNe</a>
Thu, 01 Feb 2018 08:00:00 GMT	The long (and growing) list of factors weighing on Bitcoin and cryptocurrency	investinglive	<a href="https://news.google.com/rss/articles/CBMiAFBV95cUxOWUln0e0GZEMORNS2Wx">https://news.google.com/rss/articles/CBMiAFBV95cUxOWUln0e0GZEMORNS2Wx</a>
Fri, 02 Feb 2018 08:00:00 GMT	Samsung Begins Manufacturing ASIC Chips for Mining Cryptocurrency	extremetech.com	<a href="https://news.google.com/rss/articles/CBMiGwFBV95cUxObk2zcFjmQ0qQdWRNtNmV">https://news.google.com/rss/articles/CBMiGwFBV95cUxObk2zcFjmQ0qQdWRNtNmV</a>
Fri, 02 Feb 2018 08:00:00 GMT	Bitcoin value drops below \$8,500	The Verge	<a href="https://news.google.com/rss/articles/CBMiGwFBV95cUxNcE23TfVCVtYh5Srm8mVl">https://news.google.com/rss/articles/CBMiGwFBV95cUxNcE23TfVCVtYh5Srm8mVl</a>
Fri, 02 Feb 2018 08:00:00 GMT	Cryptocurrency milestone: Milwaukee-area jewelry store chain begins accepting bitcoin	Milwaukee Journal Sentinel	<a href="https://news.google.com/rss/articles/CBMiAFBV95cUxN4d0T7WzYVW4RvUvZ2F3">https://news.google.com/rss/articles/CBMiAFBV95cUxN4d0T7WzYVW4RvUvZ2F3</a>
Thu, 01 Feb 2018 08:00:00 GMT	What the Coincheck hack means for the future of blockchain security	MIT Technology Review	<a href="https://news.google.com/rss/articles/CBMiGwFBV95cUxQzUhgZmg5eDcaUk5TWF0c">https://news.google.com/rss/articles/CBMiGwFBV95cUxQzUhgZmg5eDcaUk5TWF0c</a>
Thu, 01 Feb 2018 08:00:00 GMT	A giant botnet is forcing Windows servers to mine cryptocurrency	ZDNet	<a href="https://news.google.com/rss/articles/CBMiGwFBV95cUxQVdGd8RmZNBvUJ2zpl">https://news.google.com/rss/articles/CBMiGwFBV95cUxQVdGd8RmZNBvUJ2zpl</a>

شکل ۳-۴-۱ - نمونه‌ای از اخبار تحت عنوان *cryptocurrency*

## ۳-۴-۳ پیش‌پردازش داده‌ها

در ابتدا کار با حذف ویژگی‌های کم‌اهمیت و تکراری شروع شده‌است. در داده‌های قیمت تاریخی قیمت بازشدن، بیشترین قیمت، کمترین قیمت و ارزش بازار حذف شدند چرا که همبستگی<sup>۱۶۹</sup> زیادی با قیمت بسته شدن دارند و نیازی به وجود آن‌ها نیست. همچنین لازم به ذکر است که در اکثر پژوهش‌ها، برای پیش‌بینی قیمت تنها از قیمت بسته شدن استفاده شده است. سپس قیمت بسته شدن و حجم معاملات توسط نرمال‌سازی به بازه 0 تا 1 برده شده است که به این روش Min-Max گفته می‌شود و فرمول آن به صورت زیر است:

$$x_{normalized} = \frac{x_{original} - x_{min}}{x_{max} - x_{min}}$$

<sup>۱۶۹</sup> Correlation

همچنین داده‌هایی که بیشتر از 95 درصد یا کمتر از 5 درصد کل داده‌ها باشند، با میانگین داده‌های قبل و بعد جایگزین شده‌اند تا داده بدون نویز باشد.

### ۴-۴-۳ تحلیل احساسات اخبار

برای تحلیل احساسات اخبار گرفته شده، از سه مدل متفاوت استفاده شده است که این مدل‌ها عبارت‌اند از کریپتوبرت، دیستیل‌روبرت و فاین‌برت. هر سه مدل بر اساس برت هستند و توانایی بالایی در تحلیل احساسات با دقت بالا دارند. مدل‌ها به‌ازا هر خبر دو خروجی می‌دهند، اولین خروجی کلاس و نوع خبر را مشخص می‌کند که یا مثبت است یا منفی یا خنثی و دومین خروجی، احتمال یا میزان اطمینان از کلاس داده شده را مشخص می‌کند. سپس اخبار توسط میانگین‌گیری وزن‌دار به صورت روزانه در می‌آیند، چرا که تایم فریم داده‌ها یک روزه بوده‌است. برای داده‌های آغازین یعنی سال 2018 ممکن است خبری وجود نداشته باشد که برای این روزها، عدد 2- جایگذاری شده است. نمونه‌ای از نتیجه تحلیل احساسات را می‌توان در شکل زیر مشاهده کرد.

date	cryptobert_label	cryptobert_score	distilroberta_label	distilroberta_score	finbert_label	finbert_score
Fri, 02 Feb 2018 08:00:00 GMT	Neutral	0.743702173	positive	0.980845332	Neutral	0.728892386
Mon, 05 Feb 2018 18:05:25 GMT	Neutral	0.541872442	neutral	0.999860048	Neutral	0.99991703
Mon, 05 Feb 2018 18:07:38 GMT	Bullish	0.56179142	neutral	0.999882936	Neutral	0.99994123
Wed, 07 Feb 2018 07:06:03 GMT	Neutral	0.544213235	neutral	0.995571196	Negative	0.913323998
Wed, 07 Feb 2018 02:08:18 GMT	Neutral	0.796974063	neutral	0.999822915	Neutral	0.999982715
Wed, 07 Feb 2018 03:51:32 GMT	Bullish	0.668858469	neutral	0.999856353	Neutral	0.999927402
Wed, 07 Feb 2018 03:54:23 GMT	Neutral	0.536501527	neutral	0.953971684	Neutral	0.999854326
Tue, 06 Feb 2018 23:49:45 GMT	Bullish	0.538800538	neutral	0.999834299	Neutral	0.999853015
Wed, 07 Feb 2018 02:08:46 GMT	Neutral	0.615441263	neutral	0.999884248	Neutral	0.999974608
Tue, 06 Feb 2018 18:42:45 GMT	Bullish	0.624978065	neutral	0.999749124	Neutral	0.500033557
Wed, 07 Feb 2018 09:16:57 GMT	Neutral	0.680372477	negative	0.974078476	Positive	0.980428517
Fri, 09 Feb 2018 05:53:36 GMT	Bullish	0.590097666	neutral	0.999812186	Neutral	0.997753441
Fri, 09 Feb 2018 02:11:22 GMT	Neutral	0.63647306	neutral	0.999880195	Neutral	0.999952197
Fri, 09 Feb 2018 18:45:56 GMT	Neutral	0.675836742	neutral	0.999472558	Neutral	0.999984622
Sat, 10 Feb 2018 08:00:00 GMT	Bullish	0.67835182	positive	0.9966833	Neutral	0.999462306
Fri, 09 Feb 2018 18:46:06 GMT	Neutral	0.927077115	negative	0.998514593	Negative	0.99998033
Sat, 10 Feb 2018 04:47:03 GMT	Neutral	0.685279429	neutral	0.999895334	Neutral	0.999978423
Mon, 12 Feb 2018 00:48:25 GMT	Bearish	0.669006824	neutral	0.999860764	Neutral	0.999909639
Mon, 12 Feb 2018 02:47:25 GMT	Neutral	0.541693866	neutral	0.999892592	Positive	0.984210253
Sun, 11 Feb 2018 22:10:50 GMT	Neutral	0.643935323	neutral	0.999827743	Neutral	0.999790967
Mon, 12 Feb 2018 06:28:38 GMT	Neutral	0.608377278	neutral	0.999895215	Neutral	0.999985814

شکل ۴-۴-۱ - نمونه‌ای از تحلیل احساسات اخبار توسط هر سه مدل

### ۵-۴-۳ ترکیب داده‌ها

پس از انجام مراحل پیش‌پردازش داده‌ها و استخراج احساسات از اخبار، لازم است این دو مجموعه داده با یکدیگر ادغام شوند. همچنین برای حفظ ترتیب زمانی داده‌ها، از توالی اعداد استفاده شده است تا ساختار توالی در ورودی الگوریتم‌ها لحاظ گردد. بنابراین، مجموعه ویژگی‌هایی که به عنوان ورودی مدل‌های پیش‌بینی مورد استفاده قرار می‌گیرند شامل مواردی چون قیمت پایانی، حجم معاملات، اندیکاتور شاخص قدرت نسبی، حجم معاملات بیت‌کوین، قیمت پایانی بیت‌کوین، شاخص حرص و طمع، توالی عددی و نتایج تحلیل احساسات خواهد بود.

### ۶-۴-۳ مدل‌های پیاده سازی شده برای مقایسه

برای مقایسه کامل‌تر و برای اینکه اطمینان حاصل شود مدل پیشنهادی عملکرد خوبی دارد، چندین مورد از الگوریتم‌های یادگیری عمیق مهم پیاده‌سازی شده‌اند. این الگوریتم‌ها شامل پرستپترون چندلایه، شبکه عصبی کانولوشنی، شبکه عصبی بازگشتی، شبکه عصبی بازگشتی دو طرفه، حافظه طولانی کوتاه‌مدت، حافظه طولانی کوتاه‌مدت دو طرفه، واحد بازگشتی دروازه‌ای و واحد بازگشتی دروازه‌ای دو طرفه هستند. مشخصات و هایپرپارامترهای تمام مدل‌ها در جدول ۳-۴-۶-۲ قابل مشاهده است. این هایپرپارامترها نتیجه تجربه و آزمایش‌های متعدد هستند تا بهترین مدل را برای مقایسه داشته باشیم.

الگوریتم	لایه ها (نورون ها - فیلتر - کرنل - تابع فعالساز)
<b>MLP</b>	Dense (128 - ReLU)
<b>CNN</b>	Conv1D (128 - 5 - ReLU)
<b>RNN</b>	SimpleRNN (128 - ReLU)
<b>Bi-RNN</b>	BiDirectional(SimpleRNN (128 - ReLU))
<b>LSTM</b>	LSTM (128 - ReLU)
<b>Bi-LSTM</b>	BiDirectional(LSTM (128 - ReLU))
<b>GRU</b>	GRU (128 - ReLU)
<b>Bi-GRU</b>	BiDirectional(GRU (128 - ReLU))

علاوه بر ۸ مدل یادگیری عمیق ذکر شده در جدول بالا، در این تحقیق ۱۰ روش از مقاله های مشابه بر روی داده های جمع آوری شده پیاده سازی شده اند تا بتوان بهترین مقایسه ممکن را داشت. مدل اول از مقاله (Rathee et al., ۲۰۲۳) منتشر شده در سال ۲۰۲۳ است که از ترکیب شبکه عصبی کانولوشنی و حافظه طولانی کوتاه مدت دو طرفه تشکیل شده است. مدل دوم از پژوهش (Jiang, ۲۰۱۹) پیاده سازی شده است و ترکیبی از حافظه طولانی کوتاه مدت و شبکه عصبی روبه جلو است. مدل سوم، چهارم و پنجم از مطالعه (Murray et al., ۲۰۲۳) گرفته شده اند. مدل سوم از ترکیب شبکه عصبی کانولوشنی، حافظه طولانی کوتاه مدت و شبکه عصبی روبه جلو تشکیل شده، مدل چهارم ترکیبی از واحد بازگشتی دروازه ای و شبکه عصبی روبه جلو است و مدل پنجم از حافظه طولانی کوتاه مدت، شبکه عصبی روبه جلو، واحد بازگشتی دروازه ای و شبکه عصبی روبه جلو تشکیل شده است. مدل ششم مربوط به سال ۲۰۲۵ از تحقیق (Amirshahi & Lahmiri, ۲۰۲۵) است و از ترکیب شبکه



عصبی کانولوشنی به همراه حافظه طولانی کوتاه‌مدت، لایه توجه<sup>۱۷۰</sup> و لایه تراکم تشکیل شده است که نسبت به سایر متدها، روشی نوین‌تری را پیاده‌سازی کرده است. مدل‌های هفتم و هشتم به نسبت بقیه مدل‌ها ساده هستند که صرفاً از یک معماری تشکیل شده‌اند و به صورت ترکیبی نیستند. این دو مدل در سال ۲۰۲۵ توسط تحقیق (Kaur et al., ۲۰۲۵) پیاده‌سازی شده‌اند به این صورت که مدل هفتم صرفاً از حافظه طولانی کوتاه‌مدت تشکیل شده است و مدل هشتم نیز صرفاً از واحد بازگشتی دروازه‌ای. مدل نهم نیز در سال ۲۰۲۵ و در تحقیق (Mazinani et al., ۲۰۲۵) معرفی شده است که این مدل نیز به نسبت سایر مدل‌ها نوین‌تر و پیچیده‌تر است و از ترکیب لایه تراکم و لایه مکانیزم توجه تشکیل شده است. مدل آخر یا مدل دهم، در سال ۲۰۲۴ توسعه یافته و مدل ترکیبی از شبکه عصبی کانولوشنی، واحد بازگشتی دروازه‌ای و لایه تراکم است که از پایان‌نامه سرکار خانم تابع در موسسه آموزش عالی زند گرفته شده است. این مدل به دلیل ماهیت پیچیده خود، توانایی بالایی در پیش‌بینی قیمت ارز دیجیتال دارد. تمام ۱۰ مدل به همراه مشخصات و معماری منابع آن‌ها، در جدول ۳-۴-۳ قابل مشاهده است. پیاده‌سازی مدل‌های زیاد با معماری‌های متفاوت به دلیل مقایسه بهتر و نشان دادن عملکرد بهتر مدل پیشنهادی این تحقیق است.

---

<sup>۱۷۰</sup> Attention Layer

جدول ۳-۴-۳ - مدل‌های پیاده سازی شده مطالعات با منابع

منبع	معماری پیشنهادی
(Rathee et al., 2023)	3Conv1D (64, 128, 64) + 2Bi-LSTM (100)
(Jiang, 2019)	2LSTM (256) + Dense (128)
(Murray et al., 2023)	Conv1D (64) + LSTM (75) + Dense (16)
(Murray et al., 2023)	GRU (75) + Dense (100)
(Murray et al., 2023)	LSTM (75) + LSTM (50) + Dense (32) + GRU (50) + Dense (64)
(Amirshahi & Lahmiri, 2025)	Conv1D (64) + 2LSTM (50, 100) + Attention + Dense (128)
(Kaur et al., 2025)	LSTM (100)
(Kaur et al., 2025)	GRU (100)
(Mazinani et al., 2025)	Dense (100) + Attention + Dense (128, 128)
Fatemeh Tabe et al.	3Conv1D (128, 64, 128) + GRU (256, 256, 256) + Dense (128)

### ۷-۴-۳ مدل پیشنهادی

در این تحقیق سه سناریو اصلی وجود دارد: در سناریو اول فقط از قیمت بسته‌شدن برای پیش بینی استفاده می‌شود، در سناریو دوم علاوه بر قیمت بسته‌شدن، داده‌های دیگری از جمله شاخص حرص و طمع، حجم معاملات، قیمت بیت‌کوین، حجم معاملات بیت‌کوین و اندیکاتور شاخص قدرت نسبی نیز استفاده شده است و در سناریو سوم و آخر نیز احساسات استخراج شده از اخبار نیز علاوه بر داده‌های سناریو دوم در نظر گرفته شده است. تحلیل احساسات در سناریو آخر توسط سه ابزار ذکر شده به صورت جدا انجام شده و در انتها با هم مقایسه شده‌اند. ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد آن‌ها برای آزمایش در نظر گرفته شده است. به دلیل ماهیت

سری‌زمانی داده‌های ارزش دیجیتال روش برش دادن<sup>۱۷۱</sup> استفاده شده است تا ترتیب داده ها حفظ شود. تابع ضرر<sup>۱۷۲</sup> یا همان تابع هزینه<sup>۱۷۳</sup> استفاده شده در روش پیشنهادی، هوپر<sup>۱۷۴</sup> است و از آدام نیز به عنوان تابع بهینه‌ساز استفاده شده است.

معماری پیشنهادی این تحقیق صرفاً از واحد بازگشتی دروازه‌ای به صورت دوطرفه و لایه تراکم تشکیل شده است. نکته‌ای که این پایان‌نامه را خاصی می‌کند نحوه و روش استفاده از واحد بازگشتی دروازه‌ای دوطرفه است. ترکیب واحد بازگشتی دروازه‌ای دوطرفه با معماری باقی‌مانده یک ایده پیشرفته و پرکاربرد در مدل‌سازی توالی‌هاست، مخصوصاً در پیش‌بینی سری‌های زمانی مالی. استفاده از اتصال‌های باقیمانده<sup>۱۷۵</sup> روی واحدهای بازگشتی دروازه‌ای دوطرفه چندین مزیت و برتری به همراه خواهد داشت. از برتری‌های این معماری می‌توان به موارد زیر اشاره کرد:

- کاهش مشکل ناپدید شدن گرادیان: در شبکه‌های بازگشتی عمیق، با افزایش لایه‌ها، گرادیان‌ها در جریان پس‌انتشار به شدت ضعیف می‌شوند. اتصال‌های باقیمانده مسیر میان‌بری برای گرادیان ایجاد می‌کند و باعث می‌شود مدل حتی در لایه‌های عمیق‌تر هم قابل آموزش باقی بماند.
- بهبود جریان اطلاعات بین لایه‌ها: اتصال باقیمانده اجازه می‌دهد خروجی هر لایه نه تنها به لایه بعدی، بلکه مستقیماً به خروجی نهایی هم تاثیر بگذارد. این کار کمک می‌کند اطلاعات مفید اولیه (مثل الگوهای ساده‌تر در داده‌های مالی) در لایه‌های عمیق‌تر گم نشوند.
- یادگیری بهتر ویژگی‌های سطح بالا و سطح پایین همزمان: واحد بازگشتی دروازه‌ای دوطرفه توالی را از دو جهت جلو و عقب می‌بیند. اتصال باقیمانده باعث می‌شود ویژگی‌های سطح پایین (مثل روندهای

---

<sup>۱۷۱</sup> Slicing

<sup>۱۷۲</sup> Loss Function

<sup>۱۷۳</sup> Cost Function

<sup>۱۷۴</sup> Huber

<sup>۱۷۵</sup> Residual connection

کوتاه مدت قیمت) همراه با ویژگی‌های سطح بالاتر (مثل روندهای بلندمدت یا وابستگی‌های پیچیده) ترکیب شوند.

- بهبود همگرایی و سرعت آموزش: اتصال‌های باقیمانده معمولاً باعث می‌شوند مدل سریع‌تر همگرا شود، چون بهینه‌سازی راحت‌تر می‌شود و شبکه نیازی ندارد همه ویژگی‌ها را دوباره در هر لایه یاد بگیرد.
- دقت بیشتر در پیش‌بینی سری‌های زمانی مالی: در داده‌های رمزارز یا بازار سهام، الگوهای غیرخطی و نوسان‌های شدید وجود دارند. معماری پیشنهادی به دلیل ترکیب "یادگیری عمیق توالی" و "پایداری گرادیان"، معماری مناسبی برای گرفتن این نوسان‌های پیچیده و الگوهای چندبعدی است.
- قابلیت تعمیم بهتر<sup>۱۷۶</sup>: معماری اتصال‌های باقیمانده به مدل کمک می‌کند از بیش‌برازش جلوگیری کند، چون بخشی از اطلاعات به‌طور مستقیم منتقل می‌شود و شبکه مجبور به بازنمایی مجدد همه چیز در هر لایه نیست.

در جدول ۳-۴-۷-۱ هاپیرپارامترهای استفاده‌شده در مدل پیشنهادی نوشته به صورت کامل نوشته شده است و در شکل ۳-۴-۷-۱ معماری مدل پیشنهادی نمایش داده شده است که لایه‌ها، به ترتیب به این صورت هستند: لایه اول لایه ورودی است و در لایه بعدی، بعد و شکل داده تغییر می‌کنند تا آماده وارد شدن به اولین واحد بازگشتی دروازه‌ای دوطرفه مستقل باشند. این لایه شامل ۱۲۸ واحد است و به صورت دوطرفه است. سپس از این قدم، معماری اتصال‌های باقی‌مانده شروع می‌شود و سه بار این معماری و قالب تکرار می‌شود. به این صورت که ورودی به دو واحد بازگشتی دروازه‌ای دوطرفه با ۱۲۸ واحد به صورت متوالی وارد می‌شود. سپس خروجی این عملیات با ورودی همین لایه‌ها جمع شده و به مرحله بعدی می‌رود. یعنی در اصل ورودی قبل از دو واحد بازگشتی دروازه‌ای دوطرفه متوالی با خروجی آن‌ها جمع شده

---

<sup>۱۷۶</sup> Generalization

و تبدیل می‌شود به ورودی مرحله اتصال باقی‌مانده بعدی. همین روند سه بار تکرار می‌شود. در نهایت خروجی وارد یک لایه تراکم با ۱۲۸ واحد می‌شود و سپس لایه خروجی را داریم.

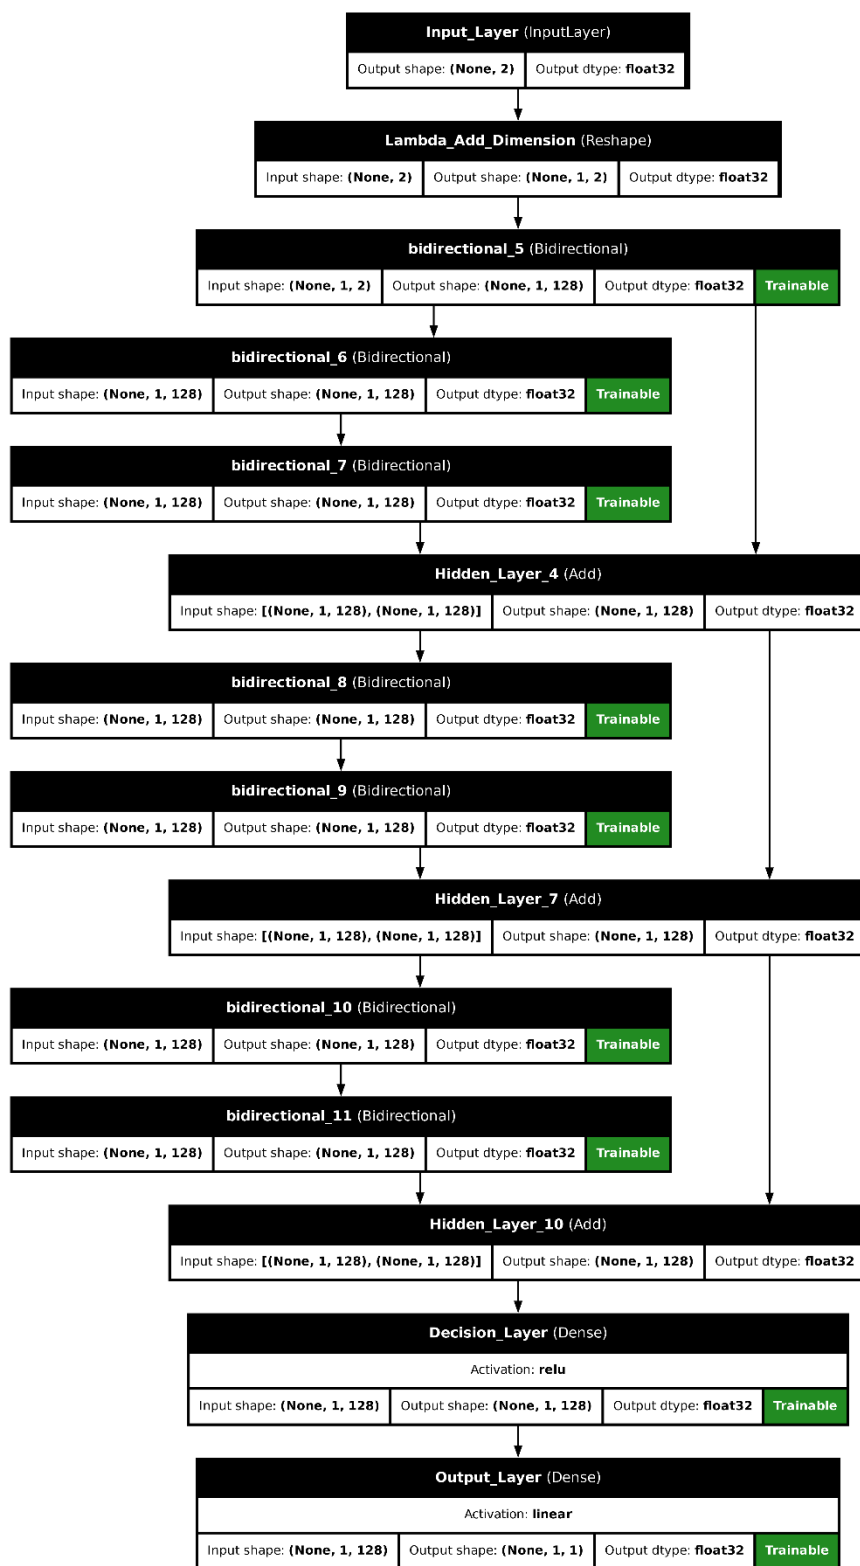
جدول ۳-۴-۱ - هایپرپارامترهای مدل پیشنهادی

128	تعداد واحدهای GRU دو طرفه
128	تعداد نورون‌های Dense
Huber	تابع هزینه
Adam	بهینه ساز
1000	دوره‌ها <sup>۱۷۷</sup>
32	اندازه دسته <sup>۱۷۸</sup>

---

<sup>۱۷۷</sup> Epochs

<sup>۱۷۸</sup> Batch Size



شکل ۳-۴-۱ - معماری مدل پیشنهادی

### ۵-۳ جمع بندی

در این فصل ابتدا چارچوب‌های نظری لازم برای درک عمیق مدل‌های پیاده‌سازی شده و همچنین روش‌های ارزیابی عملکرد در مسائل رگرسیونی ارائه گردید. در ادامه، فرآیند گردآوری داده‌ها، مراحل پیش‌پردازش و آماده‌سازی آن‌ها به تشریح شد. همان‌گونه که پیش‌تر اشاره شد، سه سناریو داده مرتبط با دو ارز دیجیتال مورد استفاده قرار گرفت. پس از آن، مجموعه الگوریتم‌ها و مدل‌های مورد بررسی شامل هشت مدل یادگیری عمیق تکی ساده و همچنین ده مدل پیشنهادی برگرفته از پژوهش‌های پیشین معرفی و تشریح شدند. هدف از این روند، ایجاد بستری برای انجام یک مقایسه جامع و دقیق میان مدل‌ها و اطمینان از برتری عملکرد مدل پیشنهادی این پایان‌نامه نسبت به سایر رویکردها بوده است. در فصل آتی، نتایج حاصل از پیاده‌سازی و ارزیابی این مدل‌ها به تفصیل ارائه خواهد شد.

## فصل چہارم



## نتایج و بحث و تحلیل


### ۱-۴ مقدمه

در این فصل نتایج تمام الگوریتم‌های یادگیری عمیق تکی، تحقیق‌های قبلی و رویکرد پیشنهادی روی دو ارز دیجیتال ذکر شده یعنی بایننس و اتریوم به صورت جداگانه بررسی می‌شود. سپس این نتایج را بررسی کرده و در پایان، یک جمع بندی انجام خواهد شد.

### ۲-۴ نتایج و تحلیل


#### ۱-۲-۴ ارز بایننس

شکل ۱-۱-۲-۴ تقسیم بندی داده‌های بایننس‌کوین به صورت آموزش و آزمایش پس از پیش‌پردازش را نشان می‌دهد.



شکل ۱-۱-۲-۴ - تقسیم بندی داده‌های بایننس

برای ارزیابی مدل‌ها، داده‌های بایننس توسط سه سناریو ذکر شده در این بخش استفاده شده‌اند. نمودار همبستگی<sup>۱۷۹</sup> ویژگی‌ها را می‌توان در شکل ۲-۱-۲-۴ مشاهده کرد. تنها ویژگی که همبستگی زیادی به قیمت بسته‌شدن دارد، قیمت بسته‌شدن بیت‌کوین است که این همبستگی برای این دو ویژگی طبیعی است و نشان دهنده تاثیر زیاد قیمت بیت‌کوین روی این ارز است، اما طبق آزمایش‌های صورت گرفته به این نتیجه رسیده‌شده که بودن این ویژگی می‌تواند به مدل‌ها کمک کند.



شکل ۲-۱-۲-۴ - نمودار همبستگی بایننس

همانطور که در جدول ۲-۱-۲-۴ مشاهده می‌شود، ۲۳ سطر یا نتیجه در نظر گرفته شده‌است. ۸ سطر اول مربوط به نتایج الگوریتم‌های یادگیری عمیق تکی هستند، ۱۰ سطر بعدی مربوط به الگوریتم‌ها و مدل‌های سایر تحقیق‌ها هستند و ۵ سطر آخر مربوط به مدل پیشنهادی این مقاله می‌شود که در حالت سه سناریو گفته‌شده پیاده‌سازی شده است. اولین سطر از مدل پیشنهادی مربوط به صرفاً قیمت بسته‌شدن ارز است، دومین سطر مربوط به داده‌های حجم معاملات، شاخص حرص و طمع، قیمت

<sup>۱۷۹</sup> Correlation

بسته شدن بیت کوین، حجم معاملات بیت کوین و اندیکاتور شاخص قدرت نسبی به علاوه قیمت بسته شدن خود ارز است و سومین تا آخرین سطر بیان گر تاثیر تحلیل احساسات اخبار توسط ابزار های ذکر شده، علاوه بر سایر ویژگی ها هستند. ۴ معیار ارزیابی مطرح و رایج برای بررسی و مقایسه بهتر استفاده شده اند که در جدول مشاهده می شود.

طبق نتایج مشاهده شده از جدول، می توان به این نتیجه رسید که مدل پیشنهادی در سناریو اول که صرفا قیمت بست شدن هست، بهترین مدل بین تمامی مدل ها است. این نتیجه بدین معناست که در پایه ای ترین سناریو و شرایط، مدل پیشنهادی در تمامی معیارها برتری دارد. مدل پیشنهادی در حالت سناریو دوم و با داشتن ویژگی های بیشتر، از حالت سناریو اول خود نیز بهتر عمل می کند. این نتیجه به ما نشان می دهد که مدل نه تنها موفق بوده است، بلکه ویژگی های اضافه شده به مدل کمک کردند که پیش بینی دقیق تری داشته باشد. در سناریو سوم، یعنی حالتی که اخبار نیز اضافه می شود، مدل بهترین نتیجه را از خودش نشان می دهد که نشان دهنده تاثیر اضافه شدن اخبار به ویژگی ها است. در این سناریو، سه ابزار متفاوت پیاده سازی شده بود که طبق نتایج مشاهده می شود که همگی از حالت سناریو دوم بهتر هستند اما کریپتو برت و دیستیل روبرتا مدل های برتر در بخش تحلیل احساسات اخبار هستند. کریپتو برت در معیارهای  $rmse$  و  $mse$  نتایج بهتری را ارائه داده است، در حالی که دیستیل روبرتا در معیارهای  $mae$  و  $mape$  بدین ترتیب مشخص می شود که ویژگی ها و مدل پیشنهادی تاثیر مثبت در پیش بینی قیمت داشته اند.


جدول ۴-۱-۱ - مقایسه مدل‌ها در پیش‌بینی رمزارز بایننس

#	نام مدل	RMSE	MAPE	MSE	MAE
1	MLP	0.021901	1.987774	0.00048	0.016191
2	CNN	0.021204	1.881794	0.00045	0.015291
3	RNN	0.026395	2.570907	0.000697	0.021218
4	Bi-RNN	0.021656	1.950866	0.000469	0.015875
5	LSTM	0.021263	1.891129	0.000452	0.015349
6	Bi-LSTM	0.022845	2.05499	0.000522	0.016706
7	GRU	0.021662	1.951341	0.000469	0.015855
8	Bi-GRU	0.021074	1.859814	0.000444	0.015064
9	CNN Bi-LSTM Ensemble	0.023024	2.095999	0.00053	0.01729
10	2LSTM Dense	0.023254	2.083119	0.000541	0.016967
11	CNN LSTM Dense	0.030498	2.840193	0.00093	0.023191
12	GRU DENSE	0.021176	1.871359	0.000448	0.015152
13	2LSTM DENSE GRU Dense	0.021414	1.903229	0.000459	0.015398
14	CNN 2LSTM Attention	0.021182	1.880697	0.000449	0.015202
15	LSTM	0.127785	15.30575	0.016329	0.125764
16	GRU	0.152846	18.22216	0.023362	0.150353
17	Transformer	0.03767	3.66911	0.001419	0.03112
18	Fatemeh Tabe et al.	0.025272	2.437291	0.000639	0.0196
19	Proposed Method (Scenario 1)	0.019867	1.705625	0.000395	0.014195
20	Proposed Method (Scenario 2)	0.017629	1.50291	0.000311	0.01272
21	Proposed Method (Scenario 3 - CryptoBert)	<b>0.014416</b>	1.280455	<b>0.000208</b>	0.01136
22	Proposed Method (Scenario 3 - DistilRoberta)	0.014593	<b>1.277189</b>	0.000213	<b>0.011314</b>
23	Proposed Method (Scenario 3 - FinBert)	0.016841	1.417459	0.000284	0.012515

## ۲-۲-۴ ارزش اتریوم


شکل ۴-۲-۱ - تقسیم بندی داده‌های اتریوم به صورت آموزش و آزمایش

پس از پیش‌پردازش را نشان می‌دهد.



شکل ۴-۲-۱ - تقسیم بندی داده‌های اتریوم

داده‌های اتریوم نیز توسط سه سناریو ذکر شده برای ارزیابی مدل‌ها در این بخش استفاده شده‌اند. در شکل ۴-۲-۲ نمودار همبستگی ویژگی‌های اتریوم را می‌توان مشاهده کرد.



شکل ۴-۲-۲ - نمودار همبستگی اتریوم

۲۳ سطر نیز در جدول ۴-۲-۱ مشاهده می‌شود. مانند ارز دیجیتال قبلی، ۸ سطر اول مربوط به نتایج الگوریتم‌های یادگیری عمیق تکی هستند، ۱۰ سطر بعدی مربوط به الگوریتم‌های سایر تحقیقات هستند و ۵ سطر آخر مربوط به مدل پیشنهادی این مقاله می‌شود که در حالت سه سناریو گفته شده پیاده‌سازی شده است مانند ارز دیجیتال بایننس. ۴ معیار ارزیابی مطرح و رایج برای بررسی و مقایسه بهتر استفاده شده‌اند که در جدول مشاهده می‌شود.

طبق نتایج جدول، می‌توان مشاهده کرد که مدل پیشنهادی در سناریو اول که صرفاً قیمت بست شدن هست، بهترین مدل بین تمامی مدل‌ها است که این امر دقیقاً مانند ارز قبلی تکرار شده است. این نتیجه بدین معناست که در پایه‌ای‌ترین سناریو و شرایط، مدل پیشنهادی در تمامی معیارها برتری دارد. مدل پیشنهادی در حالت سناریو دوم و با داشتن ویژگی‌های بیشتر، از حالت سناریو اول خود نیز بهتر

عمل می‌کند. این نتیجه به ما نشان می‌دهد که ویژگی‌های اضافه‌شده به مدل کمک کردند که پیش‌بینی دقیق‌تری داشته باشد. در سناریو سوم و حالتی که اخبار نیز اضافه می‌شود، مدل بهترین نتیجه را از خودش نشان می‌دهد که نشان‌دهنده تاثیر اضافه‌شدن اخبار به ویژگی‌ها است. در این سناریو، سه ابزار متفاوت پیاده‌سازی شده بود که طبق نتایج مشاهده می‌شود همگی از حالت سناریو دوم بهتر هستند اما برعکس ارز دیجیتال قبلی، کریپتو بورت مدل برتر در بخش تحلیل احساسات اخبار هست و در تمامی معیارها بهترین عملکرد را داشته است. بدین ترتیب مشخص می‌شود که ویژگی‌ها و مدل پیشنهادی تاثیر مثبت در پیش‌بینی قیمت داشته‌اند.

جدول ۴-۲-۱ - مقایسه مدل‌ها در پیش‌بینی رمز ارز اتریوم

#	نام مدل	RMSE	MAPE	MSE	MAE
1	MLP	0.021651	2.955092	0.000469	0.015807
2	CNN	0.02242	3.110354	0.000503	0.016598
3	RNN	0.021537	2.886721	0.000464	0.015654
4	Bi-RNN	0.022226	3.200294	0.000494	0.016705
5	LSTM	0.02192	2.899944	0.00048	0.01574
6	Bi-LSTM	0.022878	3.116244	0.000523	0.016808
7	GRU	0.021911	2.88887	0.00048	0.015696
8	Bi-GRU	0.021682	2.845774	0.00047	0.015545
9	CNN Bi-LSTM Ensemble	0.022042	3.122862	0.000486	0.016481
10	2LSTM Dense	0.022254	3.008065	0.000495	0.01634
11	CNN LSTM Dense	0.030762	5.116597	0.000946	0.025278
12	GRU DENSE	0.021936	2.902867	0.000481	0.015927
13	2LSTM DENSE GRU Dense	0.021975	2.912262	0.000483	0.015973
14	CNN 2LSTM Attention	0.021656	2.935824	0.000469	0.01586
15	LSTM	0.078274	12.01161	0.006127	0.069812
16	GRU	0.077858	13.67032	0.006062	0.073885
17	Transformer	0.021958	3.014804	0.000482	0.016225
18	Fatemeh Tabe et al.	0.021632	2.853353	0.000468	0.015589
19	Proposed Method (Scenario 1)	0.02081	2.819452	0.000433	0.014367
20	Proposed Method (Scenario 2)	0.020759	2.738288	0.000431	0.013881
21	Proposed Method (Scenario 3 - CryptoBert)	<b>0.017987</b>	<b>2.518299</b>	<b>0.000324</b>	<b>0.013655</b>
22	Proposed Method (Scenario 3 - DistilRoberta)	0.019077	2.679601	0.000364	0.013818
23	Proposed Method (Scenario 3 - FinBert)	0.020262	2.696965	0.000411	0.01386

#### ۳-۴ جمع بندی

در این فصل، نتایج حاصل از پیاده‌سازی الگوریتم‌ها و ارزیابی رویکرد پیشنهادی بر روی داده‌های مربوط به رمزارزهای بایننس‌کوین و اتریوم مورد تحلیل قرار گرفت. بررسی جداول ارائه‌شده نشان داد که رویکرد پیشنهادی از نظر دقت و کارایی نسبت به سایر مدل‌ها برتری محسوسی دارد و همچنین نقش سایر ویژگی‌ها و تحلیل احساسات علاوه بر قیمت بسته‌شدن در بهبود عملکرد مدل‌ها به‌طور مثبت تأیید شد. بر اساس یافته‌ها، ابزارهای کریپتوBERT و دیستیل‌روBERTا به‌عنوان کارآمدترین روش‌ها در استخراج و کمی‌سازی احساسات شناسایی شدند که ابزار کریپتوBERT همچنان یک پله بهتر عمل کرده‌بود. علاوه بر این، نتایج نشان داد که استفاده از واحدهای بازگشتی دروازه‌ای دوطرفه در قالب اتصال‌های باقی‌مانده منجر به کاهش خطا و بهبود دقت پیش‌بینی گردیده است. در نهایت، فصل بعد به جمع‌بندی نتایج کلی پژوهش و ارائه پیشنهاداتی برای مسیرهای آتی تحقیقات اختصاص خواهد یافت.

## فصل پنجم



## نتیجه‌گیری و پیشنهادها

### ۱-۵ مقدمه

در پژوهش‌های پیشین اکثراً از داده‌های تاریخی قیمت برای پیش‌بینی استفاده می‌شد اما مطالعاتی نیز وجود داشتند که از هر دو مولفه قیمت و تحلیل احساسات با هم برای پیش‌بینی قیمت ارزهای دیجیتال استفاده می‌کردند. لازم به ذکر است که طبق بررسی‌ها و جست‌وجوهای انجام شده، معماری پیشنهاد داده شده و ویژگی‌های استفاده شده در این تحقیق، در هیچ یک از پژوهش‌های پیشین دیده نشدند. از نقاط قوت دیگر این تحقیق می‌توان به پیاده‌سازی تعداد زیادی مدل به صورت تکی و همچنین از سایر مقالات و اجرا کردن آن‌ها بر روی داده‌های جمع‌آوری شده، اشاره کرد. در این فصل به نتیجه‌گیری و پیشنهادات برای تحقیقات آینده پرداخته خواهد شد.

### ۲-۵ نتیجه‌گیری

بازارهای مالی از جمله بورس، فارکس و به‌ویژه ارزهای دیجیتال به یکی از محورهای اصلی توجه پژوهشگران و سرمایه‌گذاران تبدیل شده‌اند. سرمایه‌گذاری در حوزه رمزارزها، در صورتی که بر مبنای تحلیل دقیق و تصمیم‌گیری صحیح انجام گیرد، می‌تواند از سودآورترین روش‌های سرمایه‌گذاری محسوب شود. از این رو، طراحی و توسعه الگوریتم‌هایی با قابلیت پیش‌بینی دقیق قیمت رمزارزها و حداقل‌سازی خطای تخمین، ضرورتی انکارناپذیر است. در این پژوهش تلاش شد با بهره‌گیری از داده‌های تاریخی، اندیکاتور، تاثیر بیت‌کوین و تحلیل احساسات اخبار مرتبط و همچنین استفاده از یک معماری نوین بر اساس واحد بازگشتی دروازه‌ای دوطرفه در قالب اتصال‌های باقی‌مانده، روند قیمتی دو ارز دیجیتال پرکاربرد یعنی بایننس و اتریوم پیش‌بینی شود. مرور پژوهش‌های گذشته نشان می‌دهد که استفاده از

معماری‌های مبتنی بر شبکه‌های عصبی عمیق در مسائل پیش‌بینی بازارهای مالی، اغلب منجر به بهبود دقت و پایداری مدل می‌شود.

نتایج آزمایش‌ها و مقایسه با الگوریتم‌های مرسوم شبکه‌های عصبی عمیق نشان داد که روش پیشنهادی در مسئله پیش‌بینی قیمت رمزارزها کارآمدتر عمل کرده و عملکرد قابل توجهی در کاهش خطا داشته است. همان‌گونه که در فصل سوم جزئیات داده‌های مورد استفاده و معماری پیشنهادی تشریح گردید و در فصل چهارم نیز نتایج به تفکیک رمزارزها ارائه شد، ادغام تحلیل احساسات اخبار و سایر ویژگی‌ها با داده‌های تاریخی قیمت تأثیری مثبتی بر دقت مدل داشته است. بررسی عملکرد مدل پیشنهادی بر روی هر ارز دیجیتال به صورت مجزا نشان داد که این روش نسبت به رویکردهای موجود نتایج برتری ارائه می‌دهد. با توجه به آنکه هر رمزارز رفتار و الگوهای نوسانی خاص خود را داراست، مقایسه عملکرد مدل‌ها باید به صورت اختصاصی و در بستر داده‌های همان ارز انجام گیرد تا اعتبار نتایج تضمین شود.

## ۳-۵ پیشنهادها

با توجه به محدودیت‌هایی که در فصل نخست این پژوهش مورد بحث قرار گرفت، فرایند گردآوری داده‌ها با چالش‌های قابل توجهی همراه بود. اگرچه داده‌های متعددی در زمینه ارزهای دیجیتال وجود دارد اما دسترسی به بخشی از این داده‌ها دشوار بوده و محدودیت‌هایی را ایجاد کرده است. از این رو، یکی از مسیرهای پیشنهادی برای تحقیقات آینده استفاده از مجموعه داده‌های گسترده‌تر و متنوع‌تر خواهد بود تا از این طریق دقت و قابلیت تعمیم‌پذیری مدل‌ها ارتقا یابد. پیشنهاد می‌شود شاخص‌ها و اندیکاتورهای دیگر و پرکاربردتر نیز به عنوان متغیرهای ورودی به مدل‌های یادگیری عمیق افزوده شوند، چرا که می‌توانند در افزایش کارایی مدل نقش بسزایی داشته باشند. یکی دیگر از راهکارهای بهبود، تغییر بازه زمانی پیش‌بینی است؛ بدین معنا که به جای تمرکز بر پیش‌بینی قیمت روز بعد، قیمت در بازه‌های کوتاه‌تر نظیر یک ساعت آینده مورد پیش‌بینی قرار گیرد. چنین رویکردی می‌تواند به‌ویژه در بازار پرنوسان ارزهای دیجیتال، دقت بیشتری را به همراه داشته باشد.

علاوه بر این، افزایش تعداد ویژگی‌های ورودی می‌تواند اثر معناداری بر بهبود نتایج داشته باشد. بر اساس شواهد پژوهش‌های پیشین، متغیرهایی نظیر قیمت طلا، نرخ نوسانات دلار آمریکا، قیمت نفت و نقره، شاخص بیکاری، شاخص‌های بازارهای مالی همچون S&P 500 و Hushen 300، همچنین

میزان جستجوهای گوگل و هزینه‌های استخراج ارزش‌های دیجیتال از جمله عواملی هستند که اثرات قابل توجهی بر قیمت رمزارزها بر جای می‌گذارند. ادغام این متغیرها با داده‌های اصلی می‌تواند در افزایش دقت پیش‌بینی نقش کلیدی ایفا کند. از دیگر مسیرهای بالقوه برای ارتقای عملکرد مدل‌ها، پیچیده‌تر کردن معماری‌های یادگیری عمیق است. برای مثال می‌توان با افزودن لایه‌های بیشتر به شبکه‌های موجود یا بهره‌گیری از رویکردهای نوین‌تر مانند معماری ترانسفورمر به نتایج دقیق‌تر و پایدارتر دست یافت.

## ۴-۵ جمع‌بندی

به‌کارگیری همزمان داده‌های قیمت، تاثیر بیت‌کوین و اندیکاتور به همراه نتایج تحلیل احساسات اخبار، در کنار بهره‌گیری از معماری‌های نوین، منجر به افزایش دقت پیش‌بینی گردیده است. با این حال، همچنان امکان بهبود عملکرد و کاهش خطای مدل وجود دارد؛ موضوعی که در بخش پیشنهادات به تفصیل مورد بررسی قرار گرفته است. به طور کلی، با توجه به ماهیت پرنوسان و پیچیدگی‌های ذاتی بازار ارزش‌های دیجیتال، اتخاذ تصمیمات سرمایه‌گذاری نیازمند ارزیابی جامع تمامی ابعاد مؤثر است و صرفاً نمی‌توان به نتایج مدل‌ها بسنده کرد. در این راستا، استفاده از الگوریتم‌های هوش مصنوعی به‌عنوان یک ابزار پشتیبان تصمیم‌گیری می‌تواند منجر به ارائه پیش‌بینی‌های دقیق‌تر شده و ریسک ناشی از عدم قطعیت بازار را کاهش دهد.

- Altan, A., Karasu, S., & Bekiros, S. (2019). Digital currency forecasting with chaotic meta-heuristic bio-inspired signal processing techniques. *Chaos, Solitons & Fractals*, 126, 325–336. <https://doi.org/https://doi.org/10.1016/j.chaos.2019.07.011>
- Amirshahi, B., & Lahmiri, S. (2025). Investigating the effectiveness of Twitter sentiment in cryptocurrency close price prediction by using deep learning. *Expert Systems*, 42(1), e13428. <https://doi.org/https://doi.org/10.1111/exsy.13428>
- Aslam, N., Rustam, F., Lee, E., Washington, P. B., & Ashraf, I. (2022). Sentiment Analysis and Emotion Detection on Cryptocurrency Related Tweets Using Ensemble LSTM-GRU Model. *IEEE Access*, 10, 39313–39324. <https://doi.org/10.1109/ACCESS.2022.3165621>
- Dag, A., Dag, A. Z., Asilkalkan, A., Simsek, S., & Delen, D. (2023). A Tree Augmented Naïve Bayes-based methodology for classifying cryptocurrency trends. *Journal of Business Research*, 156, 113522. <https://doi.org/https://doi.org/10.1016/j.jbusres.2022.113522>
- Hamayel, M. J., & Owda, A. Y. (2021). A Novel Cryptocurrency Price Prediction Model Using GRU, LSTM and bi-LSTM Machine Learning Algorithms. *AI*, 2(4), 477–496.
- Jiang, X. (2019). Bitcoin price prediction based on deep learning methods. *Journal of Mathematical Finance*, 10(1), 132–139.
- Kanwal, A., Lau, M. F., Ng, S. P. H., Sim, K. Y., & Chandrasekaran, S. (2022). BiCuDNNLSTM-1dCNN — A hybrid deep learning-based predictive model for stock price prediction. *Expert Systems with Applications*, 202, 117123. <https://doi.org/https://doi.org/10.1016/j.eswa.2022.117123>
- Kaur, R., Uppal, M., Gupta, D., Juneja, S., Arafat, S. Y., Rashid, J., Kim, J., & Alroobaea, R. (2025). Development of a cryptocurrency price prediction model: leveraging GRU and LSTM for Bitcoin, Litecoin and Ethereum. *PeerJ Computer Science*, 11, e2675.
- Kazemina, S., Sajedi, H., & Arjmand, M. (2023, 3–4 May 2023). Real-Time Bitcoin Price Prediction Using Hybrid 2D-CNN LSTM Model. 2023 9th International Conference on Web Research (ICWR),
- Lahmiri, S., & Bekiros, S. (2019). Cryptocurrency forecasting with deep learning chaotic neural networks. *Chaos, Solitons & Fractals*, 118, 35–40. <https://doi.org/https://doi.org/10.1016/j.chaos.2018.11.014>
- Lahmiri, S., Saade, R. G., Morin, D., & Nebebe, F. (2020, 24–26 Nov. 2020). An Artificial Neural Networks Based Ensemble System to Forecast

- Bitcoin Daily Trading Volume. 2020 5th International Conference on Cloud Computing and Artificial Intelligence: Technologies and Applications (CloudTech),
- Leung, M.-F., Chan, L., Hung, W.-C., Tsoi, S.-F., Lam, C.-H., & Cheng, Y.-H. (2023). An Intelligent System for Trading Signal of Cryptocurrency Based on Market Tweets Sentiments. *FinTech*, 2(1), 153–169.
- Liu, Y., Li, Z., Nekhili, R., & Sultan, J. (2023). Forecasting cryptocurrency returns with machine learning. *Research in International Business and Finance*, 64, 101905. <https://doi.org/https://doi.org/10.1016/j.ribaf.2023.101905>
- Mansourabady, A., Tabe, F., Rasekh, A. H., & Ghermezian, A. (2024, 21–22 Feb. 2024). A Study on Hybrid Deep Learning Approaches for “Monero” Cryptocurrency Price Prediction. 2024 20th CSI International Symposium on Artificial Intelligence and Signal Processing (AISP),
- Mazinani, A., Davoli, L., & Ferrari, G. (2025). Deep Learning Algorithms for Cryptocurrency Price Prediction: A Comparative Analysis. *Distrib. Ledger Technol.*, 4(1), Article 5. <https://doi.org/10.1145/3699966>
- Murray, K., Rossi, A., Carraro, D., & Visentin, A. (2023). On Forecasting Cryptocurrency Prices: A Comparison of Machine Learning, Deep Learning, and Ensembles. *Forecasting*, 5(1), 196–209.
- Oyedele, A. A., Ajayi, A. O., Oyedele, L. O., Bello, S. A., & Jimoh, K. O. (2023). Performance evaluation of deep learning and boosted trees for cryptocurrency closing price prediction. *Expert Systems with Applications*, 213, 119233. <https://doi.org/https://doi.org/10.1016/j.eswa.2022.119233>
- Pandey, P., & Geeta, S. (2025). Effective Price Prediction of Cryptocurrencies using CNN-Based Dual Directional Model. *Science & Technology Asia*, 30(1), 201–219.
- Rao, K., Prasad, M., Kumar, G., Natchadalingam, R., Hussain, M., & Reddy, P. C. (2023). *Time-Series Cryptocurrency Forecasting Using Ensemble Deep Learning*. <https://doi.org/10.1109/ICCPCT58313.2023.10245083>
- Rathee, N., Ankita, S., Sharda, T., Goel, N., Mansi, A., & Dudeja, S. (2023). Analysis and price prediction of cryptocurrencies for historical and live data using ensemble-based neural networks. *Knowledge and Information Systems*, 65(10), 4055–4084. <https://doi.org/10.1007/s10115-023-01871-0>

- Seabe, P. L., Moutsinga, C. R. B., & Pindza, E. (2023). Forecasting Cryptocurrency Prices Using LSTM, GRU, and Bi-Directional LSTM: A Deep Learning Approach. *Fractal and Fractional*, 7(2), 203.
- Tabe, F., Mansourabady, A., Rasekh, A. H., & Tanoori, B. (2024, 21–22 Feb. 2024). Comparison of Deep Learning Algorithms for “Bitcoin Cash” Price Prediction. 2024 20th CSI International Symposium on Artificial Intelligence and Signal Processing (AISP),
- Tanwar, S., Patel, N., Patel, S., Patel, J., & Davidson, I. (2021). Deep Learning-Based Cryptocurrency Price Prediction Scheme With Inter-Dependent Relations. *IEEE Access*.  
<https://doi.org/10.1109/ACCESS.2021.3117848>
- Valencia, F., Gómez-Espinosa, A., & Valdés-Aguirre, B. (2019). Price Movement Prediction of Cryptocurrencies Using Sentiment Analysis and Machine Learning. *Entropy*, 21(6), 589.
- Zhang, Z., Dai, H.-N., Zhou, J., Mondal, S. K., García, M. M., & Wang, H. (2021). Forecasting cryptocurrency price using convolutional neural networks with weighted and attentive memory channels. *Expert Systems with Applications*, 183, 115378.  
<https://doi.org/https://doi.org/10.1016/j.eswa.2021.115378>
- Zhong, C., Du, W., Xu, W., Huang, Q., Zhao, Y., & Wang, M. (2023). LSTM-ReGAT: A network-centric approach for cryptocurrency price trend prediction. *Decision Support Systems*, 169, 113955.  
<https://doi.org/https://doi.org/10.1016/j.dss.2023.113955>
- Zhou, Z., Song, Z., Xiao, H., & Ren, T. (2023). Multi-source data driven cryptocurrency price movement prediction and portfolio optimization. *Expert Systems with Applications*, 219, 119600.  
<https://doi.org/https://doi.org/10.1016/j.eswa.2023.119600>

## **Abstract**

# **The combination of sentiment analysis and an approach based on recurrent neural networks for the estimation and analysis of cryptocurrencies**

By

**Ali Mansourabady**

The cryptocurrency market, due to its rapid growth and unpredictable volatility, provides a fertile ground for scientific research in the field of modeling and forecasting. This has led to the development of prediction models becoming one of the key areas of focus in supporting investment decision-making and guiding both market participants and researchers. The primary objective of this study is to investigate the effectiveness of combining recurrent deep neural networks in enhancing the accuracy of cryptocurrency price prediction. In this work, residual recurrent neural network architectures are employed to mitigate issues such as the vanishing gradient problem, thereby improving predictive performance over long sequences. To validate the robustness of the proposed approach, multiple cryptocurrencies were analyzed. The proposed method integrates historical price data with news sentiment to predict the next day's price movements. For sentiment analysis of the news data, pretrained language models including CryptoBERT, FinBERT, and DistilRoBERTa were utilized. Experimental results demonstrate that the proposed model achieves higher accuracy compared to baseline methods. The contributions of this study lie in advancing cryptocurrency price prediction through the use of state-of-the-art sentiment analysis techniques, as well as in demonstrating the superiority of the residual recurrent architecture for time-series forecasting tasks. Overall, the findings confirm that combining historical price data with sentiment analysis, together with the proposed architecture, significantly enhances predictive accuracy.

**Keywords:** cryptocurrencies, recurrent neural networks, Sentiment analysis, deep learning

**In the Name of God**

**The combination of sentiment analysis and an approach based on  
recurrent neural networks for the estimation and analysis of  
cryptocurrencies**

By  
**Ali Mansourabady**

Thesis  
Submitted to Zand Institute of Higher Education in Partial Fulfillment of the  
Requirements for the Degree of Master of Science (M.Sc.)

In  
Computer Software Engineering

Zand Institute of Higher Education  
Shiraz  
Islamic Republic of Iran

**Evaluated and Approved by the Thesis Committee as:**

.....	AH. Rasekh (Ph.D.), Assistant Prof. of the Dept. of Computer Engineering (Supervisor)
.....	A. Ghermezian (Ph.D.), Assistant Prof. of the Dept. of Computer Engineering (Advisor)
.....	Name

September 2025





**Department of Engineering**  
**M.Sc. Thesis in**  
**Computer Software Engineering**

**The combination of sentiment analysis and an  
approach based on recurrent neural networks for  
the estimation and analysis of cryptocurrencies**

**By**  
**Ali Mansourabady**

**Supervised by**  
**Amir Hossein Rasekh (Ph.D.)**

September 2025