

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



دانشکده برق و کامپیوتر

گروه کامپیوتر

پایان نامه برای دریافت درجه کارشناسی ارشد در رشته شبکه های کامپیوتری

پیش بینی قیمت سهام با سری اصلی و سری های کمکی با روش های نوین هوش مصنوعی
و یادگیری ماشین

استاد راهنما: جمشید باقرزاده

استاد مشاور: سامان تاجبخش

نگارش

محمدرضا رضائی

خرداد ۱۴۰۳

محمدرضا رضایی

۱۴۰۲/۰۴/۰۲

پیش بینی قیمت بازار سهام به کمک سری اصلی و سری های کمکی که روی آن تاثیر دارند با استفاده از روش های مدرن هوش مصنوعی و یادگیری ماشین



پایان نامه کارشناسی ارشد آقای/خانم محمدرضا رضایی در تاریخ ۱۴۰۳/۰۳/۳۰ به شماره ۱۷۱۶۳ با رتبه خیلی خوب و نمره ۱۸.۷۵ (به حروف هجده و هفتاد و پنج صدم) مورد پذیرش هیات محترم داوران قرار گرفت.

	استاد راهنما جمشید باقرزاده محاسفی
	استاد مشاور میرسامان تاجبخش
	داوری پایان نامه/رساله اصغر اصل اصغریان سردرود
	داوری پایان نامه/رساله صالح یوسفی

چکیده

پیش بینی قیمت سهام با استفاده از روش های هوش مصنوعی یکی از موضوعات جذاب و پراهمیت در حوزه مالی و سرمایه گذاری است. بازار سهام به دلیل نوسانات فراوان و پیچیدگی های ناشی از عوامل اقتصادی، سیاسی و روانشناختی، همواره مورد توجه پژوهشگران و فعالان بازار بوده است. با توجه به این که تصمیم گیری های مالی به شدت تحت تاثیر پیش بینی های دقیق و قابل اعتماد از روندهای آینده بازار قرار دارند، استفاده از ابزارهای پیشرفته تحلیل داده ها بیش از پیش اهمیت یافته است. در دهه های اخیر، بهره گیری از روش های هوش مصنوعی مانند شبکه های عصبی مصنوعی، الگوریتم های یادگیری ماشین، و تحلیل داده های بزرگ، تحولات چشمگیری را در عرصه پیش بینی قیمت سهام به وجود آورده است. این روش ها با استفاده از داده های تاریخی و شناسایی الگوهای مخفی در داده ها، می توانند روندهای آتی بازار را با دقت بالاتری پیش بینی کنند. استفاده از هوش مصنوعی در پیش بینی قیمت سهام مزایای متعددی دارد. این روش ها نه تنها می توانند دقت پیش بینی ها را افزایش دهند، بلکه با تحلیل سریع و کارآمد داده ها، امکان واکنش به موقع به تغییرات بازار را فراهم می کنند. همچنین، هوش مصنوعی قادر است عوامل متعددی را به صورت همزمان در نظر بگیرد و تاثیرات متقابل آن ها را تحلیل کند، امری که در روش های سنتی تحلیل بازار به دشواری امکان پذیر است.

یکی از رویکردهای نوین در این زمینه، استفاده از سری های کمکی برای بهبود دقت پیش بینی ها است. سری های کمکی به داده ها و اطلاعاتی اشاره دارند که می توانند به عنوان مکملی برای داده های اصلی قیمت سهام استفاده شوند. این داده ها ممکن است شامل اطلاعات اقتصادی کلان، شاخص های مالی دیگر، اخبار مرتبط با بازار، و حتی داده های شبکه های اجتماعی باشند. بهره گیری از سری های کمکی می تواند دید جامع تری از عوامل موثر بر قیمت سهام ارائه دهد و به بهبود مدل های پیش بینی کمک کند. در این مقاله، به بررسی کاربردهای مختلف هوش مصنوعی در پیش بینی قیمت سهام و نقش سری های کمکی در این فرآیند پرداخته می شود. ابتدا به معرفی مفاهیم پایه ای و ابزارهای هوش مصنوعی مورد استفاده در این زمینه می پردازیم و سپس به بررسی روش های مختلف پیش بینی و مقایسه آن ها با تکنیک های سنتی خواهیم پرداخت. در نهایت، چالش ها و محدودیت های استفاده از هوش مصنوعی و سری های کمکی در پیش بینی قیمت سهام و نیز آینده پژوهش ها و کاربردهای عملی این روش ها مورد بحث قرار خواهد گرفت. این بررسی جامع می تواند راهنمایی برای سرمایه گذاران و پژوهشگران علاقه مند به بهبود دقت و کارایی پیش بینی های مالی باشد.

واژه های کلیدی

هوش مصنوعی، یادگیری ماشین، سری های کمکی، عوامل موثر بر قیمت سهام، شبکه های عصبی، تاثیر دیگر بازارهای سهام در سری اصلی

فهرست مطالب

صفحه

فصل اول - کلیات	۱
۱-۱- مقدمه	۱
۱-۲- بیان مسئله	۳
۱-۳- فرضیه ها	۴
۱-۴- هدف ها	۴
۱-۵- محدودیت ها	۴
۱-۶- کاربردهای تحقیق	۵
فصل دوم : پیشینه تحقیق	۷
۱-۲- مقدمه	۷
۲-۲- روش های مبتنی بر شبکه عصبی برای پیش بینی قیمت سهام	۸
۳-۲- روش های یادگیری عمیق برای قیمت سهام	۱۷
۴-۲- بهبود شبکه های عصبی براساس روش های هیوریستیک برای پیش بینی قیمت سهام	۲۴
۵-۲- روش های مبتنی بر یادگیری تقویتی برای پیش بینی قیمت سهام	۲۵
۶-۲- روش های مبتنی بر یادگیری ماشین برای پیش بینی قیمت سهام	۲۷
۷-۲- مدل های رگرسونی برای پیش بینی قیمت سهام	۳۰
۸-۲- جمع بندی	۳۱
فصل سوم: مواد و روش ها	۳۲
۱-۳- روش تحقیق	۳۲

۳۳	۲-۳- معرفی داده ها
۳۳	۱-۲-۳- الکترونیک خودرو شرق (خشرق) - بازار دوم بورس
۳۴	۲-۲-۳- توسعه فناوری اطلاعات خوارزمی (مفاخر) - بازار اول فرابورس
۳۵	۳-۲-۳- سرمایه گذاری مسکن (ثمسکن) - بازار اول (تابلوی اصلی) بورس
۳۵	۴-۲-۳- گسترش نفت و گاز پارسیان (پارسان) - بازار اول (تابلوی اصلی) بورس
۳۶	۵-۲-۳- داده های دلار
۳۷	۳-۳- پیش پردازش داده ها
۴۱	۴-۳- سری های زمانی
۴۳	۵-۳- سناریوهای تحقیق
۴۳	۶-۳- مدل های پیشنهادی مطالعه
۴۷	۱-۶-۳- تعریف پارامترها
۴۷	۲-۶-۳- پیاده سازی مدل ها در سری های تک و چند متغیره
۵۵	۷-۳- معیارهای ارزیابی مدل ها
۵۸	فصل چهارم: نتایج و بحث
۵۸	۱-۴- مقدمه
۵۸	۲-۴- شروع پیش بینی و تعامل با کاربر
۷۱	۳-۴- نتایج ارزیابی مدل ها
۷۷	فصل پنجم: نتیجه گیری و پیشنهادها
۸۰	منابع و مآخذ

فصل اول - کلیات

۱-۱- مقدمه

پیش بینی به عنوان بیان رویدادهایی که در آینده رخ می دهد، قبل از وقوع، بر اساس اصول علمی و منطقی، تعریف شده است. با توجه به اهمیت بازارهای مالی برای فعالان اقتصادی، پیش بینی در این زمینه از محققان توجه زیادی کرده است. پیش بینی بازار سهام، به عنوان یکی از بزرگترین بازارهای مالی می تواند به پیش بینی کنندگان بسیار سودآور باشد. پویایی و پیچیدگی بازار به تجدید نظر خود به محققان اضافه شده است. بازار سهام مکانی است که در آن می توان سهام را انتقال، داد و ستد و گردش کرد. تاریخچه ای ۴۰۰ ساله دارد و می تواند به عنوان کانالی برای شرکت ها برای جمع آوری سرمایه استفاده شود. با انتشار سهام، حجم زیادی از سرمایه به بازار سهام سرازیر می شود. این امر تمرکز سرمایه را ارتقا می دهد، ترکیب ارگانیک سرمایه شرکت را بهبود می بخشد و توسعه اقتصاد کالایی را به شدت ارتقا می دهد. بنابراین، بورس به عنوان فشارسنج فعالیت های اقتصادی و مالی در یک کشور یا منطقه در نظر گرفته می شود. پیش بینی ارزش سهام به دلیل اهمیت آن در روندهای مالی عصر حاضر، از علاقه زیادی در بین مدیران، سهامداران و کارشناسان برخوردار است. پیش بینی بازار سهام به دلیل ویژگی های متعدد حاکم بر بازار سهام مانند بی نظمی ها، بی ثباتی، نفوذ سیاسی، روندهای روزانه بازار و سروصدا، به عنوان یک مشکل پیچیده و مبهم تلقی می شود. سرمایه گذاران و معامله گران، با این وجود، بر تحلیل علمی مانور داده های تاریخی یا قدیمی سهام و داده های اخیر سهام تکیه می کنند. برآورد بازار سهام بر اساس اطلاعات ثبت شده روزانه سهام بسیار دشوار است.

بورس یک موسسه مالی سازمان یافته است. سهام و ارز تحت کنترل نیروهای عرضه و تقاضا خرید و فروش می شوند. هدف اصلی بازار سهام این است که به عنوان یک بازار اولیه و ثانویه برای کشف قیمت تسهیلات سرمایه گذار و نشان دهنده فعالیت اقتصادی عمل کند. قیمت سهام حاوی اطلاعات پیچیده، ناقص و مبهم است که پیش بینی روند توسعه آن را به یک کار بسیار دشوار تبدیل می کند. داده های مالی نوسان به تعداد بی شماری از عوامل دائماً در حال تغییر مرتبط بستگی دارد. برای پیش بینی قیمت سهام، معامله گران از روش های تحلیل تکنیکال بنیادی استفاده می کنند. تحلیل بنیادی بازار بورس روش هایی را برای پیش بینی قیمت سهام پیشنهاد می کند.

در دنیای امروز، بورس یکی از مهم ترین مکان ها برای سرمایه گذاری است. در ایران نیز در سال های اخیر حجم معاملات و سرمایه گذاری ها در این بازار افزایش زیادی داشته است. با این حال، عوامل مختلف مؤثر بر قیمت سهام از جمله بحران های مالی خارجی و سیاست های پولی داخلی بیشترین تأثیر را بر بازار سهام تهران به عنوان اصلی ترین بازار مالی کشور داشته اند. مردم بدیهی است که سعی می کنند سرمایه خود را در بازارهای کم ریسک و با بازده بالا سرمایه گذاری کنند. از یک سو، بازدهی بالا در بازارهای سهام برای سرمایه گذاران و سوسه انگیز است، اما از سوی دیگر، ریسک

حضور در بازار، نگرانی هایی را برای آنها ایجاد می کند. یکی از کاربردی ترین راه ها برای کاهش این ریسک، پیش بینی قیمت آتی سهام در بازار سهام است. بورس ها ستون فقرات بخش مالی هر کشور هستند. اکثر کارگزاران، فروشندگان، خریداران و معامله گران سهام در بازار سهام از تکنیک های پیش بینی بازار سهام از طریق تحلیل تکنیکال، تحلیل بنیادی یا تحلیل سری زمانی استفاده می کنند. این روش ها نتایج پیش بینی درست را در بازار سهام تضمین نمی کنند، زیرا بر اساس روندهای گذشته بازار سهام هستند تا قیمت سهام.

در سال های اخیر، تعداد فعالیت های مالی با توسعه سریع اقتصادی به طور فزاینده ای در حال افزایش بوده و روند تغییرات آنها نیز به طور فزاینده ای پیچیده شده است. شناخت الگوی فعالیت های مالی و پیش بینی توسعه و تغییرات آنها از محورهای پژوهشی در محافل علمی و مالی است. پیش بینی تقریبی داده های مالی با استفاده از یک یا چند روش می تواند به درک توسعه و تغییرات بازار مالی در سطح کلان کمک کند و زمینه ای را برای سرمایه گذاران و سازمان های انتفاعی برای تصمیم گیری و برنامه ریزی تجاری در سطح میکروسکوپی فراهم کند. ، در نتیجه به آنها اجازه می دهد تا سود را به حداکثر برسانند. از آنجایی که داده های مالی حاوی اطلاعات پیچیده، ناقص و مبهم هستند، پیش بینی روند توسعه آنها یک چالش بسیار دشوار است.

شاخص های قیمت سهام در بین بازارهای مالی جهان به عنوان معیار اصلی ارزیابی عملکرد اوراق بهادار و بازار سهام بسیار مهم هستند. آنها از انباشت حرکات قیمت سهام همه شرکت ها یا طبقه خاصی از شرکت های موجود در بازار بورس به دست می آیند. بنابراین، از آنجایی که بازارهای مالی درجه بالایی از رقابت را در بین شرکت کنندگان ارائه می کنند، مطالعه مدل های پیش بینی شاخص قیمت سهام برای سرمایه گذاران برای تبدیل بازار اوراق بهادار به مکانی سودآور بسیار ضروری است. این امر از یک سو منجر به به روز رسانی دانش سرمایه گذاران در تصمیم گیری صحیح در انتخاب پرتفوی مناسب و از سوی دیگر فراهم شدن فرصت های سرمایه گذاری بین المللی برای سرمایه گذاران می شود.

اگر سرمایه گذاران شروع به دانستن زمان افزایش یا کاهش قیمت سهام کنند چه خواهد شد؟ آنها تمام پول خود را در آن سهام می گذاشتند و از حداکثر سود ممکن استفاده می کردند. با این حال، این امکان پذیر نیست، آنچه ممکن است انجام حدس های تخمینی و پیش بینی های آگاهانه بر اساس اطلاعات گذشته و حال موجود در مورد سهام خاص است. عمل حدس زدن تخمینی و پیش بینی آگاهانه برای پیش بینی آینده به عنوان تحلیل فنی یا یادگیری ماشین شناخته می شود. یادگیری ماشینی یکی از شرکت های تابعه هوش مصنوعی است. که با ایجاد و آزمایش الگوریتم ها با کمک داده ها سر و کار دارد. اتوماسیون در حال تسخیر بسیاری از صنایع است. رایانه ها با استفاده از مدل های ریاضی، با سرعت بالایی در تجارت آنلاین تصمیم می گیرند. بازارهایی را ایجاد می کند که در آن چشم انداز بلندمدت به سمت حرکات کوتاه مدت و فروش می رود. شبکه های عصبی مصنوعی و متد ماشین بردار پشتیبان متداول ترین الگوریتم هایی هستند که برای پیش بینی و تحلیل بازار سهام و حرکات آتی مورد استفاده قرار می گیرند. این الگوریتم ها با استفاده از داده های تیک تا

۹۹.۹ درصد دقت را ارائه می دهند. همچنین پیش بینی مالی را می توان به عنوان روابط فشرده داده، پر سر و صدا، غیر ثابت و بدون ساختار و پنهان برجسب گذاری کرد.

استفاده از روشهایی برای پیش بینی وضعیت آینده، همواره دغدغه اصلی اندیشمندان علوم مختلف بوده است. در این راه بطور طبیعی، روشهایی، قابلیت ماندگاری و کاربردی مناسب دارند که دارای کمترین خطای ممکن در پیش بینی باشند. بر این مبنا در سالهای بسیار، روشهایی ریاضی؛ اعم از میانگین ساده، میانگین موزون، میانگین دوبل، رگرسیون و مانند اینها، تنها الگوهایی بود که قاطعانه مورد تایید و استفاده قرار می گرفت؛ اما در مواقع گوناگون دارای اشکالاتی نیز بود. با ایجاد روشهای هوش مصنوعی، مانند شبکه های عصبی؛ بویژه در مواقعی که رابطه ریاضی مناسبی بین داده ها و متغیرهای مستقل و وابسته، قابل شکل دهی نبود، امیدواریهای بسیاری بوجود آمد. این امیدواریها تا جایی ادامه یافت که حتی آن را جایگزین روشهای ریاضی نیز دانستند.

۱-۲- بیان مسئله

بازار سهام به مجموعه ای از بازارها و مراکز مبادله ای اطلاق می شود که در آن فعالیت های اقتصادی مانند خرید، فروش و استقرار سهام شرکت های سهامی عام انجام می شود. چنین اقدامات مالی از طریق مبادلات رسمی نهادینه شده از طریق بازارهای خارج از بورس انجام می شود که تحت مجموعه ای از مقررات تعریف شده عمل می کنند. بازار سهام یک حوزه بسیار پویا و نامطمئن است، بنابراین پیش بینی بازار سهام به طور طبیعی به یک موضوع داغ تبدیل می شود. با توجه به پیشرفت قدرت محاسباتی در زمان های اخیر، پیش بینی بازار سهام بسیار سریعتر و دقیق تر بوده است. مدل های هوش مصنوعی و یادگیری ماشین نقش مهمی در پیش بینی قیمت سهام و در نتیجه تعیین یک نتیجه دقیق دارند.

یکی از موضوعاتی که سرمایه گذاران در بورس بیشتر به آن توجه می کنند، تغییر روند قیمت سهام است. قیمت سهام تحت تأثیر عوامل بسیاری از جمله تغییر سیاست های ملی، محیط های اقتصادی داخلی و خارجی، موقعیت های بین المللی و غیره است. تغییرات قیمت سهام اغلب غیرخطی است. پیش بینی تغییرات قیمت سهام از قبل همیشه موضوع مهمی برای اقتصاددانان بوده است. پیش بینی منطقی و دقیق از تغییر قیمت سهام می تواند ریسک سرمایه گذاری سرمایه گذاران را تا حد زیادی کاهش دهد. چنین پیش بینی به سرمایه گذاران اجازه می دهد تا قیمت سهام پیش بینی شده را در استراتژی سرمایه گذاری خود لحاظ کنند و به سرمایه گذاران کمک می کند تا درآمد سرمایه گذاری خود را به حداکثر برسانند.

بازار سهام مورد توجه گسترده سرمایه گذاران قرار گرفته است. نحوه درک نظم در حال تغییر بازار سهام و پیش بینی روند قیمت سهام همواره مورد توجه سرمایه گذاران و محققان بوده است. افزایش و کاهش قیمت سهام تحت تأثیر عوامل بسیاری مانند سیاست، اقتصاد، جامعه و بازار است. برای سرمایه گذاران سهام، پیش بینی روند بازار سهام ارتباط

مستقیمی با کسب سود دارد. هرچه پیش بینی دقیق تر باشد، می تواند به طور مؤثرتری از خطرات جلوگیری کند. برای شرکت های پذیرفته شده در بورس، قیمت سهام نه تنها منعکس کننده شرایط عملیاتی شرکت و انتظارات توسعه آتی است، بلکه یک شاخص فنی مهم برای تجزیه و تحلیل و تحقیق شرکت است. تحقیقات پیش بینی سهام نیز نقش مهمی در تحقیقات توسعه اقتصادی یک کشور ایفا می کند. بنابراین، تحقیق در مورد ارزش ذاتی و پیش بینی بازار سهام دارای اهمیت نظری و چشم انداز کاربردی گسترده ای است.

۱-۳- فرضیه ها

۱. انتخاب پارامترهای مناسب، دقت پیش بینی الگوریتم را بهبود خواهد بخشید.
۲. طراحی بهینه ساختار مدل، باعث افزایش دقت و بهبود عملکرد آن خواهد شد.
۳. استفاده از مدل های پیش بینی مبتنی بر هوش مصنوعی و یادگیری ماشین عملکرد بهتری خواهند داشت.
۴. استفاده از سری های کمکی و یافتن تاثیر آنها روی سری اصلی، کارایی مدل پیش بینی را افزایش خواهد داد.

۱-۴- هدف ها

۱. یک سری اصلی از داده های شرکت موجود است، از یک شبکه عصبی استفاده میشود که هم سری اصلی و هم سری های کمکی شامل قیمت دلار و طلا و مسکن را هم دریافت کرده و در نهایت یک سری واحد تحویل دهد.
۲. روش های مدرن که اخیراً استفاده متعدد و دقت خوبی داشته اند انتخاب شده و نتایج آنها مقایسه خواهد شد.
۳. برای درک روند رو به جلوی قیمت بازار و تحلیل داده ها، اطلاعات روی نمودار برای روش های مختلف رسم میشود.
۴. یک پارامتر ورودی الگوریتم یک زمان به عنوان تاریخ خواهد بود تا عملیات پیش بینی برای آن روز انجام شود.
۵. پیش بینی به صورت چند متغیره خواهد بود به صورتی که کمترین قیمت، بیشترین قیمت، قیمت باز شدن و قیمت بسته سهام را پیش بینی خواهد کرد.

۱-۵- محدودیت ها

درک الگوی فعالیت های مالی و پیش بینی توسعه و تغییرات آنها، تمرکز تحقیق در محافل علمی و مالی است. پیش بینی تقریبی داده های مالی با استفاده از یک یا یک سری از روش ها می تواند به درک توسعه و تغییرات در بازار مالی در سطح ماکروسکوپی کمک کند و پایه ای برای سرمایه گذاران و سازمان های سودمند برای تصمیم گیری های تجاری و برنامه های تجاری در سطح میکروسکوپی فراهم کند به این ترتیب آنها را قادر می سازد تا سود را به حداکثر برسانند. از

آنجا که اطلاعات مالی شامل اطلاعات پیچیده، ناقص و فازی است، پیش بینی روند توسعه آنها یک چالش بسیار دشوار است.

شاخص های قیمت سهام در بین بازارهای مالی جهان به عنوان معیار اصلی ارزیابی عملکرد اوراق بهادار و بازار سهام بسیار مهم هستند. آنها از انباشت حرکات قیمت سهام همه شرکت ها یا طبقه خاصی از شرکت های موجود در بازار بورس به دست می آیند. بنابراین، از آنجایی که بازارهای مالی سطح بالایی از رقابت را در بین شرکت کنندگان ارائه می کنند، مطالعه مدل های پیش بینی شاخص قیمت سهام برای سرمایه گذاران برای تبدیل بازار اوراق بهادار به مکانی سودآور بسیار ضروری است. این امر از یک سو منجر به به روز رسانی دانش سرمایه گذاران در تصمیم گیری صحیح در انتخاب پرتفوی مناسب و از سوی دیگر فراهم شدن فرصت های سرمایه گذاری بین المللی برای سرمایه گذاران می شود. با این وجود، پیش بینی بازارهای مالی یک کار پیچیده است، زیرا سری های زمانی مالی پر سر و صدا، غیر ثابت و نامنظم هستند. اگرچه روش های آماری و محاسباتی زیادی برای پیش بینی این سری ها وجود دارد، اما همچنان به عنوان یک مشکل دشوار بر روی متغیرهای مالی و به ویژه شاخص قیمت شناخته می شود. پیش بینی ها دقیق نیستند، اما میزان خطای آنها به الگوریتم مورد استفاده بستگی دارد. نکته مهم این است که به گفته محققین، رفتار اکثر متغیرها از یک روند غیرخطی در بازارهای مالی پیروی می کند. بنابراین، این احتمال وجود دارد که پیش بینی خطی نتایج مناسبی برای بررسی مسیر آینده متغیرهای مالی به همراه نداشته باشد.

بازار سهام یکی از بزرگترین بازارهای مالی است که در مجموع به ۸۰ تریلیون دلار رسیده است. پیش بینی وضعیت سهام در آینده مدتهاست که به عنوان یک کار مهم اما چالش برانگیز در زمینه تحقیقاتی تحلیل بازار مالی تلقی می شود. با این وجود، پیش بینی بازارهای مالی یک کار پیچیده است، زیرا سری های زمانی مالی پر سر و صدا، غیر ثابت و نامنظم هستند. اگرچه روش های آماری و محاسباتی زیادی برای پیش بینی این سری ها وجود دارد، اما همچنان به عنوان یک مشکل دشوار بر روی متغیرهای مالی و به ویژه شاخص قیمت شناخته می شود. پیش بینی ها دقیق نیستند، اما میزان خطای آنها به الگوریتم مورد استفاده بستگی دارد. نکته مهم این است که به گفته محققین، رفتار اکثر متغیرها از یک روند غیرخطی در بازارهای مالی پیروی می کند. بنابراین، این احتمال وجود دارد که پیش بینی خطی نتایج مناسبی برای بررسی مسیر آینده متغیرهای مالی به همراه نداشته باشد.

۱-۶- کاربرد های تحقیق

تریدر ها، مدیران مالی، افرادی که قصد خرید دارند، افرادی که بورس تدریس میکنند، استاد های اقتصاد دانشگاه ها، برنامه نویسانی که قصد توسعه نرم افزار مالی دارند، افراد تحلیلگر در بازارهای مالی و قطعاً افرادی که در این زمینه فعالیت

دارند میتوانند باتوجه به بودجه ای که در یک زمان خاص در دست دارند قادر خواهند بود با استفاده از نتیجه ای که از پیش بینی بدست می آید تصمیم خود را برای خرید قاطعانه بگیرند

شناخت الگوی فعالیت های مالی و پیش بینی توسعه و تغییرات آنها از محورهای پژوهشی در محافل علمی و مالی است. پیش بینی تقریبی داده های مالی با استفاده از یک یا چند روش می تواند به درک توسعه و تغییرات بازار مالی در سطح کلان کمک کند و زمینه ای را برای سرمایه گذاران و سازمان های انتفاعی برای تصمیم گیری و برنامه ریزی تجاری در سطح میکروسکوپی فراهم کند. ، در نتیجه به آنها اجازه می دهد تا سود را به حداکثر برسانند.

فصل دوم : پیشینه تحقیق

۲-۱- مقدمه

بورس یکی از حیاتی ترین مولفه های اقتصاد کنونی است. بسیاری از مردم همیشه سعی در پیش بینی قیمت سهام از جمله قیمت های افتتاحیه، بالاترین قیمت ها، پایین ترین قیمت ها، قیمت های بسته شدن و حجم معاملات سهام مورد علاقه خود دارند. پیش بینی دقیق قیمت سهام می تواند فرصت های بیشتری برای کسب سود در بورس برای سرمایه گذاران فراهم کند. اما پیش بینی قیمت سهام موضوعی دشوار است. تحت انواع تأثیرات از قبیل محیط اقتصادی، سیاست سیاسی، توسعه صنعتی، اخبار بازار و عوامل طبیعی، سهام پویا بوده و تنوع گسترده ای را نشان می دهد. بنابراین پیش بینی بازار سهام به دلیل ماهیت بسیار غیرخطی و ابعاد پیچیده به یک کار بسیار چالش برانگیز تبدیل می شود. در سال های اخیر، تکنیک ها و مدل های مختلفی برای پیش بینی سهام مورد تحقیق و بررسی قرار گرفته اند. این روش ها شامل شبکه های عصبی مصنوعی، ماشین های بردار پشتیبان، میانگین متحرک خودهمبسته یکپارچه، هموارسازی نمایی تطبیقی، نظریه چشم انداز و رگرسیون چندگانه است.

مسئله پیش بینی روند قیمت سهام یک مشکل کلاسیک است که توجه گسترده ای را از دانشگاه و صنعت به خود جلب کرده است. در اوایل دهه ۱۹۹۰، کارشناسان و محققان از شبکه های عصبی برای تحقیق در مورد پیش بینی روند قیمت سهام استفاده کردند. با ظهور فناوری داده کاوی و الگوریتم های یادگیری ماشین، بسیاری از کارشناسان و محققان از درخت های تصمیم، خوشه بندی، ماشین بردار پشتیبانی و سایر روش ها برای پیش بینی سهام استفاده کرده اند. در سال های اخیر، فناوری یادگیری عمیق در زمینه های دیگر به موفقیت های بزرگی دست یافته است، بنابراین این امر همچنین باعث شده است که یادگیری عمیق در حل مشکل پیش بینی روند قیمت سهام به موفقیتی دست یابد. مسئله پیش بینی روند قیمت سهام اساساً یک مسئله طبقه بندی پیش بینی مبتنی بر سری های زمانی است و فناوری یادگیری عمیق توانایی قوی برای مقابله با مشکلات سری زمانی دارد.

در ادبیات مالی، روش های پیش بینی قیمت به چهار گروه روش های تحلیلی فنی، تحلیل بنیادی و پیش بینی مبتنی بر سری های زمانی و یادگیری ماشین طبقه بندی می شوند. از طریق کشف الگوهای جدید در داده های تاریخی، یادگیری ماشین قصد دارد تابع زیربنایی را که بر اساس آن داده ها شکل می گیرد شناسایی کند و مدل های خطی و غیرخطی موجود در این داده ها را تحقق بخشد. در سال های گذشته، الگوریتم هایی مانند شبکه های عصبی مصنوعی و ماشین بردار پشتیبان به طور گسترده برای پیش بینی سری های مالی و دستیابی به دقت بالا در پیش بینی مورد استفاده قرار گرفتند. نتایج مطالعات حاکی از برتری قابل توجه این روش ها نسبت به روش های سنتی در پیش بینی قیمت سهام است. به همین دلیل، در بسیاری از کشورها مانند ایالات متحده آمریکا، آلمان، فرانسه و بریتانیا، محققان موفق به پیش بینی رفتار بازار

سهام از طریق روش های مختلف یادگیری ماشین شده اند. روش های یادگیری ماشینی اغلب به عنوان زیرشاخه هوش مصنوعی در نظر گرفته می شوند. با این حال، تعداد زیادی از مطالعات با استفاده از یادگیری ماشین، بر خلاف روش های دیگر هوش مصنوعی، وجود دارد.

یادگیری عمیق یکی از مدل های یادگیری ماشینی است که اخیراً ابداع شده است. این شاخه ای از یادگیری ماشین و هوش مصنوعی و مجموعه ای از الگوریتم ها است که سعی می کند مفاهیم مفهومی سطح بالا را با استفاده از یادگیری در سطوح و لایه های مختلف مدل سازی کند. یادگیری می تواند تحت نظارت، نیمه نظارت یا بدون نظارت باشد. از مهمترین مزایای یادگیری عمیق می توان به یادگیری خودکار ویژگی ها، یادگیری چندلایه ویژگی ها، دقت بالا در نتایج، قدرت تعمیم بالا و شناسایی داده های جدید اشاره کرد.

با ورود تدریجی بازارهای سهام به دید عمومی، پیش بینی دقیق شاخص های قیمت سهام به یکی از امیدوارکننده ترین پروژه های تحقیقاتی در پیش بینی سری های زمانی تبدیل شده است. روش های پیش بینی رایج به دو دسته تقسیم می شوند: روش های اقتصادسنجی و مدل های مبتنی بر هوش مصنوعی. ثابت شده است که دومی، که توسط شبکه های عصبی مصنوعی نشان داده می شود، بهتر از روش های اقتصادسنجی در برخورد با سری های زمانی غیر ثابت و غیر خطی عمل می کند. در سال های اخیر الگوریتم هایی برای پیش بینی روند سهام به طور مداوم پیشنهاد شده اند. از منظر پیش بینی می توان آنها را به دو دسته عمده تقسیم کرد. یکی پیش بینی روند قیمت سهام است که به آن طبقه بندی می گویند. دیگری پیش بینی قیمت سهام است که به آن رگرسیون می گویند. علاوه بر این، از منظر زمان پیش بینی، تقریباً به دو نوع پیش بینی روند کوتاه مدت و بلندمدت قیمت سهام تقسیم می شود. به طور کلی، مدت زمان پیش بینی روند قیمت سهام با ویژگی های انتخاب شده همبستگی بالایی دارد. به عنوان مثال، معمولاً از شاخص هایی مانند قیمت پایانی دیروز و قیمت بسته شدن میانگین متحرک ۵ روزه استفاده می شود. پیش بینی روند کوتاه مدت سهام در مقابل، عوامل مالی مانند درآمد عملیاتی و بازده کل دارایی ها در پیش بینی روند بلندمدت سهام مفیدتر هستند.

۲-۲- روش های مبتنی بر شبکه عصبی برای پیش بینی قیمت سهام

در این بخش پژوهش هایی مورد بررسی قرار می گیرند که به پیش بینی قیمت های سهام شرکت های مختلف از سرار دنیا با استفاده از روش های متنی بر شبکه های عصبی پرداخته اند.

با توجه به ویژگی های نوسانات بازار سهام، پیش بینی قیمت سهام اغلب یک پیش بینی سری زمانی غیرخطی بوده و پیش بینی از طریق یک مدل ساده دشوار است. بنابراین، ونجی لو و همکاران [1] به منظور پیش بینی دقیق تر قیمت سهام یک روش ترکیبی^۱ پیشنهاد می کنند تا پیش بینی قیمت بسته شدن سهام روز بعد را پیش بینی کند. این روش با

¹ CNN-BiLSTM-AM

استفاده از قیمت باز، بالاترین قیمت، پایین ترین قیمت، قیمت بسته شدن، حجم، گردش مالی، صعود و سقوط و تغییر داده های سهام به عنوان ورودی استفاده می شود. بنابراین، استفاده کامل از ویژگی های توالی زمانی داده های سهام را ممکن می کند. این روش از شبکه های عصبی پیچشی^۱، حافظه طولانی کوتاه مدت دوطرفه^۲ و مکانیسم توجه^۳ تشکیل شده است. شبکه های عصبی پیچشی برای استخراج ویژگی^۴ از داده های ورودی استفاده می شود. حافظه طولانی کوتاه مدت^۵، بهبود شبکه عصبی بازگشتی^۶ است که از مشکل ناپدید شدن شیب و نویز گرادیان ناشی از شبکه عصبی بازگشتی جلوگیری می کند. حافظه طولانی کوتاه مدت دوطرفه به طور کامل می تواند وابستگی متقابل داده های سری زمان سهام را پیدا کند و از داده های ویژگی که استخراج شده برای پیش بینی قیمت بسته شدن سهام در روز بعد استفاده می کند. از مکانیسم توجه برای به دست آوردن تأثیر حالت های ویژگی ها بر قیمت بسته شدن سهام (داده های سری زمانی در قیمت سهام) در زمان های مختلف در گذشته برای بهبود دقت پیش بینی استفاده می شود. روش ترکیبی پیشنهادی^۷ برای پیش بینی قیمت سهام و ارائه راهی مطمئن برای سرمایه گذاران برای تصمیم گیری سرمایه گذاری سهام مناسب تر است. در این آزمایش، سهام شاخص ترکیبی شانگهای به عنوان داده های تجربی انتخاب شده است. داده های معاملات روزانه ۷۰۸۳ روز معاملاتی از ۱ جولای ۱۹۹۱ تا ۳۰ ژوئن ۲۰۲۰ از پایگاه داده wind به دست آمده است. هر قطعه داده شامل هشت مورد است: قیمت افتتاحیه، بالاترین قیمت، پایین ترین قیمت، قیمت بسته شدن، حجم، گردش مالی، فراز و نشیب، و تغییر. برای اثبات کارایی این روش، از این روش و هفت روش دیگر برای پیش بینی قیمت بسته شدن سهام در روز بعد برای ۱۰۰۰ روز معاملاتی شاخص ترکیبی شانگهای استفاده می شود. نتایج تجربی نشان می دهد که روش ترکیبی پیشنهادی دارای بالاترین دقت پیش بینی و بهترین عملکرد در مقایسه با متدهای پرسپترون چندلایه^۸، شبکه های عصبی پیچشی، شبکه های عصبی بازگشتی، حافظه طولانی کوتاه مدت، حافظه طولانی کوتاه مدت دوطرفه و مدل های ترکیبی دیگری^۹ با مجموعه داده های یادگیری و آزمایش یکسان در محیط عملیاتی یکسان را دارد. میانگین خطای مطلق و ریشه میانگین مربع خطا در این متد نسبت به بقیه متدها کمتر بوده (که ۲۱.۹۵۲ و ۳۱.۶۹۴ می باشند) و R^2 در بزرگترین مقدار خود و نزدیک به ۱ است (مقدار آن ۰.۹۸۰۴ است). برای اینکه به دقت پیش بینی بالایی برسیم به جای استفاده از یک شبکه، میتوانیم پیچیدگی شبکه را بیشتر کنیم تا دقت پیش بینی بهبود یابد. روش ترکیبی برای پیش بینی قیمت سهام مناسب است و می تواند مرجع مربوط به سرمایه گذاران برای به حداکثر رساندن بازده سرمایه گذاری ارائه دهد. همچنین این متد تجربه عملی برای تحقیقات افراد در داده های سری مالی را فراهم می کند. در این آزمایش، تمام پارامترهای آموزش متد

¹ Convolutional Neural Networks (CNN)

² Bidirectional Long Short-term Memory (BiLSTM)

³ Attention Mechanism

⁴ Feature extraction

⁵ Long short-term Memory

⁶ Recurrent Neural Networks

⁷ CNN-BiLSTM-AM

⁸ Multi layer perceptron

⁹ CNN-LSTM, CNN-BiLSTM, BiLSTM-AM

یکسان است، دوره ۱۰۰، تابع ضرر میانگین خطای مطلق است، از بهینه ساز Adam استفاده شده، اندازه دسته ۶۴، گام زمانی ۵ و نرخ یادگیری^۱ ۰.۰۰۱ است. کار تحقیقاتی آینده عمدتاً پارامترهای مدل را تنظیم می کند تا نتایج دقیق تر شود و میتوان تحقیق کرد که آیا مدل را می توان به زمینه های بیشتری از پیش بینی سری زمانی، مانند پیش بینی قیمت طلا، پیش بینی قیمت نفت، پیش بینی آب و هوا، پیش بینی زلزله و غیره اعمال کرد.

در پژوهشی دیگر، وی چن و همکاران [2] یک روش جدید برای پیش بینی روند سهام را با استفاده از مدل شبکه عصبی پیچشی مبتنی بر گراف پیچشی بر مبنای ویژگی^۲ پیشنهاد می کنند که در آن هر دو اطلاعات بازار سهام و اطلاعات سهام فردی مورد بررسی قرار می گیرند. با الهام از شبکه مجتمع مالی، آنها شبکه های بازار سهام و ماتریس های مربوطه را ساختیم تا اطلاعات بازار سهام را بر اساس همبستگی بین سهام و ویژگی هر سهام نشان دهند. در همین حال، آنها سهام هدف را بر اساس داده های تجاری و شاخص های فنی برای به دست آوردن اطلاعات سهام فردی تجزیه و تحلیل می کنیم. در روش پیشنهادی، اطلاعات بازار سهام، به عنوان مثال، شبکه های سهام ساخته شده و ماتریس های مربوطه مربوطه و اطلاعات سهام فردی، به عنوان مثال، داده های تجاری و شاخص های فنی سهام هدف، به تصاویر تبدیل می شوند. به طور خاص، یک شبکه بهبود یافته گراف پیچش^۳ و شبکه های عصبی پیچشی دوگانه^۴ برای ساخت مدل جدید طراحی شده است، که می تواند به طور همزمان ویژگی های بازار سهام و ویژگی های سهام فردی شامل داده های ساختار توپولوژیک را جمع اوری کند. به طور کلی روش پیشنهادی به سه مرحله اصلی تقسیم می شود: کشف سهام مرتبط، ایجاد تصویر و پیش بینی روند سهام. سپس شش سهام چینی به طور تصادفی انتخاب شده تا عملکرد برتر روش پیشنهادی را نشان دهد. برای مقایسه عملکرد روش های مختلف، چندین معیار ارزیابی لازم است که باید از قبل انتخاب شوند. در ارزیابی عملکرد محاسباتی از دقت^۵، درستی^۶، فراخوان^۷ و اندازه گیری^۸ F استفاده می شود. در ارزیابی مالی، آنها معاملات سهام را شبیه سازی می کنیم و عمدتاً بر بازده و ریسک معاملات تمرکز می کنیم. بنابراین، کل پول، میانگین بازده سالانه و نسبت تیز برای ارزیابی نتایج معاملات شبیه سازی شده استفاده می شوند. سهام برای آزمایش های آنها از بازار سهام چین است. برای پیش پردازش داده های اصلی، از دو مرحله زیر استفاده شد. ابتدا، مقادیر شاخص های فنی را که برای تولید تصاویر استفاده می شد، محاسبه کردند. دوم، با توجه به داده های گمشده ناشی از تعلیق، داده های گمشده را با صفر پر کردند تا وضعیت معلق را نشان دهد.

¹ Learning rate² Graph convolutional feature based convolutional neural network (GC-CNN) model³ improved graph convolutional network⁴ Dual-CNN⁵ Accuray⁶ Precision⁷ Recall⁸ F-measure (F_1)

در تحقیقی دیگر، ماناس رانجان سنپاتی و همکاران [2] یک مدل هوشمند و مطلوب برای پیشگویی قیمت بازار سهام با استفاده از ترکیب شبکه عصبی آدالین¹ و بهینه سازی ازدحام ذرات اصلاح شده ارائه می دهد. مدل ترکیبی شبکه عصبی آدالین و و بهینه سازی ازدحام ذرات از نوسانات بازار سهام به عنوان یک عامل استفاده می کند و از و بهینه سازی ازدحام ذرات برای بهینه سازی و به روزرسانی وزن های نمایش آدالین برای نشان دادن قیمت باز بورس bombay استفاده می کند. عملکرد پیش بینی مدل پیشنهادی با نمایش های مختلف مانند اندازه گیری های فاصله، CMS-PSO و Bayesian-Ann مقایسه شده است. نتایج تجربی و شبیه سازی نشان می دهد که طرح پیشنهادی از نظر میانگین درصد مطلق خطا² نسبت به همه شماهای دیگر برتری دارد. این مدل پیش بینی یک روش بالقوه برای پیش بینی سری مالی است. همچنین مدل پیش بینی پیشنهادی به خوبی آموزش داده شده است تا خطای مربعات میانگین کاهش یافته³ و میانگین درصد خطای مطلق کاهش یافته ای را در مورد داده های موجودی HDFC و JSPL ارائه دهد. به نظر می رسد این مدل در پیش بینی سهام عملکرد خوبی داشته باشد. از نتایج به دست آمده، می توان مشاهده کرد که میانگین درصد خطای مطلق برای مدل پیشنهادی حداقل است که برای JSPL و HDFC به ترتیب ۱.۱ و ۱.۰۸ است. پارامترهای مورد استفاده در این مدل بهینه و داده های ورودی از سری داده های نرمال شده دنیای واقعی است. شبکه با استفاده از همان سری داده های نرمال شده آموزش، آزمایش و اعتبارسنجی می شود. آنها معتقدند که اراعه بهبود یافته است و می تواند برای بین رفتن ارزش باز بازار سهام استفاده شود. برای بهبود آینده، مدل پیشنهادی را می توان به زمینه های دیگری مانند پیش بینی قیمت بنزین، قیمت برق یا قیمت کالاهای مختلف تعمیم داد. مدل پیش بینی با تغییر پارامتر و محیط خاصی کار خواهد کرد.

در پژوهشی دیگر نیز، سینا دامی و همکاران [6] تلاش کردند تا با استفاده از یافته های خود و با استفاده از شبکه عصبی مبتنی بر حافظه طولانی کوتاه مدت، نتایج بهتر در بورس اوراق بهادار تهران را بدست آورند. در زمینه مهندسی ویژگی، آنها سعی کردند تعداد ویژگی های خود را با استفاده از انتخاب ویژگی های مبتنی بر رمزگذار خودکار⁴ برای بهبود بازده سهام و به حداقل رساندن خطای پیش بینی کاهش دهند. برای ارزیابی روش پیشنهادی، یک معیار بازگشت که نزدیک به دنیای واقعی تجارت سهام است، مورد استفاده قرار می گیرد. نتایج تجربی نشان داد که استفاده از روش پیشنهادی خروجی بهتری با میانگین خطای کمتر به همراه داشت. یکی از ویژگی های خاص بازار سهام تهران، کارمزد بالا و مالیات بر فروش سهام است که معاملات مکرر در آن به طور مستمر مؤثر نیست (کمیسیون در بورس تهران ۱.۵ درصد قیمت معامله خرید و فروش در بازار آمریکا است، که نزدیک به صفر است). از این رو در این تحقیق به بررسی یک بررسی ۷ ساله از قیمت سهام در بازار سهام تهران پرداخته و عوامل مؤثر بر تغییر قیمت را شناسایی کردند تا بتوانند تغییرات قیمت را در بازه زمانی روزانه پیش بینی کنند و خرید و فروش را برای نمونه کارهای خاص پیشنهاد کنند. اجرای این تحقیق با استفاده از زبان برنامه نویسی پایتون با استفاده از توابع کتابخانه تنسورفلو و کراس انجام شده است. به طور

¹ Adaline neural networks (Adaptive Linear Neuron)

² mean absolute percentage error

³ Mean Square Error

⁴ AutoEncoder-based feature selection

خلاصه، ابتدا تعداد ویژگی ها را با استفاده از رمزگذاری خودکار از ۵ به ۲ کاهش دادند و از آنها به عنوان ورودی برای مدل های بعدی استفاده کردند. برای محاسبه خطا از میانگین خطای مطلق استفاده شد. آنها از رگولاتور ۲-L1L برای جلوگیری از بیش از حد مناسب^۱ رفتن الگوریتم استفاده کردند. برای بهینه سازی از بهینه ساز Adam استفاده شد. توقف زودهنگام نیز در مرحله دیگری برای جلوگیری از تطبیق بیش از حد با کمک داده های اعتبارسنجی استفاده شد. در نهایت، شبکه عصبی چندلایه پرسپترون، شبکه عصبی پیچشی و رگرسیون لاسو^۲ برای مقایسه عملکرد روش پیشنهادی استفاده شد. علاوه بر این، برای مقایسه بیشتر، همه روش ها را یک بار بدون فشرده سازی ورودی رمزگذاری خودکار و یک بار با آن (به جز Lasso) پیاده سازی کرده اند.

در پژوهشی دیگر، هونگ پیمگ هو و همکاران [7] یک الگوریتم کسینوس سینوسی بهبود یافته^۳ را ارائه می کنند، که یک پارامتر اضافی را به الگوریتم کسینوس سینوسی^۴، برای بهینه سازی وزن ها و اساس شبکه های عصبی انتشار برگشتی^۵ معرفی می کند. بنابراین الگوریتم کسینوس سینوسی بهبود یافته و اساس شبکه های عصبی انتشار برگشتی برای ایجاد یک شبکه جدید ترکیبی^۶، برای پیش بینی جهت قیمت های سهام افتتاحیه برای شاخص های میانگین صنعتی S&P ۵۰۰ و Dow Jones ترکیب می شوند. علاوه بر این، داده های ترندهای گوگل برای بهبود پیش بینی سهام در نظر گرفته می شود. آنها دو نوع پیش بینی را تحلیل می کنند: نوع اول پیش بینی بدون ترندهای گوگل و نوع دوم پیش بینی با ترندهای گوگل است. پیش بینی پذیری جهت قیمت سهام با استفاده از مدل ترکیبی پیشنهادی تأیید شده است. نتایج تجربی نشان می دهد که مدل ترکیبی ارائه شده از شبکه های عصبی انتشار برگشتی و مدل های ترکیبی دیگر^۷ از نظر پیش بینی جهت قیمت باز برای هر دو نوع و به طور قابل توجهی برای نوع دوم بهتر عمل می کند. نسبت برخورد^۸ برای روش پیشنهادی با ترندهای گوگل به ۸۶.۸۱ درصد برای شاخص S&P-500 و ۸۸.۹۸ درصد برای شاخص میانگین صنعتی Dow Jones می رسد. نتایج آنها نشان می دهد که ترندهای گوگل می تواند در پیش بینی جهت شاخص بورس کمک کند. بنابراین، آنها عملکرد بهینه سازی شبکه عصبی مصنوعی^۹ را با روند گوگل و الگوریتم بهبود یافته سینوسی بر اساس جمعیت بهبود می دهند. اینها به آنها نشان می دهد که الگوریتم های هوش مصنوعی قادر به بهینه سازی پارامترهای دیگر شبکه های عصبی مصنوعی برای پیش بینی ها و طبقه بندی ها هستند. بنابراین، آنها الگوریتم های اطلاعاتی جدید یا بهبود یافته را پیشنهاد خواهند کرد و الگوریتم های اطلاعاتی چندگانه را برای پیش بینی ها ترکیب می کنند.

¹ overfitting² Lasso regression methods³ improved sine cosine algorithm⁴ sine cosine algorithm⁵ back propagation neural networks⁶ ISCA-BPNN⁷ GWO-BPNN , PSO-BPNN , WOA-BPNN , SCA-BPNN⁸ hit ratios⁹ artificial neural networks

در پژوهشی دیگر، مدل های پیش بینی را بر اساس شبکه عصبی بازگشتی، حافظه طولانی کوتاه مدت و واحد بازگشتی گیتی پیشنهاد میکند (ژینگوا ژائو و همکاران [8]). مکانیسم توجه توانایی انتخاب و تمرکز "اطلاعات کلیدی" را دارد. تحقیقات موجود نشان می دهد که روش حافظه طولانی کوتاه مدت با لایه مکانیزم توجه می تواند عملکرد مدل را در مقایسه با حافظه طولانی کوتاه مدت معمولی بهبود بخشد. بنابراین، این پژوهش بر اساس شبکه عصبی بازگشتی مرسوم، مکانیسم توجه را معرفی کرده و یک مدل پیش بینی ترکیبی^۱ پیشنهاد می کند. و مدل سازی تجربی و تجزیه و تحلیل داده ها را انجام می دهد. این پژوهش شاخص ۴۰ سهام SSE ۱۸۰ و شاخص SSE را از ۵ ژانویه ۲۰۰۹ تا ۳۰ ژوئن ۲۰۱۹ انتخاب می کند تا مجموعه داده های اصلی را تشکیل دهد. نتایج نشان داد که در ابتدایی ترین آزمون مقایسه مدل های پیش بینی LSTM-M، GRU-M، GRU-M و LSTM-M به طور قابل توجهی از RNN-M بهتر بود و GRU-M کمی بهتر از LSTM-M بود؛ معرفی لایه مکانیسم توجه برای بهبود دقت مدل پیش بینی نوسانات سهام مفید بود؛ (۳) شبکه های عصبی عمیق تر لزوماً به نتایج بهتری دست پیدا نکردند. برای این آزمایش بهتر بود دو لایه به عنوان تعداد لایه های گردش انتخاب شود. در عین حال، مکانیسم توجه می تواند ثبات مدل را تا حد معینی بهبود بخشد.

در تحقیقی دیگر، بیت هه و همکاران [14] از مدلی استفاده می کنند که ترکیبی از شبکه های عصبی مانند شبکه عصبی بازگشتی، حافظه طولانی کوتاه مدت و واحد بازگشتی گیتی در یک شبکه های مولد تخصصی است. چارچوب الگوریتم های پیشنهادی برای پیش بینی قیمت سهام داده های S&P ۵۰۰ استفاده می شوند. در این پژوهش، آزمایش ها ثابت می کنند که مدل پیشنهادی نسبت به تحقیقات پیش بینی تک الگوریتم قبلی عملکرد بهتری در پیش بینی قیمت سهام دارد. داده های ۵۰ شرکت از فهرست سهام S&P ۵۰۰ برای آزمایش های آنها انتخاب شده اند سپس تقسیم بندی داده های آموزشی و داده های آزمون انجام شده. مجموعه داده از دارایی یاهو به دست آمده است. مجموعه داده شامل ۶ ویژگی مانند "باز"، "بستن"، "بالا"، "کم"، "حجم" و "تطبیق بسته" است که نشان دهنده قیمت افتتاحیه، قیمت بسته شدن، بالاترین قیمت، کمترین قیمت، حجم و قیمت بسته شدن تعدیل شده بود. شبکه های مولد تخصصی دو شبکه داخلی دارند: یک مولد و یک تفکیک کننده. مدل پیشنهادی از حافظه طولانی کوتاه مدت به عنوان مولد برای جذب الگوی داخلی از داده های موجودی سری زمانی و برای تولید روندهای آتی استفاده می کند و سپس از پرسپترون چند لایه، شبکه های عصبی بازگشتی، حافظه طولانی کوتاه مدت یا واحد بازگشتی گیتی به عنوان تمایزکننده برای تشخیص واقعی داده های آینده و داده های تولید شده توسط مولد استفاده میکند و همچنین از تفکیک کننده به عنوان یک تابع ضرر بزرگ که از شبکه عصبی دیگری تشکیل شده است استفاده می شود. برای ارزیابی مدل از مربع میانگین خطای ریشه و میانگین خطای مطلق استفاده شده است. برای ارزیابی الگوریتم ها از میانگین مقدار زیان و دقت ۵۰ شرکت استفاده شده است. در این تحقیق از قیمت پایانی برای شبیه سازی استفاده شده است. برنامه های شبیه سازی توسط PyTorch که یک کتابخانه یادگیری ماشین منبع باز است نوشته شده است. الگوریتم پیشنهادی شامل چهار شکل است که به نام های G-LSTM + D-MLP و

^۱ AT-RNN/AT-LSTM/AT-GRU

همچنین $G-LSTM + D-RNN$ ، $G-LSTM + D-LSTM$ و $G-LSTM + D-GRU$ می باشد. برچسب $G-LSTM$ نشان می دهد که $LSTM$ به عنوان ژنراتور انتخاب می شود. برچسب های $D-LSTM$ ، $D-RNN$ ، $D-MLP$ و $D-GRU$ به ترتیب MLP ، RNN ، $LSTM$ و GRU را به عنوان تشخیص دهنده نشان می دهند. به عنوان مثال، مدل با برچسب $G-LSTM+D-$ MLP نشان می دهد که مدل به ترتیب $LSTM$ را به عنوان مولد و MLP را به عنوان تشخیص دهنده می گیرد. طبق نتایج چهار مدل پیشنهادی دقت بهتری نسبت به میانگین متحرک خودهمبسته یکپارچه¹ و شبکه های مولد تخصصی دارند. به خصوص مدل $G-LSTM + D-LSTM$ که در بین مدل های پیشنهادی بهترین است، دقت بهتری نسبت به مدل های سنتی مانند متد میانگین متحرک خودهمبسته یکپارچه، شبکه مولد تخصصی و حافظه طولانی کوتاه مدت نشان می دهد. در آینده، مدل پیشنهادی باید برای شبیه سازی معاملات بازار برای آزمایش اعتبار مدل اعمال شود.

با توجه به ویژگی های سری زمانی مالی و وظیفه پیش بینی قیمت، در پژوهشی دیگر (جیمی مینگ تای هو و همکاران [15]) یک ساختار چارچوب جدید برای دستیابی به پیش بینی دقیق تر قیمت سهام ارائه می دهد که ترکیبی از شبکه عصبی پیچشی و شبکه عصبی حافظه طولانی کوتاه مدت است. این روش ترکیبی² آرایه ای از داده های تاریخی و شاخص های اصلی آن (گزینه ها و آینده ها) را می سازد و از آرایه به عنوان تصویر ورودی چارچوب شبکه عصبی پیچشی استفاده می کند و بردارهای ویژگی مشخصی را از طریق لایه پیچش و لایه ادغام³ و همچنین بردار ورودی از حافظه طولانی کوتاه مدت استخراج می کند و ده سهام در ایالات متحده و تایوان را به عنوان داده های تجربی می گیرد. در مقایسه با روش های قبلی، عملکرد پیش بینی الگوریتم پیشنهاد شده در این پژوهش منجر به نتایج بهتر در مقایسه به طور مستقیم می شود. استفاده از مجموعه داده در این کار ده سهم از دو بازار یعنی $AMZN$ ، FB ، $MSFT$ ، IBM ، $AAPL$ پنج سهام در بازار آمریکا و IJO ، DVO ، DJO ، CFO ، CDA در پنج سهام تایوان است. هر نمونه دارای چندین متغیر (عمدتاً داده های تاریخی، گزینه ها و قراردادهای آتی) و ۱۰ داده مشابه است. از آنجایی که اندازه داده هایی که در حال حاضر استفاده می شوند نسبتاً بزرگ است، روش خوبی برای مقیاس بندی داده ها به گونه ای است که در یک بازه زمانی خاص قرار گیرند. به این روش استانداردسازی داده می گویند. استفاده از استانداردسازی داده ها نه تنها می تواند راه حل بهینه نزول گرادیان را سرعت بخشد، بلکه دقت را نیز بهبود می بخشد. به طور کلی متد پیشنهادی به این صورت عمل میکند که روش ورودی آن تقلید عناصر ورودی تصویر شبکه عصبی پیچشی و تأیید داده های موجود در حال حاضر در قالب یک تصویر است سپس از طریق این وزن های شبکه آموزش تصویری برای استخراج ویژگی های مفید، ویژگی های استخراج شده به شبکه حافظه طولانی کوتاه مدت وارد می شوند تا بازار شدید را برای تولید سیگنال های مناسب شناسایی کند. داده های تاریخی و شاخص های پیشرو بازارهای سهام تایوانی و آمریکا به عنوان داده های ورودی استفاده می شود و بردار ورودی شبکه پیشنهادی با پیش پردازش تبدیل می شود. در آزمایش، این پژوهش انواع مختلف داده ها و شاخص

¹ Autoregressive Integrated Moving Average

² stock sequence array convolutional LSTM = SACLSTM

³ Pooling layer

های مختلف را برای آزمایش و دریافت سیگنال مناسب ترکیب می کند. بر این اساس، این پژوهش یک استراتژی تجاری ساده مبتنی بر پیش بینی را برای ارزیابی سودآوری و ثبات شبکه آزمایش می کند. همچنین این پژوهش داده های تاریخی، مجموعه داده های گزینه ها و قراردادهای آتی را برای مقایسه با روش های دیگر^۱ ترکیب و یک بردار دو بعدی را پیشنهاد می کند که سبک ورودی تصویر را شبیه سازی می کند و سپس آن را برای پیش بینی سهام وارد شبکه پیشنهادی می کند. این چارچوب ورودی، پیش بینی قیمت سهام را ممکن می سازد. در این پژوهش، محاسبات پیشنهادی با الگوریتم قبلی مقایسه می شود، داده هایی جمع آوری می شود و برای تأیید سودمندی الگوریتم آزمایش می شود.

در پژوهشی دیگر (ایودل اریو ادبی و همکاران [17]) عملکرد پیش بینی شبکه های عصبی میانگین متحرک خودهمبسته یکپارچه و شبکه های عصبی مصنوعی را با داده های سهام منتشر شده به دست آمده از بورس نیویورک بررسی می کند. نتایج تجربی به دست آمده نشان دهنده برتری مدل شبکه های عصبی نسبت به مدل شبکه های عصبی میانگین متحرک خودهمبسته یکپارچه است. عملکرد مدل پیش بینی کننده شبکه های عصبی مصنوعی در این مطالعه با مدل معمولی Jenkins ARIMA، که به طور گسترده ای برای پیش بینی سری زمانی مورد استفاده قرار گرفته است، مقایسه شد. یافته های آنها نشان داد که هر دو مدل شبکه های عصبی میانگین متحرک خودهمبسته یکپارچه و مدل شبکه های عصبی مصنوعی می توانند پیش بینی خوبی را در زمینه استفاده از مشکلات زندگی واقعی به دست آورند و بنابراین می توانند به طور موثر برای پیش بینی قیمت سهام سودآور باشند. آنها همچنین مشاهده کردند که الگوی مدل های پیش بینی شبکه های عصبی میانگین متحرک خودهمبسته یکپارچه جهت گیری است. مدل پیش بینی شده قیمت سهام توسعه یافته با رویکرد مبتنی بر شبکه های عصبی مصنوعی عملکرد برتر را نسبت به مدل های شبکه های عصبی میانگین متحرک خودهمبسته یکپارچه نشان داد؛ در واقع، ارزش های واقعی و پیش بینی شده مدل پیش بینی قیمت سهام توسعه یافته بسیار نزدیک است. در مطالعات آینده، ترکیبی از تکنیک های هوشمند می تواند برای بهبود مدل های پیش بینی کننده موجود با داده های سهام اخیر و شاخص سهام بیشتر شرکت کند. ابزار شبیه سازی مدل ها به ترتیب نرم افزار متلب ۲۰۰۷ و EViews برای مدل شبکه های عصبی مصنوعی و مدل شبکه های عصبی میانگین متحرک خودهمبسته یکپارچه می باشد. پارامترهای آموزشی به صورت زیر تنظیم شدند: نرخ یادگیری برابر ۰.۰۱، ترم تکانه برابر ۰.۹، و اندازه دوره برابر ۱۰۰۰، ۲۰۰۰، ۵۰۰۰. در نهایت، شبکه با مجموعه داده ها آزمایش شد تا توانایی تعمیم آن برآورد شود.

در پژوهشی دیگر (پنگ فب یو و همکاران [12])، داده های قیمت محصول مالی به عنوان یک سری یک بعدی تولید شده توسط طرح یک سیستم آشفته متشکل از عوامل متعدد به بعد زمانی در نظر گرفته می شوند و سری قیمت با استفاده از روش بازسازی فاز-فضای سری زمانی بازسازی می شود. مدل پیش بینی مبتنی بر شبکه عصبی عمیق بر اساس روش بازسازی فاز-فضا و شبکه های حافظه طولانی کوتاه مدت برای یادگیری عمیق طراحی شده است و برای پیش بینی قیمت

¹ SVM, CNNpred, CNN-corr, NN

سهام استفاده می شود. مقایسه نتایج نشان می دهد که مدل پیش بینی پیشنهادی دقت پیش بینی بیشتری دارد. به طور کلی یک مدل پیش بینی برای داده های قیمت مالی که سری های زمانی غیر ثابت و نسبتاً پر سر و صدا هستند، از طریق سه مرحله فرآیندی یعنی پردازش داده های سری زمانی، ساخت مدل شبکه و ارزیابی و تحلیل نتایج ارائه شده است. روش بازسازی فاز-فضا برای تحلیل سری های زمانی با مدل شبکه حافظه طولانی کوتاه مدت مبتنی بر شبکه عصبی عمیق ترکیب شده است. حذف نویز و نرمال سازی داده ها در مرحله پیش پردازش انجام می شود. علاوه بر این، ساختار داده نیز با پارتیشن بندی با استفاده از یک پنجره زمانی به دست می آید. پس از آن، یک مدل مبتنی بر شبکه عصبی عمیق با انتخاب یک تابع فعال سازی بهینه و روش بهینه سازی طراحی و بهینه سازی می شود. سپس از چهار معیار برای ارزیابی اثربخشی مدل استفاده می شود. در نهایت، روش های مختلف پیش بینی، از جمله روش تحلیلی خطی شبکه های عصبی میانگین متحرک خودهمبسته یکپارچه، روش یادگیری رگرسیون بردار پشتیبان، یک مدل پرسپترون چندلایه عمیق، یک مدل حافظه طولانی کوتاه مدت عمیق که شامل فرآیند بازسازی فاز-فضا نیست و حافظه طولانی کوتاه مدت عمیق همراه با بازسازی فاز-فضا، مقایسه می شوند. مقایسه نتایج پیش بینی برای شاخص های مختلف سهام برای دوره های مختلف نشان می دهد که مدل پیش بینی مبتنی بر شبکه عصبی عمیق ظرفیت پیش بینی بالاتری نسبت به مدل های دیگر نشان می دهد.

در یک پژوهش دیگر، هونگ لی نیو و همکاران [16] یک مدل ترکیبی جدید مبتنی بر تجزیه حالت متغیر¹ و شبکه بازگشتی دروازه ای معرفی می کنند که با مکانیسم توجه بهبود یافته است تا دقت پیش بینی شاخص های قیمت سهام را افزایش دهد. در فرآیند ایجاد مدل، از تجزیه حالت متغیر برای تجزیه سری اولیه به چند دنباله تقریباً متعامد استفاده می شود. مکانیسم توجه به شبکه واحدهای بازگشتی دروازه ای معرفی شده است تا وزن های مختلفی را از قبل به عناصر ورودی اختصاص دهد تا بتوان نتایج پیش بینی بهتری برای هر جزء به دست آورد. در آزمایش تجربی، شاخص FTSE لندن و شاخص Nasdaq² برای بررسی عملکرد مدل ترکیبی³ اتخاذ شده اند. نتایج تجربی گزارش می دهند که مدل ترکیبی توسعه یافته از مدل های منفرد بهتر عمل می کند و در واقع دقت پیش بینی شاخص های قیمت سهام را افزایش می دهد. علاوه بر این، معرفی مکانیسم توجه می تواند سطح دقت پیش بینی را افزایش دهد اما ممکن است دقت پیش بینی جهت را کاهش دهد. با توجه به استراتژی "تجزیه و مجموعه"، ابتدا قیمت ها با تکنیک تجزیه حالت متغیر تجزیه می شوند که در آن ابتدا باید تعداد زیر مجموعه های صندوق بین المللی پول تعیین شود. همه فرآیندها در پایتون اجرا می شوند که بر روی یک پردازنده چهار هسته ای ایتل نسل پنج با فرکانس ۱.۴۰ گیگاهرتز با ۸ گیگابایت رم نصب شده اجرا می شود. در این کار، از قیمت بسته شدن روزانه دو شاخص که بالا معرفی شد برای بررسی اعتبار مدل پیشنهادی استفاده شده است. دو شاخص قیمت سهام منتخب هر دو نماینده در بازارهای سهام جهانی هستند و به عنوان معیارهای مهم توسعه

¹ variational mode decomposition² IXC³ VMD-AttGRU

اجتماعی و اقتصادی تلقی می شوند. آنها از شاخص های جهانی قیمت سهام پایگاه داده Wind جمع آوری شده اند که در قالب سری های زمانی [تاریخ، قیمت] ذخیره می شوند. آنها می خواهند استحکام شبکه پیش بینی جدید را بهتر تأیید کنند، این کار پنج معیار رایج را برای بررسی برتری مدل از دیدگاه های مختلف اتخاذ می کند که شامل میانگین خطای مطلق، خطای مربع میانگین ریشه، خطای درصد مطلق میانگین، ضریب نابرابری تیل¹ و آماره جهت دار² و Dstat هستند که در آن از چهار شاخص اول برای اندازه گیری سطح استفاده می شود. دقت پیش بینی و Dstat برای اندازه گیری صحت جهت پیش بینی شده برای یک سری زمانی بر حسب درصد استفاده می شود.

مطالعات تنها یک مقدار را پیش بینی می کنند. برای پیش بینی مقادیر چندگانه در یک مدل، باید مدلی طراحی شود که بتواند چندین ورودی را مدیریت کند و چندین مقدار خروجی مرتبط را به طور همزمان تولید کند. (گانگ یو دینگ و همکاران[25]) برای این منظور، یک مدل شبکه عصبی بازگشتی عمیق همراه با ورودی های متعدد و خروجی های متعدد بر اساس شبکه حافظه طولانی کوتاه مدت پیشنهاد شده است. مدل شبکه مرتبط می تواند قیمت افتتاحیه، کمترین قیمت و بالاترین قیمت سهام را به طور همزمان پیش بینی کند. مدل شبکه مرتبط با مدل شبکه حافظه طولانی کوتاه مدت و مدل شبکه عصبی بازگشتی عمیق مقایسه شد. آزمایش ها نشان می دهد که دقت مدل مرتبط در پیش بینی مقادیر چندگانه به طور همزمان نسبت به دو مدل دیگر برتری دارد و دقت پیش بینی آن بیش از ۹۵ درصد است. داده های تجربی در این پژوهش، داده های تاریخی واقعی هستند که از اینترنت دانلود شده اند. از سه مجموعه داده در آزمایش ها استفاده شد، یکی شاخص ترکیبی شانگهای و دیگری دو سهام پتروچاینا در بورس شانگهای و ZTE در بورس اوراق بهادار شنژن هستند. شاخص ترکیبی شانگهای دارای ۶۱۱۲ داده تاریخی است. پتروچاینا دارای ۲۶۸۸ داده تاریخی و ZTE دارای ۴۹۳۰ داده تاریخی است. هر مجموعه داده به یک مجموعه آموزشی و یک مجموعه آزمایشی به ترتیب زمانی به نسبت ۴:۱ تقسیم می شود. هر مجموعه داده دارای هفت پارامتر فنی است. از این پارامترهای فنی به عنوان ویژگی های ورودی اولیه و LP، OP و HP روز بعد به عنوان مقادیر خروجی مدل استفاده می شود. به منظور تأیید آموزش هر مدل در مرحله آموزش، سه مدل به طور جداگانه با استفاده از مجموعه آزمایشی از سهام چندگانه مورد آزمایش قرار گرفتند. خطای مربع میانگین مقدار مورد انتظار مربع تفاوت بین مقدار تخمینی پارامتر و مقدار واقعی پارامتر است، خطای مطلق میانگین بهتر می تواند وضعیت واقعی خطای مقدار پیش بینی شده را منعکس کند.

۲-۳- روش های یادگیری عمیق برای قیمت سهام

در این بخش پژوهش هایی مورد بررسی قرار می گیرند که به پیش بینی قیمت های سهام شرکت های مختلف از سراسر دنیا با استفاده از روش های متنی بر یادگیری عمیق پرداخته اند.

¹ Theil Inequality Coefficient

² directional statistic

در یک پژوهش (اشیش کومر و همکاران [3]) با هدف بهبود دقت پیش بینی و کاهش خطای پیش بینی از طریق معماری یادگیری عمیق با استفاده از شبکه مولد متخاصم ارائه شده است. این مدل یک مدل عمومی متشکل از روش بازسازی فاز-فضا¹ برای بازسازی سری قیمت و شبکه های مولد متخاصمی که ترکیبی از دو شبکه عصبی است که حافظه طولانی کوتاه مدت به عنوان مدل تولید کننده و شبکه عصبی پیچشی به عنوان مدل تبعیض آمیز برای آموزش های متخاصمی برای پیش بینی بازار سهام است. حافظه طولانی کوتاه مدت نمونه های جدیدی را بر اساس اطلاعات شاخص های اساسی تاریخی تولید می کند و سپس شبکه عصبی پیچشی برآورد می کند که آیا داده ها توسط حافظه طولانی کوتاه مدت پیش بینی شده یا واقعی است. در نهایت مشخص میشود که شبکه مولد متخاصم عملکرد خوبی نسبت به متد حافظه طولانی کوتاه مدت براساس فاکتور خطای تقویت شده ی مربع میانگین ریشه² دارد، زیرا ۴.۳۵ درصد دقیق تر در پیش بینی جهت و کاهش زمان پردازش و خطای مربع میانگین ریشه به ترتیب ۷۸ ثانیه و ۰.۰۲۹ بود. این مطالعه نتیجه ای بهتر در دقت شاخص سهام را فراهم می کند. به نظر می رسد که سیستم پیشنهادی بر کاهش خطای مربع میانگین ریشه و زمان پردازش و بهبود دقت پیش بینی جهت حرکت سهام، تمرکز می کند و نتیجه بهتری در دقت شاخص سهام را ارائه میدهد. معیارهای ارزیابی خطای نسبی مربع میانگین ریشه³، خطای اصلاح شده ی مربع میانگین ریشه⁴، دقت جهت گیری⁵، تابع ضرر⁶ و دقت جهت گیری اصلاح شده⁷ هستند. بر این اساس کلیت پژوهش می تواند به شرح زیر باشد: استفاده از تابع ضرر برای اندازه گیری افت خطای پیش بینی هر نمونه آموزشی. دقت جهت اندازه گیری دقت مربوط به روند سری است. این پارامتر برای اندازه گیری ظرفیت پیش بینی مدل استفاده می شود. دقت جهت بالاتر، دقت پیش بینی را بالاتر می برد. یا به عبارت دیگر، دقت جهت بالاتر به معنای معاملات برنده بیشتر است و خطای مربع میانگین ریشه شاخصی برای نزدیک بودن پیش بینی به قیمت واقعی است. این تحقیق به منظور غلبه بر محدودیت های بهترین راه حل فعلی برای دستیابی به دقت پیش بینی بر اساس خطای مربع میانگین ریشه برابر با ۰.۰۵۸۵ با میانگین زمان پردازش برابر با ۳ دقیقه و ۲۶ ثانیه بررسی شده است. این نتیجه توجیه می کند که افزودن خطای تقویت شده ی مربع میانگین ریشه پیشنهادی بر محدودیت های بهترین راه حل فعلی غلبه کرده است. بر اساس بررسی تحقیقات پیشین، چندین راه حل برای حل و غلبه بر این موضوع پیشنهاد شده است، اما تا کنون هیچ کدام نمیتوانند خطای دقیق مربع میانگین ریشه را ارائه دهند. الگوریتم پیشنهادی توانایی ها را برای به حداقل رساندن خطای مربع میانگین ریشه فراهم میکند تا دقت پیش بینی شاخص قیمت بسته به ۶۱.۴۵ درصد و ۲ دقیقه و ۸ ثانیه زمان پردازش را بهبود بخشد.

¹ Phase-space Reconstruction

² enhanced root mean square error

³ Root Mean Square Relative Error

⁴ Modified Root Mean Square Error

⁵ Directional accuracy

⁶ loss function

⁷ Modified Directional accuracy

در پژوهشی دیگر، مجموعه داده آزمایشی مورد استفاده، مجموعه داده های بازار سهام ملی بورس^۱ است، به ویژه شاخص قیمت NIFTY، در بازه زمانی آوریل ۲۰۰۸ تا آوریل ۲۰۱۸، جمع آوری شده از وب سایت ملی بورس هند است. این مدل ها با استفاده از کتاب خانه کراس در پایتون آموزش و آزمایش شدند. این پیکربندی سخت افزار و نرم افزار حدود ۳ ساعت طول کشید تا مدل شبکه عصبی مصنوعی برای ۱۰۰۰۰ دوره آموزش داده شود و حدود ۱ ساعت و ۳۰ دقیقه برای آموزش مدل شبکه عصبی پیچشی برای ۱۵۰ دوره طول کشید. انگیزه این مطالعه این است که پیش بینی های دقیق ارزش های بازار سهام برای روزهای متوالی در طول نوسانات بازار شدید مانند پاندومی کووید ۱۹ در ماه مارس و آوریل ۲۰۲۰ ارائه شود. در حالت کلی این مطالعه (سومنات موخرجی و همکاران [9]) دو رویکرد را برای پیش بینی شاخص های بازار سهام و قیمت سهام پیشنهاد می کند. این مطالعه ابتدا از یک شبکه عصبی پیش خور^۲ استفاده می کند و الگوریتم پس انتشار^۳ را برای فرآیند آموزش انجام می دهد. این مدل بینشی اساسی در مورد روند پیش بینی و یک نتیجه گرافیکی در مورد اینکه چگونه پیش بینی باید به نظر برسد ارائه کرد. این مدل با میانگین دقت پیش بینی ۹۷.۶۶ درصد نتایج رضایت بخشی به دست داد، اما برای رسیدن به دقت فوق به داده ها و دوره های آموزشی زیادی نیاز داشت. علاوه بر این، تا حدودی دچار بیش از حد برازش نیز شده بود که با استفاده از روش منظم سازی انجام شد. بنابراین، برای غلبه بر هزینه آموزش گسترده، این مطالعه رویکرد پاک تر دیگری را ارائه می دهد. مدل شبکه عصبی پیچشی نتایج بهتری را در یک مجموعه داده مشخص ارائه می دهد. این مطالعه رویکرد متفاوتی برای تجزیه و تحلیل داده های سری زمانی پیدا می کند. از هیستوگرام های دوبعدی خاکستری تولید شده از داده های سری زمانی برای پیش بینی استفاده می کند. کل مجموعه داده به ۱۵ بخش تقسیم می شود، هر بخش به مدل شبکه عصبی پیچشی وارد می شود و حداکثر دقت برای هر یک از آنها به دست می آید. این افزایش ورودی به مدل تفاوت زیادی در زمان آموزش و دقت پیش بینی ایجاد می کند. این مدل به داده های آموزشی و زمان کمتری نسبت به مدل قبلی نیاز داشت. پس از مرحله آموزش و کمی سازی، میانگین دقت پیش بینی ۹۸.۹۲ درصد به دست می آید که نسبت به مدل قبلی نیز بهتر است. از سوی دیگر، تولید تصاویر مصنوعی در هیستوگرام های دوبعدی هزینه ای را اضافه می کند که در رویکرد اول وجود ندارد. هر دو روش مزایا و معایب خود را دارند، اما هر دو می توانند پیش بینی های تقریباً دقیقی را برای مجموعه داده هایی از این نوع ارائه دهند. چنین پیش بینی کارآمدی از بازار سهام در دنیای امروز ضروری است. برای تحلیلگران بازار سهام که می توانند راه حل هایی را برای کمک به شرکت ها و اقتصادها با پیش بینی الگوهای آینده در بازار سهام توسعه دهند، مفید خواهد بود.

در پژوهشی دیگر، یونگ شی و همکاران [11] یک سیستم تجزیه و تحلیل احساسات جدید را با شبکه های عصبی عمیق برای نظرات سهام پیشنهاد کردند و اطلاعات مربوط به احساسات برآورد شده را به پیش بینی حرکت سهام اعمال

¹ NSE

² Feed-forward Neural Network

³ backpropagation algorithm

کردند. نتایج تجربی نشان داد که روش طبقه بندی عمیق آنها به بهبود ۹٪ در مورد الگوریتم رگرسیون لجستیک^۱ به دست آورد و یک استخراج کننده دقیق احساسات^۲ را برای مرحله پیش بینی بعدی ارائه داد. علاوه بر این ویژگی های ترکیبی جدید آنها که داده های معاملاتی سهام و اطلاعات احساسات را به دست آورد، ۱.۲۵٪ بهبود را در میان ۱۵۰ سهام چینی در مجموعه داده های تست به دست آورد. برای سهام آمریکا، اطلاعات احساسات نتایج پیش بینی شده را کاهش می دهد. آنها دریافتند که ویژگی های احساسات استخراج شده از نظرات در واقع برای سهام با قیمت بالاتر نسبت به ارزش دفتری و ارزش ریسک بتا پایین تر در چین مؤثر است. برای کار پیش بینی، سه بخش مهم وجود دارد. بخش اول یک جمع آورنده داده با یک سری خزنده های وب است و هر خزنده برای جمع آوری انواع مختلف داده ها از اینترنت استفاده می شود. بخش اصلی دوم یک موتور تجزیه و تحلیل احساسات مبتنی بر یک شبکه یادگیری عمیق است که عمدتاً برای ارائه اطلاعات احساسات اضافی برای سهام فردی استفاده می شود. و بخش سوم یک سیستم پیش بینی حرکت سهام بر اساس داده های معاملات سهام و داده های احساسات است. از طریق تجزیه و تحلیل تجربی، آنها می توانند نتیجه های زیر را جلب کنند: ۱. تجزیه و تحلیل احساسات مبتنی بر روش های یادگیری عمیق برای پیش بینی حرکت سهام قابل عمل است و ویژگی های احساسات تأثیر مثبتی بر پیش بینی دارند. در فرآیند استخراج ویژگی احساسات، اگرچه شبکه های عصبی عمیق، مانند شبکه های عصبی پیچشی و واحد بازگشتی گیتی به بهترین نتایج طبقه بندی قطبیت^۳ دست یافتند، اما تقریباً سهم یکسانی در پیش بینی نهایی با روش رگرسیون لجستیک^۴ دارند. بنابراین، استخراج ویژگی مبتنی بر یادگیری ماشین می تواند عملکردی مشابه با روش های مبتنی بر یادگیری عمیق داشته باشد. ۲. برای هر دو ویژگی های تجاری و ویژگی های ترکیبی، تجزیه و تحلیل مؤلفه های اصلی^۵ یک روش تجزیه و تحلیل مؤثر و قدرتمند است. این بهترین عملکرد را در میان روش های انتخاب ویژگی به دست آورد. از طریق تجسم ویژگی، می توانند یاد بگیرند که اطلاعات بیشتر احساسات پس از مهندسی ویژگی فیلتر شده است. ۳. معقول ترین روزهای مرجع تاریخی، پنج است که دقیقاً یک چرخه تجاری در یک هفته است. بر این اساس، مدل پیش بینی تنها می تواند حرکات را در چند روز آینده پیش بینی کند و در پیش بینی بلندمدت با شکست مواجه می شود. ۴. تجزیه و تحلیل احساسات برای سهام با نسبت P/B بالاتر و ارزش ریسک بتا کمتر مفید است. این رفتار نشان می دهد که سرمایه گذاران بیشتر بر روی سهام با فضای توسعه تمرکز می کنند و بر اساس احساسات کلی بازار برنامه ریزی می کنند. در تحقیقات آینده، به جز بهبود دقت پیش بینی، یک روش تشخیص برای رویدادهای مهم سهام باید مورد مطالعه قرار گیرد. در عین حال، استراتژی های سرمایه گذاری مناسب باید با تحقیق پیش بینی فعلی ترکیب شوند تا بتوانند به بازار سهام واقعی اعمال شوند.

¹ logistic regression algorithm² accurate sentiment extractor³ best polarity classification results⁴ logistic regression⁵ Principal component analysis

یک مطالعه دیگر (مهلا نیکو و همکاران [13]) به دنبال ارزیابی قدرت پیش بینی مدل های یادگیری ماشین در بازار سهام است. داده های مورد استفاده در این مطالعه شامل اطلاعات قیمت نزدیک روزانه سهام بریتانیا^۱ از ژانویه ۲۰۱۵ تا ژوئن ۲۰۱۸ است. فرایند پیش بینی از طریق چهار مدل الگوریتم های یادگیری ماشین انجام می شود. نتایج نشان می دهد که روش یادگیری عمیق در پیش بینی بهتر از سایر روش ها است و روش رگرسیون بردار پشتیبانی در رتبه بعدی با توجه به شبکه عصبی و روش های جنگل تصادفی با خطای کمتر است. مهمترین مزایای یادگیری عمیق، یادگیری خودکار از ویژگی ها، یادگیری چند لایه از ویژگی ها، دقت بالا در نتایج، قدرت کلی بالا و شناسایی داده های جدید است. بنابراین، هدف از این مطالعه پیش بینی قیمت نزدیک سهام انگلستان از طریق این روش و مقایسه قدرت پیش بینی آن با سایر روش های یادگیری ماشین است. یکی از عوامل اصلی که توسط سرمایه گذاران در سرمایه گذاری و خرید سهام و فروش سهام در نظر گرفته شده، شاخص قیمت سهام است. برای این منظور، چهار تکنیک داده کاوی، شبکه عصبی مصنوعی، حافظه طولانی کوتاه مدت، جنگل تصادفی و رگرسیون بردار پشتیبانی با استفاده از کدگذاری در پایتون اجرا شد و عملکرد آنها با قیمت نزدیک روزانه بریتانیا مقایسه شد. این تجزیه و تحلیل و خلاصه نتایج به دست آمده به شرح زیر است. نتایج مطالعه نشان می دهد که روش شبکه بازگشتی با یک بلوک حافظه طولانی کوتاه مدت در پیش بینی قیمت نزدیک سهام بریتانیا بهتر از سایر روش ها است و سپس روش رگرسیون بردار پشتیبانی دقت بیشتری نسبت به شبکه عصبی و جنگل تصادفی دارد. در حالت کلی توصیه های زیر را می توان انجام داد: ۱. برای پیش بینی قیمت نزدیک سهام بریتانیا، روش یادگیری عمیق بهتر از روش های دیگر تست شده است؛ بنابراین، سرمایه گذاران، مدیران و تحلیلگران بازار توصیه می شود از این روش استفاده کنند. از سوی دیگر، پیش بینی مناسب شاخص های قیمت می تواند تأثیر قابل توجهی بر سودآوری داشته باشد و تصمیمات مناسب در مورد مجموعه سرمایه گذاران و ذینفعان داشته باشد. نتایج این مطالعه می تواند به شرکت های سرمایه گذاری و سایر کاربران در ارزیابی سودآوری در فروش و خرید سهام کمک کند. ۲. به محققان توصیه می شود از مدل های ترکیبی مانند مدل رگرسیون بردار پشتیبانی ترکیبی با الگوریتم ژنتیکی و سایر مدل های ترکیبی از الگوریتم های یادگیری ماشین استفاده کنند. علاوه بر این، برای تحقیقات بیشتر، توصیه می شود برای بررسی انواع مختلف مدل های حافظه طولانی کوتاه مدت، مانند حافظه طولانی کوتاه مدت پشته ای، حافظه طولانی کوتاه مدت رمزگذار-رمزگشا، حافظه طولانی کوتاه مدت دوطرفه، حافظه طولانی کوتاه مدت با شبکه عصبی پیچشی و مدل های حافظه طولانی کوتاه مدت مولد در پیش بینی قیمت سهام توصیه شود. در نهایت، با توجه به استفاده از داده های سری زمانی در این مطالعه، نقش سایر عوامل موثر بر پیش بینی قیمت سهام مورد بررسی قرار نگرفت. بنابراین، به محققان توصیه می شود که نقش عوامل دیگر در مطالعات آینده را در نظر بگیرند و نتایج حاصل از نتایج این مطالعه را مقایسه کنند.

¹ ISHARES MSCI

یک پژوهش دیگر (دنگ لین مینج و همکاران [18]) یک چارچوب جدید برای پیش بینی جهت قیمت های سهام را با استفاده از هر دو اخبار مالی و فرهنگ لغت احساسات ارائه می دهد. مشارکت های اصلی این پژوهش عبارتند از پیشنهاد یک شبکه جدید واحد بازگشتی گیتی دو جهته و Stock2Vec که تعبیه کلمه احساسی است که بر روی مجموعه داده اخبار مالی و هاروارد-IV آموزش دیده است. دو آزمایش اصلی انجام می شود: آزمایش اول جهت های قیمت سهام شاخص S&P ۵۰۰ را با استفاده از قیمت های تاریخی S&P ۵۰۰ و مقالات اخذ شده از رویترز و بلومبرگ پیش بینی می کند، و آزمایش دوم روند قیمت شاخص VN را با استفاده از اخبار VietStock و قیمت سهام از Acophieu^۱ پیش بینی می کند. نتایج نشان می دهد که واحد بازگشتی گیتی دو جریانی از مدل های پیشرفته بهتر عمل می کند Stock2Vec در برخورد با مجموعه داده های مالی کارآمدتر است. و با استفاده از مدل، یک سناریوی شبیه سازی ثابت می کند که مدل آنها برای بخش سهام موثر است. بنابراین بر اساس تحلیل ها و ارزیابی های فوق، آنها یک رویکرد جدید برای پیش بینی جهت های روزانه قیمت سهام با تحلیل مقالات اخبار مالی و قیمت های تاریخی سهام با استفاده از رویکرد یادگیری عمیق پیشنهاد می کنند. مشارکت های اصلی شامل چهار جنبه است، پیشنهاد یک واحد بازگشتی گیتی دو جریانی برای پیش بینی روند قیمت سهام، پیشنهاد یک مدل تعبیه احساسات Stock2Vec که هم در اخبار سهام و هم فرهنگ لغت احساسات آموزش دیده است و اعمال سه شاخص فنی به عنوان یک مجموعه ویژگی اضافی برای پیش بینی روند قیمت سهام و تجزیه و تحلیل کامل اینکه آیا اخبار بلافاصله یا پس از یک دوره کوتاه (۲ روز، یک هفته) بر قیمت سهام تأثیر می گذارد. آنها چندین آزمایش انجام می دهند تا نشان دهند مدل واحد بازگشتی گیتی دو جریانی در مقایسه با روش های پیشرفته چقدر خوب عمل می کند. این مطالعه شامل دو مجموعه داده مختلف است، اخبار مالی روزانه از رویترز و بلومبرگ از اکتبر ۲۰۰۶ تا نوامبر ۲۰۱۳، به ترتیب ۱۰۶۵۲۱ و ۴۴۷۱۴۵ پژوهش خبری از هر منبع، قیمت روزانه سهام S&P ۵۰۰ در همان دوره از دارایی یاهو دانلود می شود. عملکرد سیستم با محاسبه ماتریس سردرگمی^۱ ارزیابی می شود. پس از به دست آوردن مقدار در ماتریس سردرگمی، از دقت، فراخوانی و درستی برای ارزیابی عملکرد سیستم استفاده می شود. پیاده سازی بر روی جعبه ابزار NVIDIA DIGITS با کرا با استفاده از پایتون انجام شده است. این مدل در ۳۰ دوره آموزش داده شد و میانگین زمان تمرین برای هر دوره ۶۴ دقیقه بود. یک ماشین لینوکس با اوبونتو ۱۴.۰۴ برای کل فرآیند استفاده شد.

در عصر داده های بزرگ، یادگیری عمیق برای پیش بینی قیمت ها و روندهای بازار سهام حتی بیش از گذشته محبوب شده است. جینگ یی شن و همکاران [22] داده های ۲ ساله را از بازار سهام چین جمع آوری کردند و سفارشی سازی جامعی از مهندسی ویژگی و مدل مبتنی بر یادگیری عمیق را برای پیش بینی روند قیمت بازارهای سهام پیشنهاد کردند. راه حل پیشنهادی جامع است زیرا شامل پیش پردازش مجموعه داده های بازار سهام، استفاده از تکنیک های مهندسی چندگانه، همراه با یک سیستم مبتنی بر یادگیری عمیق سفارشی برای پیش بینی روند قیمت بازار سهام است.

¹ confusion matrix

آنها ارزیابی های جامعی را بر روی مدل های یادگیری ماشینی پرکاربرد انجام دادند و به این نتیجه رسیدند که راه حل پیشنهادی آنها به دلیل مهندسی ویژگی جامعی که ساخته اند، بهتر عمل می کند. این سیستم به طور کلی به دقت بالایی برای پیش بینی روند بازار سهام دست می یابد. با طراحی دقیق و ارزیابی طول مدت پیش بینی، مهندسی ویژگی، و روش های پیش پردازش داده، این کار به جامعه تحقیقاتی تحلیل سهام در حوزه مالی و فنی کمک می کند. همچنین آنها مجموعه داده را از منبع داده به عنوان یک API داده منبع باز به نام Tushare ساخته اند. تازگی راه حل پیشنهادی آنها این است که به جای مدل حافظه طولانی کوتاه مدت، یک مهندسی ویژگی همراه با یک سیستم تنظیم دقیق را پیشنهاد کردند. آنها از کارهای قبلی مشاهده می کنند و شکاف ها را پیدا می کنند و قبل از آموزش مدل پیش بینی، یک معماری راه حل با روش مهندسی ویژگی جامع پیشنهاد می کنند. با موفقیت روش توسعه ویژگی در همکاری با الگوریتم های حذف ویژگی بازگشتی، درها را برای بسیاری از الگوریتم های یادگیری ماشین دیگر برای دستیابی به امتیازات دقت بالا برای پیش بینی روند قیمت کوتاه مدت باز می کنند. این کارایی پسوند ویژگی پیشنهادی آنها را به عنوان مهندسی ویژگی ثابت کرد. آنها مدل حافظه طولانی کوتاه مدت سفارشی خود را بیشتر معرفی کردند و نمرات پیش بینی را در تمام معیارهای ارزیابی بهبود دادند. راه حل پیشنهادی از یادگیری ماشینی و مدل های مبتنی بر یادگیری عمیق در کارهای قبلی مشابه بهتر عمل کرد. به طور کلی تر این کار از سه بخش تشکیل شده است: استخراج داده ها و پیش پردازش مجموعه داده های بازار سهام چین، انجام مهندسی ویژگی، و مدل پیش بینی روند قیمت سهام بر اساس حافظه طولانی کوتاه مدت. آنها داده های ۲ ساله بازار سهام چین را جمع آوری، پاکسازی و ساختار بندی و تکنیک های مختلفی را که اغلب توسط سرمایه گذاران دنیای واقعی استفاده می شود، بررسی کردند، یک مؤلفه الگوریتم جدید ایجاد و آن را به عنوان پسوند ویژگی نامیدند، که ثابت شده است مؤثر است. آنها رویکردهای گسترش ویژگی را با حذف ویژگی به صورت بازگشتی و به دنبال آن تجزیه و تحلیل مؤلفه اصلی برای ساخت یک روش مهندسی ویژگی که هم مؤثر و هم کارآمد است، به کار بردند. این سیستم با مونتاژ روش مهندسی ویژگی با یک مدل پیش بینی حافظه طولانی کوتاه مدت سفارشی می شود، که دقت پیش بینی بالایی را به دست آورده است که از مدل های پیشرو در بیشتر کارهای مرتبط بهتر عمل می کند. آنها همچنین ارزیابی جامعی از این کار انجام دادند. با مقایسه پرکاربردترین مدل های یادگیری ماشین با مدل حافظه طولانی کوتاه مدت پیشنهادی آنها در بخش مهندسی ویژگی سیستم پیشنهادی شان، به بسیاری از یافته های اکتشافی که می توانند سؤالات تحقیقاتی آینده در حوزه های تحقیقات فنی و مالی باشند، نتیجه می گیرند.

در پژوهشی دیگر (سوبو راعو پولامری و همکاران [20]) با یادگیری تقویتی و بهینه سازی بیزی^۱ بر این مشکل غلبه میشود. یک چارچوب یادگیری عمیق مبتنی بر شبکه های مولد متخاصم، به نام Stock-GAN، با مولد و تفکیک کننده پیاده سازی شده است. شبکه عصبی حافظه طولانی کوتاه مدت و شبکه عصبی پیچشی به عنوان مدل های مولد و تفکیک کننده استفاده می شوند. شبکه مولد تخصصی ویژگی های انتخابی را از متد پیش پردازش جدید دریافت می کند.

¹ reinforcement learning and Bayesian optimization

نتایج به منظور تنظیم فرآیندهای هر دو مدل در StockGAN تحت یادگیری تقویتی و بهینه سازی بیزی قرار می گیرند. برای تقریب سهام از مدل خطی مانند میانگین متحرک خودهمبسته یکپارچه استفاده می شود. رمزگذارهای خودکار برای استخراج ویژگی ها از داده ها استفاده می شوند. XGBoost برای دانستن اهمیت ویژگی ها به منظور فیلتر کردن ویژگی هایی که به تابع هدف پیش بینی کمک نمی کنند استفاده می شود. الگوریتمی به نام شبکه مولد متخاصم مبتنی بر الگوریتم پیش بینی ترکیبی^۱ پیشنهاد شده است. استخراج ویژگی از مجموعه داده ها با استفاده از پردازش زبان طبیعی، نقشه های خودسازماندهی، میانگین متحرک خودهمبسته یکپارچه، پورتفولیوهای خاص و تبدیل فوریه انجام می شود. حذف نویز بیشتر از ویژگی ها با کمک رمزگذارهای خودکار پشته ای انجام می شود. پیش بینی اهمیت ویژگی و کاهش ابعاد با استفاده از تحلیل مؤلفه اصلی و XGB انجام می شود. از Apache MXNet API و پلتفرم علم داده پایتون برای پیاده سازی Stock-GAN استفاده می شود. پس از آن، الگوریتم پیش بینی ترکیبی چند مدلی^۲ و شبکه مولد تخصصی با هم ترکیب شدند تا مدل هیبریدی دیگری^۳ را تشکیل دهند. مطالعه تجربی نشان داد که Stock-GAN عملکرد امیدوارکننده ای را در پیش بینی قیمت سهام در مقایسه با متدهای پیشرفته از نظر پیش بینی قیمت سهام، خطای مطلق میانگین، خطای مربع میانگین و ضریب همبستگی به دست می آورد. الگوریتم، الگوریتم پیش بینی ترکیبی مبتنی بر شبکه مولد تخصصی پیشنهادی در پیش بینی قیمت سهام از مدل، الگوریتم پیش بینی ترکیبی چند مدلی موجود بهتر عمل می کند. اما مدل ترکیبی نهایی بهبود الگوریتم پیش بینی ترکیبی مبتنی بر شبکه مولد تخصصی را نشان داد. در آینده، آنها قصد دارند Stock-GAN را بیشتر تقویت کنند تا با اشکال متنوع داده های سهام مقابله کنند. جهت دیگر برای کار آینده، کشف روابط علی پنهان در داده های بازار سهام است.

۲-۴- بهبود شبکه های عصبی براساس روش های هیوریستیک برای پیش بینی قیمت سهام

در این بخش پژوهش هایی مورد بررسی قرار میگیرند که به پیش بینی قیمت های سهام شرکت های مختلف از سراسر دنیا با استفاده از روش های متنی بر هیوریستیک پرداخته اند.

به منظور بهبود اثر پیش بینی قیمت سهام، بر اساس الگوریتم بهبود یافته بهینه سازی ازدحام ذرات، این پژوهش (فووی یانگ و همکاران [4]) یک مدل پیش بینی قیمت سهام از طریق شبکه عصبی ایجاد می کند و تجزیه و تحلیل تجربی را از طریق این مدل انجام می دهد تا دقت پیش بینی قیمت سهام را بهبود بخشد. بر اساس این ایده که تا حد امکان از ریزش ذرات در یک راه حل محلی یکسان اجتناب و گوناگونی ذرات حفظ شود و به منظور توانایی جستجوی سراسری الگوریتم در مراحل اولیه تکامل و توانایی جستجوی محلی در مرحله آخر تکامل، تنظیم تطبیقی وزن اینرسی

¹ Generative Adversarial Network based Hybrid Prediction Algorithm

² Multi-Model based Hybrid Prediction Algorithm

³ Multi-Model Generative Adversarial Network based Hybrid Prediction Algorithm

پیشنهاد شده است و الگوریتم با ترکیب با شبکه عصبی بهبود می‌یابد. علاوه بر این، این پژوهش بر اساس الگوریتم بهبودیافته، یک سیستم پیش‌بینی قیمت سهام را بر اساس شبکه عصبی ایجاد می‌کند. در نهایت، این پژوهش آزمایش‌هایی را برای تأیید عملکرد مدل از منظر جمع‌آوری و پردازش داده‌های سهام و صحت پیش‌بینی قیمت سهام و رسم نمودارهای آماری بر اساس نتایج تحقیقات آماری طراحی می‌کند. نتایج تحقیق نشان می‌دهد که سیستم ساخته شده در این پژوهش اثر عملی خاصی دارد. این پروژه بر اساس معماری B/S است و از فریم ورک Django و حالت MTV برای توسعه سیستم استفاده می‌کند. جنگو یک وب فریم پایتون سطح بالا است که ساخت وب سایت سریع و ایمن را امکان پذیر می‌کند. جنگو توسط متخصصان باتجربه توسعه داده شده است، بنابراین به آنها کمک می‌کند تا بر روی ایجاد نرم افزار بدون نیاز به اختراع مجدد چرخ تمرکز کنند. این پژوهش بر اساس موتور جستجوی عمودی و فناوری تجزیه و تحلیل گرایش متن، داده‌های مرتبط را در اینترنت جمع‌آوری و پردازش می‌کند و داده‌های از پیش پردازش شده را طبقه‌بندی و تجزیه و تحلیل می‌کند. علاوه بر این، این پژوهش تکنیک‌های یادگیری ماشین و یادگیری عمیق را در زمینه‌های پیش‌بینی سهام و توصیه سهام اعمال می‌کند. علاوه بر این، این پژوهش یک مدل پیش‌بینی قیمت سهام از شبکه عصبی بازگشتی بهبودیافته و بهینه‌شده مبتنی بر بهینه سازی ازدحام ذرات برای تأیید عملکرد مدل می‌سازد. این پژوهش عمدتاً شبکه عصبی بازگشتی را برای پردازش داده های پیش بینی قیمت سهام ترکیب می‌کند و نتایج پیش بینی قیمت مربوطه را به دست می‌آورد. نتایج تحقیقات تجربی نشان می‌دهد که سیستم ساخته شده در این پژوهش عملکرد خوبی در پیش بینی قیمت سهام دارد.

۲-۵- روش های مبتنی بر یادگیری تقویتی برای پیش بینی قیمت سهام

در این بخش پژوهش‌هایی مورد بررسی قرار می‌گیرند که به پیش بینی قیمت های سهام شرکت های مختلف از سرار دنیا با استفاده از روش های متنی بر یادگیری تقویتی پرداخته اند.

در پژوهشی هونگ فنگ هو و همکاران [10] یک شبکه جدید پیش‌بینی حرکت قیمت سهام را از طریق شبکه واحد بازگشتی دروازه‌ای دوطرفه مبتنی بر یادگیری تقویتی با مکانیزم توجه ترکیبی ایجاد می‌کنند. به طور خاص، برای کاهش نویز متون خبری و یادگیری بازنمایی سطح خبر با معنایی فراوان‌تر، ابتدا دو مکانیسم توجه جدید به ترتیب مبتنی بر عملیات اضافه و نقطه در این کار ارائه شد. سپس یک ساختار جدید طراحی می‌کنند تا برخی از بازنمایی‌های سطح خبری نامرتبط (به عنوان مثال، نویزهای سطح اخبار) را فیلتر کرده و وابستگی‌های طولانی مدت فراوان را به تصویر بکشند. در نهایت، نتایج تجربی نشان می‌دهد که مدل پیشنهادی بسیار بهتر از پیشرفت‌های اخیر عمل می‌کند و به عملکردهای هنری دست می‌یابد. طبق طبقه بندی Tencent Finance، آنها ۱۲ صنعت نماینده را برای جمع آوری بیش از ۲۰۰ سهام انتخاب می‌کنند که عبارتند از: موتور، بانک، پتروشیمی، بهداشت، لجستیک، لوازم خانگی، نرم افزار، اینترنت، ارتباطات، شراب، بیمه، املاک. سهام با ارزش بازار بالا معمولاً بیشتر در وب سایت های مالی چین گزارش می‌شود. بنابراین، آنها حرکات

سه ساله قیمت را از ۲۰۱۶/۰۱/۰۱ تا ۲۰۱۹/۰۶/۰۱ از ۲۴۰ سهام چینی به هدف انتخاب می کنند، که از ۲۰ سهم برتر در اندازه سرمایه در هر یک از ۱۲ صنعت بالا آمده است. در این کار، پروتکل ارزیابی را از ادبیات قبلی اتخاذ می کنند که شامل دقت و ضریب همبستگی متیوز^۱ برای ارزیابی مدل پیشنهادی است. به طور خاص، ضریب همبستگی از سوگیری ناشی از انحراف داده ها جلوگیری می کند. به طور خلاصه، مشارکت های اصلی این پژوهش به شرح زیر است. ۱. با توجه به ویژگی های متون خبری پیش بینی سهام چینی، آنها پیشنهاد دو مکانیزم توجه جدید به ترتیب بر اساس عملیات افزودن و نقطه، که ترکیبی از تعبیه معنایی سطح محلی و متنی های جهانی را به طور مشترک نشان می دهد که نمایش سطح اخبار را به طور مشترک یاد می دهد. این دو استراتژی توجه می تواند به طور موثر باعث کاهش نویزهای سطح کاراکتر در نمایش های سطح اخبار آموخته شده و بهبود عملکرد مدل شود. ۲. برای کاهش صداهای سطح اخبار در نمایش های سطح روز، آنها یک چارچوب واحد بازگشتی گیتی جدید را بر اساس یادگیری تقویتی طراحی می کنند. این چارچوب می تواند به طور خودکار نویزهای سطح اخبار را در ساخت و ساز نمایش روزانه با قابلیت تفسیر و جذب وابستگی های طولانی مدت فراوان تر فیلتر کند. در واقع، متد طراحی شده، نوآوری اصلی کار است که در فرایند ساخت مدل دقیق است. ۳. با الهام از دو ایده فوق، آنها یک شبکه پیش بینی حرکت قیمت سهام سطح پایین^۲ از طریق شبکه های دو طرفه واحد بازگشتی گیتی بر اساس یادگیری تقویتی که با مکانیزم های توجه گنجانده شده است پیشنهاد می کنند. نتایج تجربی نشان می دهد که این رویکرد می تواند نویزهای سطح کاراکتر و سطح خبر را کاهش دهد که در مقایسه با پیشرفت های اخیر، عملکردهای پیشرفته تری را به دست می آورد. در واقع، در این کار، متد پیشنهادی عمدتاً بر فیلتر کردن نویز در سطح اخبار با استفاده از مکانیسم انتخاب کنش در شبکه واحد بازگشتی گیتی بر اساس یادگیری تقویتی تمرکز می کند و باعث می شود که مدل دارای قابلیت تفسیر صریح در مازول سطح روز باشد. با این حال، به عنوان محدودیت کار آنها، این رویکرد مبتنی بر ساختارهای سلسله مراتبی برای ایجاد پیوند صریح بین حرکت قیمت سهام و رویداد خاص در یک روز معاملاتی خاص بسیار سخت است و از دید کل مدل فاقد قابلیت تفسیر واضح تر است. بنابراین، در آینده قصد دارند رویدادهای مالی را در اخبار استخراج کنند و با استفاده از ابزار پردازش زبان های طبیعی بالغ، روابط بین رویدادها ایجاد کنند. علاوه بر این، با استفاده از شبکه عصبی گراف^۳ و با در نظر گرفتن پیش بینی دامنه شرطی، آنها نمودار رابطه رویداد را بر اساس اطلاعات انتساب چندوجهی (به عنوان مثال، زمان، مکان، قیمت فعلی سهام) می سازند تا مستقیماً رویدادها را به حرکت سهام در مشاهده کل بازه تاخیر زمانی مرتبط کنند و ساختارهای سلسله مراتبی را حذف کنند. در نتیجه، مدل پیش بینی حرکت قیمت سهام می تواند قابل تفسیرتر و معقول تر باشد.

¹ Matthews correlation coefficient

² stock price movement prediction network SPMPN

³ graph neural network

۲-۶- روش های مبتنی بر یادگیری ماشین برای پیش بینی قیمت سهام

در این بخش پژوهش هایی مورد بررسی قرار میگیرند که به پیش بینی قیمت های سهام شرکت های مختلف از سراسر دنیا با استفاده از روش های متنی بر یادگیری ماشین پرداخته اند.

در یک پژوهش (شیانگ هوی یان و همکاران [19])، ویژگی ها توسط الگوریتم های مختلف انتخاب ویژگی انتخاب می شوند و پارامترهای مدل های پیش بینی روند قیمت سهام مبتنی بر یادگیری ماشین از طریق اعتبارسنجی متقاطع پنجره ای لغزشی^۱ بر اساس داده های ۸ ساله بازار سهام A چین تنظیم می شوند. از طریق تجزیه و تحلیل مدل های مختلف یکپارچه، مدل زمانی بهترین عملکرد را دارد که الگوریتم جنگل تصادفی هم برای انتخاب ویژگی و هم برای پیش بینی روند قیمت سهام استفاده میشود. بر اساس الگوریتم جنگل تصادفی، یک پورتفولیوی بلند-کوتاه برای اعتبارسنجی اثربخشی بهترین مدل ساخته شده است. در این پژوهش، آنها بر پیش بینی روند بلندمدت قیمت سهام تمرکز می کنند تا یک مدل انتخاب بلندمدت سهام بهتر بسازند. مدل های کلاسیک پرکاربرد برای پیش بینی روند بلندمدت قیمت سهام، مدل معروف قیمت گذاری دارایی سرمایه^۲ و نظریه قیمت گذاری آربیتراژ^۳ هستند. داده های این پژوهش از تمام سهام بازار A-سهام چین است و کار پیش بینی روند سهام فردی است. با توجه به اینکه سهام ویژه و سهام جدید فرعی با زمان کوتاه تر برای ورود به بازار ریسک بیشتری برای فعالیت دارند، سهام ویژه ST و سهام با کمتر از ۳ ماه مستثنی می شوند. مجموعه داده ها از ۱ ژانویه ۲۰۱۰ تا ۱ ژانویه ۲۰۱۸ است. در آخرین روز معاملاتی هر ماه، مجموعه داده ها شامل ویژگی ها و بازده اضافی سهام را جمع آوری می کند. علاوه بر این، روش پنجره کشویی برای تقسیم داده ها به مجموعه های آموزشی و مجموعه های آزمایشی استفاده می شود. این داده های تجربی همگی از پایگاه داده Wind به دست آمده اند. این پژوهش بر روی مدل انتخاب سهام چند ویژگی مبتنی بر الگوریتم های انتخاب ویژگی مختلف و الگوریتم های پیش بینی روند قیمت سهام مبتنی بر یادگیری ماشین برای بازار سهام چین تمرکز می کند و رابطه غیرخطی بین عوامل و بازده سهام را ایجاد می کند. جهت توسعه مدل چند عاملی کلاسیک را گسترش می دهد و یک استراتژی سرمایه گذاری جدید برای سرمایه گذاران در بازار سهام چین ارائه می کند. در کار آنها، ۶۰ ویژگی برای استفاده به عنوان ورودی مدل، از طریق گزارش مالی، قیمت های افتتاحیه روزانه، قیمت های بسته شدن، حجم ها و سایر داده های بازار A-سهام به دست آمده است. سهم اصلی این تحقیق در نکات زیر منعکس شده است. ابتدا، الگوریتم انتخاب ویژگی برای فیلتر کردن ویژگی ها استفاده می شود که می تواند پیچیدگی مدل را کاهش دهد و از فاجعه ابعادی ناشی از ویژگی های بیش از حد جلوگیری کند. دوم، با توجه به مشکل تجزیه و تحلیل داده های سری زمانی با استفاده از روش اعتبارسنجی متقاطع اصلی، روش

^۱ time-sliding window cross-validation

^۲ Capital Asset Pricing Model

^۳ Arbitrage Pricing Theory

اعتبارسنجی متقاطع پنجره کشویی برای ایجاد مدل مناسب تر برای وضعیت واقعی اتخاذ می شود. سوم، الگوریتم پیش بینی روند قیمت سهام برای پیش بینی بازده مازاد سهام در ماه بعد اعمال می شود.

در یک پژوهش هدف پیش بینی جهت قیمت سهام ایالات متحده با ادغام آنتروپی انتقال موثر متغیر با زمان¹ و الگوریتم های مختلف یادگیری ماشین است. سوندو کیم و همکاران [21] در ابتدا، بررسی می کنند که آنتروپی انتقال موثر بر اساس پنجره های متحرک ۳ و ۶ ماهه می تواند به عنوان متغیر توضیحی بازار با تجزیه و تحلیل ارتباط بین بحران های مالی و روابط Granger-causal در بین سهام در نظر گرفته شود. سپس، متوجه می شوند که عملکرد پیش بینی در جهت قیمت سهام زمانی بهبود می یابد که متغیر مبتنی بر آنتروپی انتقال موثر به عنوان یک ویژگی جدید در رگرسیون لجستیک، پرسپترون چندلایه، جنگل تصادفی، XGBoost و شبکه حافظه طولانی کوتاه مدت ادغام شود. در همین حال، آنها پیشنهاد می کنند از دقت تعدیل شده به دست آمده از بازده تعدیل شده با ریسک در امور مالی به عنوان معیار عملکرد پیش بینی استفاده شود. در نهایت، آنها تایید می کنند که شبکه پرسپترون چندلایه و حافظه طولانی کوتاه مدت برای پیش بینی قیمت سهام مناسب تر هستند. این مطالعه اولین تلاش برای پیش بینی جهت قیمت سهام با استفاده از آنتروپی انتقال موثر است که می تواند به راحتی در زمینه عملی اعمال شود. تازگی این پژوهش در این واقعیت نهفته است که، در بهترین دانش آنها، این اولین تلاش برای ادغام آنتروپی انتقال موثر یک سهام ایالات متحده برای تجزیه و تحلیل بازار ایالات متحده و پیش بینی جهت قیمت سهام است. با مقایسه عملکرد مجموعه ها با و بدون متغیر آنتروپی انتقال موثر، آنها قابلیت استفاده آنتروپی انتقال موثر را در پیش بینی قیمت سهام تایید می کنند. توجه داشته باشید که آنها از رگرسیون لجستیک به عنوان یک مدل پیش بینی خطی، پرسپترون چندلایه به عنوان یک شبکه عصبی پس انتشار، جنگل تصادفی به عنوان یک روش مجموعه ای از نوع کیسه ای، XGBoost به عنوان یک تقویت کننده نوع روش مجموعه و شبکه حافظه طولانی کوتاه مدت به عنوان یک الگوریتم یادگیری عمیق استفاده می کنند. یافته های این پژوهش را می توان به شرح زیر خلاصه کرد. در ابتدا، متوجه شدند که آنتروپی انتقال موثر متغیر با زمان مبتنی بر پنجره های متحرک ۳ و ۶ ماهه با استفاده از ۵۵ سهام از ۱۱ بخش و شش مورد بحران مالی در بازار مالی ایالات متحده، قدرت توضیحی بازار دارد. ثانیاً، آنها افزایش نفوذ بخش های مرتبط با بحران مالی و اندازه مطلق جریان اطلاعات در بازار را تشخیص می دهند. ثالثاً، استفاده از شاخص های شبکه آنتروپی انتقال موثر به عنوان ویژگی های جدید، پیش بینی جهت قیمت سهام را برای همه موارد رگرسیون لجستیک، پرسپترون چندلایه، جنگل تصادفی، XGB و حافظه طولانی کوتاه مدت بهبود می بخشد. به طور خاص، هر چه تاخیر برای پیش بینی کمتر باشد، دوره پیش بینی طولانی تر است، دقت پیش بینی بالاتر است. چهارم، آنها الگوریتم های شبکه عصبی پرسپترون چندلایه و حافظه طولانی کوتاه مدت را به عنوان الگوریتم های یادگیری ماشینی مناسب تر در پیش بینی جهت قیمت سهام بر اساس دقت تعدیل شده، معیار عملکرد جدید معرفی شده بر اساس مفهوم بازده تعدیل شده با ریسک، شناسایی می کنند. در نهایت، بخش های مناسب برای استفاده از شاخص های شبکه آنتروپی انتقال موثر را نشان می دهند.

¹ Integrating time-varying effective transfer entropy

محدودیت این تحقیق که باید در مطالعات آینده به آن پرداخته شود، زمان محاسبه برای به دست آوردن آنتروپی انتقال موثر با زمان متغیر است. به خصوص، بهینه سازی الگوریتم محاسباتی آنتروپی انتقال موثر برای اعمال مکانیزم برای همه سهام در S&P ۵۰۰ به طور گسترده ضروری است. همچنین، به عنوان یک کار پیگیری، در حال برنامه ریزی برای پیشنهاد و آزمایش استراتژی های سرمایه گذاری پرتفوی با استفاده از نتایج پیش بینی و مدل بلک لیترمن هستند.

یک پژوهشی دیگر (شیلی چن و همکاران [24]) استفاده از الگوریتم ژنتیک را برای انتخاب ویژگی و توسعه یک مدل پیش بینی سهام شبکه عصبی بهینه شده ی حافظه طولانی کوتاه مدت پیشنهاد می کند. در مرحله اول، آنها از الگوریتم ژنتیک برای به دست آوردن رتبه بندی اهمیت عوامل استفاده می کنند. سپس ترکیب بهینه عوامل از این رتبه بندی با روش آزمون و خطا به دست می آید. در نهایت از ترکیب عوامل بهینه و مدل حافظه طولانی کوتاه مدت برای پیش بینی سهام استفاده می کنند. مطالعات تجربی کامل بر اساس مجموعه داده بانک ساخت و ساز چین و مجموعه داده سهام CSI ۳۰۰ نشان می دهد که مدل ترکیبی ژنتیک با حافظه طولانی کوتاه مدت می تواند از همه مدل های پایه برای پیش بینی سری های زمانی بهتر عمل کند. برای پیش بینی زمان بندی مالی چند متغیره، انتخاب ویژگی مؤثر بسیار مهم است. انتخاب ویژگی ها مزایای زیادی دارد، مانند زمان آموزش مدل را کاهش می دهد. به ساده سازی پیچیدگی پیش بینی کنندگان کمک می کند. دقت مدل را بهبود می بخشد. همچنین با حذف متغیرهای غیر ضروری از مجموعه ویژگی ها از برازش بیش از حد جلوگیری می کند. الگوریتم ژنتیک تأثیر خوبی در کاربرد مسئله انتخاب ویژگی دارد. استفاده از الگوریتم ژنتیک مبتنی بر جمعیت می تواند به طور موثر مشکلات نویز و هم خطی را حل کند. بنابراین، این پژوهش استفاده از ژنتیک را برای انتخاب ویژگی عوامل متعدد پیشنهاد می کند و آن را برای مدل پیش بینی سهام شبکه عصبی حافظه طولانی کوتاه مدت اعمال می کند. از طریق مقایسه تجربی، این روش به نتایج قابل توجهی در بهبود دقت پیش بینی سهام دست یافت.

با توجه به بازار مالی چین، این پژوهش ترکیب عامل اصلی متشکل از ۴۰ عامل سهام شامل عوامل بازار، عوامل فنی و عوامل مالی را تعیین می کند. در این پژوهش، ۲۴۹۰ قطعه داده تاریخی بانک ساختمانی چین و سهام CSI ۳۰۰ از اول ژانویه ۲۰۱۰ تا ۱ آوریل ۲۰۲۰ از طریق پلت فرم کمی JoinQuant به دست آمده است. به منظور حذف تأثیر ابعادی بین شاخص ها و تسریع سرعت نزول گرادیان برای یافتن راه حل بهینه، داده ها را نرمال کردند. اگرچه مدل پیش بینی قیمت سهام ارائه شده در این پژوهش می تواند به طور موثری دقت پیش بینی را بهبود بخشد و از استحکام بالایی برخوردار است، اما هنوز برخی از مشکلات به شرح زیر وجود دارد: اولاً، آنها فقط از داده های سهام چین برای آزمایش استفاده می کنند، بنابراین تحقیقات بیشتر می تواند شامل داده هایی از بازارهای سهام مختلف باشد. ثانیاً، در طراحی پارامترهای مدل در این پژوهش، معمولاً آزمون و خطا به جای روش سیستماتیک برای یافتن اندازه بهینه پارامترها مانند انتخاب تعداد فاکتورها اتخاذ می شود. روش بهبود ترکیب با سایر فناوری های یادگیری ماشین برای یافتن پارامترهای بهینه و بهبود تفسیرپذیری

مدل است. علاوه بر این، هنگامی که پارامترهای کنترلی الگوریتم ژنتیک مانند نرخ متقاطع، نرخ جهش و تعداد ترکیبات فاکتور تنظیم می شوند، می توان انواع ترکیبات مناسب را برای بهبود عملکرد تحقیق به دست آورد.

۷-۲- مدل های رگرسیونی برای پیش بینی قیمت سهام

در این بخش پژوهش هایی مورد بررسی قرار می گیرند که به پیش بینی قیمت های سهام شرکت های مختلف از سرار دنیا با استفاده از روش های متنی بر رگرسیون پرداخته اند.

یک مطالعه (برون میراندا هنریک و همکاران [23]) از یک تکنیک یادگیری ماشینی به نام رگرسیون بردار پشتیبان برای پیش بینی قیمت سهام برای سرمایه گذاری های بزرگ و کوچک و در سه بازار مختلف، با استفاده از قیمت ها با فرکانس های روزانه و لحظه ای استفاده می کند. خطاهای پیش بینی اندازه گیری می شوند و مدل با مدل پیاده روی تصادفی پیشنهاد شده توسط فرضیه بازار کارآمد مقایسه می شود. نتایج نشان می دهد که رگرسیون بردار پشتیبان دارای قدرت پیش بینی است، به ویژه زمانی که از استراتژی به روزرسانی مدل به صورت دوره ای استفاده می کند. همچنین نتایج نشان دهنده ای از افزایش دقت پیش بینی در طول دوره های نوسان کمتر وجود دارد. ریشه میانگین مربعات خطا و میانگین درصد مطلق خطا برای ارزیابی کفایت پیش بینی قیمت مدل ها استفاده می شود. این مطالعه سهام برزیل، آمریکایی و چینی را با سه سهام بلو چیپ و سه سهام با سقف کوچک برای هر کشور، در مجموع ۱۸ دارایی در نظر می گیرد. این سهام برای به دست آوردن توزیعی از شرکت ها با اندازه های مختلف در بازارهای مختلف با ماهیت توسعه یافته و در حال توسعه انتخاب شدند. به طور کلی برای تجزیه و تحلیل فرضیه بازار کارآمد، این مطالعه پیش بینی پذیری سهام در برزیل، ایالات متحده و چین را بر اساس تجزیه و تحلیل خطای پیش بینی آزمایش می کند. این مطالعه به دنبال شناسایی استراتژی های معاملاتی نیست که می تواند منجر به سودهای خارق العاده شود، بلکه به دنبال ارزیابی خطاهای پیش بینی با مقایسه یک مدل یادگیری ماشین با یک مدل پایه است که از یک پیاده روی تصادفی پیروی می کند. انتخاب کشورها به دلیل تمایل به ارزیابی نتایج تکنیک های یادگیری ماشین در بازارهای توسعه یافته و در حال توسعه است. با توجه به فراوانی قیمت سهام، داده های روزانه در مطالعات پیش بینی سستی هستند. با این حال، مطالعات دیگر، از داده های به روز استفاده می کنند. مطالعه آنها نتایج را برای قیمت های روزانه و قیمت های لحظه ای نشان می دهد. سهم مهم این مطالعه مقایسه نتایج پیش بینی قیمت مدل های رگرسیون بردار پشتیبان ارائه شده با مدل پیاده روی تصادفی است که بر اساس آن بازارها در بلندمدت غیرقابل پیش بینی هستند. از این نظر، نتایج ارائه شده در اینجا نشان می دهد که برخی از مدل های رگرسیون بردار پشتیبان، با به روزرسانی های دوره ای یا ثابت، ممکن است عملکرد بهتری نسبت به پیش بینی تصادفی داشته باشند، به ویژه با استفاده از هسته خطی. نتیجه دیگری که باعث بررسی بیشتر می شود، نشان دهنده رابطه قوی بین پیش بینی قیمت رگرسیون بردار پشتیبان و نوسانات، با در نظر گرفتن یک پنجره آموزشی متحرک است. مطالعات آینده

ممکن است شامل تعداد بیشتری از سهام و بازارهای آزمایشی غیر از مواردی باشد که در اینجا انتخاب شده اند. سایر مدل های پیش بینی را نیز می توان مقایسه کرد، از جمله طبقه بندی کننده جهت های قیمت دارایی. متغیرهای مستقل ممکن است شامل سایر شاخص های آنتروپی انتقال، پیش بینی کننده های روند یا قیمت های گذشته باشند. علاوه بر این، شاخص های تحلیل بنیادی، مانند اندازه شرکت، نقدینگی، بدهی، سودآوری و معیارهای فعالیت، می تواند گنجانده شود. گنجاندن چنین داده هایی می تواند مکانیسم یادگیری ماشین را بهبود بخشد. همچنین توصیه می شود که سایر دوره های به روزرسانی مدل، به ویژه آنهایی که فرکانس بالاتری نسبت به قیمت های لحظه ای دارند، آزمایش شوند.

۲-۸- جمع بندی

پیش بینی قیمت سهام مشخصه هایی برای سهامداران دارند تا بیشترین سود را کسب کنند و همیشه به دنبال راهکارهای منطقی و دقیق جهت پیش بینی بوده اند. تکنیک های داده علاوه بر جمع آوری و مدیریت، آنالیز و پیش بینی های را نیز شامل می شود که کشف الگوهای موجود و روابط ناشناخته ای میان داده ها را در پیش بینی یاری می رساند. بنابراین در این فصل سعی کردیم پیشینه تحقیق مربوط به روش های پیش بینی قیمت سهام یا روند حرکت آن را که با روش های یادگیری ماشین، یادگیری عمیق، روش های هیوریستیک مانند بهینه سازی ازدحام ذرات، شبکه های عصبی و یا روش های ترکیبی از آنها پیاده سازی شده اند و یا روش های جدیدی که قیمت های کوتاه مدت یا بلند مدت بازار سهام را با دقت و معیارهای ارزیابی بالاتر و بهتری پیش بینی میکنند، به طور خلاصه بپردازیم. همچنین برای هر پژوهش دیتاست مورد استفاده و توضیحی از داده های آن، زبان پیاده سازی آن، نحوه حل مسعله با متد مورد استفاده و مقایسه ی آن با روش های دیگر، معیار های مقایسه و نتایج اراعه شده را بررسی کردیم.

فصل سوم: مواد و روش ها

۳-۱- روش تحقیق

برای پیش بینی قیمت سهام که موضوع مورد مطالعه در این تحقیق می باشد روش تحقیق به این صورت است که از وبسایت ها مقالات و بازارهای مالی که به صورت پیشرفته در این زمینه فعالیت دارند کمک گرفته شده است همچنین از طریق آموزش هایی که در وبسایت هایی مثل مدیوم و یا دیگر وبسایت ها که موضوعات هوش مصنوعی را تدریس می کنند بهره گرفته شده است.

در این پژوهش ابتدا روش های پیشین که قیمت سهام را پیش بینی میکردند و هم چنین مدل های آنها مورد بررسی قرار گرفت در گام بعد با استفاده از روش های کنونی عملیات پیش بینی روی داده های شرکت های خارجی نظیر اپل و مایکروسافت انجام شد. هدف اصلی این بود که پیش بینی روی داده های سهام یک شرکت داخلی مثل ایران خودرو که با سری های کمکی هم برای بهبود دقت پیش بینی ادغام شده بود، صورت گیرد. برای این منظور یک شبکه عصبی که چند سری زمانی را دریافت کرده و بعد از بروز رسانی وزن ها و عبور از لایه های گوناگون، در نهایت یک سری واحد را تولید میکند، طراحی شد. قدم بعدی آموزش داده ها با مدل های مختلفی بود که در حال حاضر بیشترین استفاده و دقت پیش بینی خوبی را داشتند. هم چنین یک پارامتر ورودی به صورت تاریخ در نظر گرفته شده که زمان پیش بینی را مشخص میکند و برنامه میتواند با توجه به آن تاریخ عملیات پیش بینی را روی آن سری واحد انجام دهد. در گام بعدی هدف این است که با بهبود پارامترهای مدل و هم چنین ساختار آن خطای پیش بینی را کاهش داده و در نتیجه دقت بهتری از آن بدست آید. هم چنین پیش بینی رو داده ها به صورت چند متغیره صورت میگیرد بدین منظور به جای پیش بینی یک قیمت، همزمان چندین قیمت از سری واحد مثل قیمت بسته شده سهام، قیمت باز شده، کمترین و بیشترین قیمت در خروجی مشاهده خواهد شد. در نهایت در قدم آخر برای درک و تحلیل و بررسی روند حرکت سهام، نتایج پیش بینی روی داده ها در نمودار ها ترسیم شده و دقت آنها باهم مقایسه می شود. همچنین روش گردآوری اطلاعات شامل مطالعه اسناد و مجلاتی که مقالات معتبری ارائه میدهند، وب سایت هایی که در زمینه های یادگیری ماشین فعالیت دارند و همچنین سایت های داخلی که اخبار و اطلاعات لحظه ای از بازار های مالی منتشر میکنند. کانال های تلگرامی و صفحات افرادی که قیمت ها و اطلاعات مهمی را در میان میگذارند. برای جمع آوری داده ها و هم چنین پیاده سازی از زبان برنامه نویسی پایتون و کتابخانه های مربوطه در این زمینه استفاده شده است. هم چنین از محیط کدنویسی گوگل کولب برای اجرا و ویرایش کدها و پیاده سازی استفاده شده است.

۳-۲- معرفی داده ها

در این بخش داده های مورد استفاده طی روند پیش بینی که شامل جداسازی و پیش پردازش آنها نیز میشود معرفی خواهند شد. جمع آوری داده های بورس برای انجام پیش بینی در ابتدا چالش های زیادی برای ما همراه داشت. پیدا کردن مجموعه داده هایی که شامل اطلاعات درست و همچنین پیوسته تا زمان کنونی باشد، فرمت ستون های فایل مناسب و قابل تبدیل به شکل استاندارد باشد، تمام قیمت های مدنظر برای همه ی بورس ها موجود باشد و همچنین داده های تمام روزها موجود باشد و از بین رفتگی داده در مجموعه نداشته باشیم، که این موارد جز چالش های اصلی هنگام جمع آوری بود. داده ها با استفاده از الگوریتم وب کراولر یا خزش صفحات وب با استفاده از زبان پایتون از وب سایت های بورس و دلار ایران اخذ شده است.

پس از جمع آوری هر کدام از مجموعه داده، داده ها روی نمودارهای سری زمانی تحلیل و اعتبار سنجی روی آنها انجام شده تا همه داده ها ساختاری درست و یکسان داشته باشند، زیرا برخی از وب سایت ها اطلاعات نادرستی از قیمت ها به ویژه قیمت دلار را نمایش می دهند که ما به منظور همین مورد داده های مربوط به دلار را برای بار دوم و سوم جمع آوری و اعتبار سنجی کردیم و چون موضوع مورد تحقیق پیش بینی قیمت سهام شرکت های مختلف بود چالش بعدی برای یافتن داده هایی است که روابطی با یکدیگر داشته باشند که به عنوان مثال با افزایش قیمت دلار، قیمت طلا نیز افزایش یافته و یا قیمت یه سهم دیگر کاهش میابد که انتخاب سهام و داده ی مناسب میتواند در پیش بینی چند متغیره بسیار مفید واقع شود.

۳-۲-۱- الکتریک خودرو شرق (خشرق) - بازار دوم بورس

شرکت الکتریک خودرو شرق یکی از شرکت های تحت پوشش قطعات اتومبیل ایران (یاپکو) و وابسته به گروه صنعتی ایران خودرو می باشد که در حال حاضر محصولات صادراتی این شرکت در خطوط تولید شرکت خودرو سازی PSA (پژو سیتروئن) مورد استفاده قرار می گیرد. شرکت در تاریخ ۱۳۸۲ از سهامی خاص به سهامی عام تبدیل و در بهمن ماه همان سال با پذیرش در بورس اوراق بهادار تهران، وارد بورس شد. همچنین با توجه به وضعیت تولید خودروسازان، این شرکت نیز به تناسب رشد مشتریان خود و در راستای همگام شدن با پیشرفتهای صنعت خودروسازی کشور و تأمین نیازهای آنها، ظرفیتهای خود را افزایش داده است. داده های جمع آوری شده از این شرکت شامل دیتای ۲۰ ساله از سال ۲۰۰۴ تا ۲۰۲۴ بوده که شامل قیمت های باز بسته و کمترین بیشترین اولین و آخرین قیمت میباشد.

1	<TICKER>	<DTYYYYMMDD>	<FIRST>	<HIGH>	<LOW>	<CLOSE>	<VALUE>	<VOL>	<OPENINT>	<PER>	<OPEN>	<LAST>
2	E.Kh.Shargh	20240101	14200.00	14590.00	14110.00	14410.00	36470663160	2530621	603	D	14160.00	14260.00
3	E.Kh.Shargh	20231231	14220.00	14260.00	13950.00	14160.00	18015178460	1272263	249	D	14160.00	14160.00
4	E.Kh.Shargh	20231230	14020.00	14380.00	14000.00	14160.00	15860275400	1120070	254	D	13940.00	14070.00
5	E.Kh.Shargh	20231227	13880.00	14160.00	13630.00	13940.00	15634387050	1121405	291	D	13630.00	14020.00
6	E.Kh.Shargh	20231226	13720.00	13930.00	13330.00	13630.00	27396763080	2010611	319	D	13810.00	13560.00
7	E.Kh.Shargh	20231225	13760.00	14000.00	13710.00	13810.00	18624748870	1348647	304	D	13950.00	13720.00
8	E.Kh.Shargh	20231224	13710.00	14310.00	13710.00	13950.00	29647460250	2124830	286	D	14100.00	13930.00
9	E.Kh.Shargh	20231223	14200.00	14420.00	13800.00	14100.00	18986490710	1346466	324	D	14010.00	13880.00
10	E.Kh.Shargh	20231220	14090.00	14200.00	13880.00	14010.00	19625583300	1400423	399	D	14240.00	13900.00

شکل (۱): نمونه داده های سهام شرکت الکتریک خودرو شرق

۳-۲-۲- توسعه فناوری اطلاعات خوارزمی (مفاخر) - بازار اول فرابورس

شرکت خوارزمی از سال ۱۴۰۱ با یاری خداوند و استفاده از نیروهای توانمند توانسته است در مسیر رشد و تعالی قدم بگذارد و علاوه بر بکارگیری راهکارهای نوین در خدمات پشتیبانی، ارائه سرویس های دانش محور و فرایندهای هوشمند تجاری را در دستور کار خود قرار دهد. شرکت خوارزمی دارای دو شرکت زیرمجموعه بنام های پدیدآوران سخت افزار خوارزمی (پاسخ) به عنوان بازوی تولیدی و تعمیرات تجهیزات و شرکت شبکه گستران خوارزمی به عنوان مجری ارائه دهنده خدمات پسیو شبکه مشتریان است. داده های جمع آوری شده از این شرکت شامل دیتای ۱۰ ساله از سال ۲۰۱۴ تا ۲۰۲۴ بوده که شامل قیمت های باز بسته و کمترین بیشترین اولین و آخرین قیمت میباشد.

1	<TICKER>	<DTYYYYMMDD>	<FIRST>	<HIGH>	<LOW>	<CLOSE>	<VALUE>	<VOL>	<OPENINT>	<PER>	<OPEN>	<LAST>
2	Kharazmi.Info.	20240101	12390.00	13000.00	12340.00	12900.00	126812768750	9828629	1001	D	12150.00	13000.00
3	Kharazmi.Info.	20231231	12450.00	12650.00	11910.00	12150.00	109530982850	9015151	1616	D	12710.00	12160.00
4	Kharazmi.Info.	20231230	12800.00	13110.00	12380.00	12710.00	95125281780	7482826	1321	D	13010.00	12610.00
5	Kharazmi.Info.	20231227	12900.00	13650.00	12710.00	13010.00	98575147970	7574692	1497	D	13260.00	12800.00
6	Kharazmi.Info.	20231226	13770.00	13990.00	12260.00	13260.00	251146418370	18943148	2850	D	13180.00	13020.00
7	Kharazmi.Info.	20231225	12690.00	13300.00	12510.00	13180.00	195092987200	14801351	1945	D	12430.00	13300.00
8	Kharazmi.Info.	20231224	12320.00	12750.00	11710.00	12430.00	157366536510	12661416	2113	D	12020.00	12690.00
9	Kharazmi.Info.	20231223	12090.00	12410.00	11500.00	12020.00	124592624770	10368369	1784	D	11660.00	12320.00
10	Kharazmi.Info.	20231220	11390.00	11820.00	11110.00	11660.00	238012989070	20412633	2520	D	11050.00	11820.00

شکل (۲): نمونه داده های سهام شرکت فناوری خوارزمی

۳-۲-۳- سرمایه گذاری مسکن (ثمسکن) - بازار اول (تابلوی اصلی) بورس

شرکت گروه سرمایه گذاری مسکن یکی از بزرگ ترین و موثرترین فعالان صنعت ساختمان در کشور است. علاوه بر آن در ساخت مجتمع های تجاری، اداری و آموزشی، ساخت آزاد راه، خطوط انتقال آب و آماده سازی زمین فعالیت هایی انجام شده است. گروه سرمایه گذاری مسکن دارای ۱۵ شرکت زیر مجموعه است که در ۲۸ استان و ۳۶ شهر کشور، گسترده شده اند. شرکت در سال ۸۲ با نماد «ثمسکن» وارد بورس تهران شد و طی چند سال اخیر، سهام ۷ زیر مجموعه شرکت نیز در بازار سرمایه ایران پذیرفته شده اند. آخرین سرمایه ثبت شده شرکت ۶۳۰۰ میلیارد ریال است و «شرکت گروه مالی بانک مسکن» سهام دار اصلی شرکت به شمار می آید. داده های جمع آوری شده از این شرکت شامل دیتای ۲۰ ساله از سال ۲۰۰۴ تا ۲۰۲۴ می باشد که شامل قیمت های باز بسته و کمترین بیشترین اولین و آخرین قیمت می باشد.

1	<TICKER>	<DTYYYYMMDD>	<FIRST>	<HIGH>	<LOW>	<CLOSE>	<VALUE>	<VOL>	<OPENINT>	<PER>	<OPEN>	<LAST>
2	Maskan.Invest.	20231205	27340.00	28050.00	26500.00	27810.00	117128140260	4211736	832	D	26720.00	28050.00
3	Maskan.Invest.	20231204	27340.00	27340.00	25000.00	26720.00	341048299020	12761441	2241	D	26040.00	27190.00
4	Maskan.Invest.	20231203	25790.00	26120.00	25050.00	26040.00	106339508850	4083504	743	D	24880.00	26120.00
5	Maskan.Invest.	20231202	24930.00	24930.00	24300.00	24880.00	163412736800	6566880	969	D	23750.00	24930.00
6	Maskan.Invest.	20231129	23200.00	23820.00	23200.00	23750.00	41112560310	1731211	237	D	22690.00	23820.00
7	Maskan.Invest.	20231128	22500.00	22730.00	22130.00	22690.00	101218721230	4461348	978	D	21650.00	22730.00
8	Maskan.Invest.	20231127	21890.00	21920.00	21160.00	21650.00	72560490070	3352001	633	D	20880.00	21920.00
9	Maskan.Invest.	20231126	20500.00	21690.00	20150.00	20880.00	89380855140	4280027	926	D	21210.00	21450.00
10	Maskan.Invest.	20231125	21050.00	21930.00	20800.00	21210.00	107769018090	5081293	884	D	21890.00	20830.00

شکل (۳) : نمونه داده های سهام مسکن

۳-۲-۴- گسترش نفت و گاز پارسیان (پارسان) - بازار اول (تابلوی اصلی) بورس

گروه گسترش نفت و گاز پارسیان (سهامی عام) در سال ۱۳۸۶ با نام اولیه شرکت توسعه الوند غدیر به صورت شرکت سهامی خاص در اداره ثبت شرکت ها و مؤسسات غیرتجاری تهران به ثبت رسید و همچنین با هدف توسعه فعالیت ها، نام شرکت به «گروه گسترش نفت و گاز پارسیان (سهامی عام)» تغییر یافته و عملاً با پذیرش این شرکت در بورس اوراق بهادار تهران، سهام این شرکت در مورخ ۱۳۹۰ در بورس تهران عرضه شد. داده های جمع آوری شده از این شرکت شامل دیتای ۱۲ ساله از سال ۲۰۱۲ تا ۲۰۲۴ بوده که شامل قیمت های باز بسته و کمترین بیشترین اولین و آخرین قیمت می باشد.

1	<TICKER>	<DTYYYYMMDD>	<FIRST>	<HIGH>	<LOW>	<CLOSE>	<VALUE>	<VOL>	<OPENINT>	<PER>	<OPEN>	<LAST>
2	S*Parsian.Oil&Gas	20231205	41560.00	42080.00	41510.00	41790.00	73398523530	1754893	507	D	41750.00	41700.00
3	S*Parsian.Oil&Gas	20231204	42440.00	43000.00	41510.00	41750.00	332061706510	7954201	1375	D	41410.00	41650.00
4	S*Parsian.Oil&Gas	20231203	40930.00	42500.00	40900.00	41410.00	190756659140	4606036	831	D	41120.00	42430.00
5	S*Parsian.Oil&Gas	20231202	41300.00	41500.00	40910.00	41120.00	133346455210	3242867	788	D	40720.00	41000.00
6	S*Parsian.Oil&Gas	20231129	40190.00	41190.00	39550.00	40720.00	158667765950	3896776	917	D	39670.00	40700.00
7	S*Parsian.Oil&Gas	20231128	39500.00	40000.00	39480.00	39670.00	165131163850	4162251	1402	D	39520.00	39700.00
8	S*Parsian.Oil&Gas	20231127	39690.00	39710.00	39430.00	39520.00	73394141010	1856832	593	D	39510.00	39510.00
9	S*Parsian.Oil&Gas	20231126	39900.00	39900.00	39430.00	39510.00	54799333640	1384600	587	D	39450.00	39600.00
10	S*Parsian.Oil&Gas	20231125	39160.00	39870.00	39160.00	39450.00	50942444980	1292951	342	D	39490.00	39400.00

شکل (۴) : نمونه داده های سهام نفت

۳-۲-۵- داده های دلار

یکی دیگر از داده های مهمی که نقش موثری در زندگی ما داشته دلار است که در چند سال اخیر با افزایش چشم گیر قیمت آن شاید افزایش همه جانبه قیمت ها در اکثر بازار ها بوده ایم. با توجه به این که داده های دلار به درستی در هیچ وب سایتی موجود نیست داده های فقط از وب سایت اطلاع رسانی اخذ شده است. داده های جمع آوری شده از وبسایت شبکه اطلاع رسانی طلا سکه و ارز شامل داده های ۱۲ ساله از سال ۲۰۱۲ تا ۲۰۲۴ بوده که شامل قیمت های باز بسته و کمترین بیشترین قیمت میباشد.

در ردیف یک هر کدام از دیتاست ها Ticker به معنی نام بورس یا شاخص، DTYYYYMMDD تاریخ مربوط به قیمت آن روز از بورس، Open قیمت باز شدن، High بالاترین قیمت، Low پایین ترین قیمت، Close قیمت بسته شدن آن روز از شاخص بورس میباشد. بقیه ستون ها و مقادیرشان در این پژوهش مورد استفاده ای نداشته اند.

1	<OPEN>	<LOW>	<HIGH>	<CLOSE>	<amount>	<perc>	<DTYYYYMMDD>	<shamsi>
2	509490.00	504950.00	509650.00	509200.00	180.00	0.04%	2024-01-07	1402/10/17
3	511530.00	508450.00	512580.00	509380.00	4560.00	0.90%	2024-01-06	1402/10/16
4	510480.00	510450.00	514630.00	513940.00	6440.00	1.27%	2024-01-04	1402/10/14
5	505470.00	505160.00	508200.00	507500.00	1990.00	0.39%	2024-01-03	1402/10/13
6	505000.00	504250.00	505700.00	505510.00	140.00	0.03%	2024-01-02	1402/10/12
7	505610.00	504150.00	506000.00	505650.00	250.00	0.05%	2024-01-01	1402/10/11
8	504560.00	504350.00	505450.00	505400.00	260.00	0.05%	2023-12-31	1402/10/10
9	503790.00	503760.00	506600.00	505660.00	4360.00	0.87%	2023-12-30	1402/10/09
10	500530.00	500500.00	502650.00	501300.00	1220.00	0.24%	2023-12-28	1402/10/07

شکل (۵): نمونه ای از داده های دلار

۳-۳- پیش پردازش داده ها

در بخش قبل داده های مورد استفاده معرفی شد که شامل سهام ۴ شرکت و قیمت دلار بود که از وبسایت اطلاع رسانی سکه و دلار و شرکت مدیریت فناوری بورس تهران جمع آوری شده اند. هر کدام از داده ها شامل قیمت های بیشترین، کمترین، اولین، آخرین و قیمت باز و بسته ی آن سهام می باشد و هر کدام از آنها در بازه ی زمانی خاص و متفاوت از یکدیگر جمع آوری شده است.

برای انجام پیش پردازش روی هر کدام از دیتاست ها ابتدا یک بازه ی مشترک بین آنها تعیین شده است که یک بازه ی ۹ ساله از سال ۲۰۱۴ تا اوسط سال ۲۰۲۲ می باشد، در مرحله ی بعد همه ی داده ها بر حسب تاریخ مرتب شده و سپس ستون های غیر مرتبط و اضافی از آنها حذف شده است و در نهایت از ابتدای سال ۲۰۱۲ به صورت هفتگی و با شروع از روز شنبه برای هر کدام از قیمت های باز بسته کمترین و بیشترین میانگین دیتا برای آن هفته محاسبه و ذخیره شده است. محور افقی هر کدام از نمودار ها، نشان دهنده قیمت آن شاخص بورس و محور افقی نشان دهنده ی تاریخ مربوطه می باشد. که با انتخاب یه نقطه روی منحنی به راحتی میتوان قیمت بورس را در تاریخ مربوطه پیدا کرد.

Stock

Datasets

Prediction

Search

Dashboard

Dropdown

Log in

Dataset Properties

Choice Datasets ...

☒ Dollar
 ☒ Home
 ☒ Oil
 ☒ Car
 ☒ Tech

Choice Prices ...

☒ <CLOSE>
 ☒ <HIGH>
 ☒ <OPEN>
 ☒ <LOW>

Enter props ...

2014-01-07 ~ 2022-05-16

< JAN 2014 >


Sun	Mon	Tue	Wed	Thu	Fri	Sat
29	30	31	1	2	3	4
5	6	7	8	9	10	11
12	13	14	15	16	17	18
19	20	21	22	23	24	25
26	27	28	29	30	31	1
2	3	4	5	6	7	8

< MAY 2022 >

Sun	Mon	Tue	Wed	Thu	Fri	Sat
1	2	3	4	5	6	7
8	9	10	11	12	13	14
15	16	17	18	19	20	21
22	23	24	25	26	27	28
29	30	31	1	2	3	4
5	6	7	8	9	10	11


Save

شکل (۶): فرم نمایش داده های پیش پردازش شده در بازه ۹ ساله. ستون اول ورودی های مربوط به انتخاب دیتاست های مورد نظر و ستون دوم ورودی های مربوط به انتخاب قیمت و ستون سوم نیز بازه انتخاب تاریخ مورد نظر برای انجام پیش بینی میباشد.



شکل (۷): نام دیتاست بالای نمودار درج شده و نمودار شامل چندین منحنی میباشد که هر منحنی نشان دهنده قیمت مشخص شده با رنگ منحصر به فرد می باشد که زیر عنوان اشاره شده اند. به عنوان مثال منحنی رنگ سبز نشان دهنده کمترین قیمت داده های دلار میباشد.

Car Dataset Price



شکل (۸) : نمونه داده های پردازش شده برای داده های سهام شرکت الکتریک خودرو

Tech Dataset Price




شکل (۹) : نمونه داده های پردازش شده برای سهام شرکت فناوری

Oil Dataset Price



شکل (۱۰): نمونه داده های پردازش شده برای سهام نفت

Home Dataset Price



شکل (۱۱): نمونه داده های پردازش شده برای سهام الکتریک خوردو

با مشاهده نمودارها متوجه میشویم روند صعودی داده ها از اواخر سال ۲۰۱۹ میلادی شروع شده و پس از آن طی نوسانات متعدد در برخی نزول و برخی صعود مجدد داشته است.

۳-۴- سری های زمانی

در این بخش به معرفی سری های زمانی تک و چند متغیره و تفاوت آنها میپردازیم. سری های زمانی تک متغیره مجموعه داده هایی هستند که از یک سری مشاهدات با ترتیب زمانی تشکیل شده اند و یک مدل برای یادگیری از سری مشاهدات گذشته برای پیش بینی مقدار بعدی در دنباله مورد نیاز است. در سری های زمانی نیاز هست داده ها را به نمونه های ورودی و خروجی تفکیک کنیم تا به ساختار مناسبی برای مدل تبدیل شود. بنابراین مدل تابعی را یاد می گیرد که دنباله ای از مشاهدات گذشته را به عنوان ورودی به مشاهدات خروجی ترسیم می کند. به این ترتیب، دنباله مشاهدات باید به نمونه های متعددی تبدیل شود که مدل بتواند از آنها بیاموزد. قبل از تفکیک داده ها کاربر باید تعداد مرحله زمانی را برای تعیین تعداد مشاهدات مشخص نماید که پس از آن می توانیم دنباله را به الگوهای ورودی/خروجی متعددی به نام نمونه ها تقسیم کنیم، که در آن به عنوان مثال از سه مرحله زمانی به عنوان ورودی و یک مرحله زمانی به عنوان خروجی برای پیش بینی یک مرحله ای که در حال یادگیری است استفاده می شود. برای مثال یک سری تک متغیره مانند [۱۰, ۲۰, ۳۰, ۴۰, ۵۰, ۶۰, ۷۰, ۸۰, ۹۰] را در نظر بگیرید. اگر تعداد مراحل زمانی ۳ واحد انتخاب باشد تقسیم بندی داده ها به شکل زیر خواهد بود:

[10 20 30]	40
[20 30 40]	50
[30 40 50]	60
[40 50 60]	70
[50 60 70]	80
[60 70 80]	90

شکل (۱۲): خروجی تفکیک داده ها به ورودی و خروجی

پیرو توضیحات بالا تابعی مشخص این رفتار را پیاده سازی می کند و یک دنباله تک متغیره معین را به چندین نمونه تقسیم می کند که در آن هر نمونه تعداد مراحل زمانی مشخصی دارد و خروجی یک مرحله زمانی واحد است. اکنون می دانیم که چگونه یک سری تک متغیره برای مدل سازی آماده کنیم.

داده های سری زمانی چند متغیره به معنای داده هایی است که در آن بیش از یک مشاهده برای هر مرحله زمانی وجود دارد. همانند سری های زمانی تک متغیره، ما باید این داده ها را به نمونه هایی با دنباله های ورودی و خروجی ساختار دهیم تا بتوانیم یک مدل را آموزش دهیم. مسئله سری زمانی چند متغیره حالتی است که چندین سری زمانی موازی وجود دارد و باید برای هر یک مقداری پیش بینی شود. ممکن است بخواهیم مقدار هر یک از سری زمانی را برای

مرحله زمانی بعدی پیش بینی کنیم که ممکن است به عنوان پیش بینی چند متغیره نامیده شود. بنابراین همانند سری تک متغیره تعداد مرحله زمانی و تابع تفکیک ورودی خروجی پیاده سازی می شود ولی این بار ابتدا داده ها به صورت موازی ترکیب شده و سپس داده ی ترکیب شده به دنباله های ورودی خروجی تفکیک می شود. برای مثال ۳ سری زیر [۱۰ , ۲۰ , ۳۰ , ۴۰ , ۵۰ , ۶۰ , ۷۰ , ۸۰ , ۹۰] و [۱۵ , ۲۵ , ۳۵ , ۴۵ , ۵۵ , ۶۵ , ۷۵ , ۸۵ , ۹۵] و [۲۵ , ۳۵ , ۴۵ , ۵۵ , ۶۵ , ۷۵ , ۸۵ , ۹۵ , ۱۰۵ , ۱۱۵ , ۱۲۵ , ۱۳۵ , ۱۴۵ , ۱۵۵ , ۱۶۵] را در نظر بگیرید. در این حالت پس از اعمال تغییر حالت و قرارگیری داده به صورت عمودی کنارهم شکل نهایی به صورت زیر خواهد بود که هر ستون بیانگر هر سری است.

[10 15 25]
[20 25 45]
[30 35 65]
[40 45 85]
[50 55 105]
[60 65 125]
[70 75 145]
[80 85 165]
[90 95 185]

شکل (۱۳) : نتیجه ترکیب سری ها به صورت موازی

اگر مراحل زمانی را ۳ در نظر بگیریم. تفکیک داده ها به نمونه ها به شکل زیر می شود. که باتوجه به طول هر سری که برابر با عدد ۹ است با جداسازی ۳ مرحله ای، یک سری ۶ تایی به شکل های متفاوت برای داده های ورودی و خروجی ایجاد خواهد که در شکل زیر قابل مشاهده است.

[10 15 25]
[20 25 45]
[30 35 65] [40 45 85]
[20 25 45]
[30 35 65]
[40 45 85] [50 55 105]
[30 35 65]
[40 45 85]
[50 55 105] [60 65 125]
[40 45 85]
[50 55 105]
[60 65 125] [70 75 145]
[50 55 105]
[60 65 125]
[70 75 145] [80 85 165]
[60 65 125]
[70 75 145]
[80 85 165] [90 95 185]

شکل (۱۴) : تفکیک داده های سری چند متغیره به ورودی و خروجی

بعد از آماده سازی داده ها برای هر دیتاست و با توجه به نوع قیمتی که برای پیش بینی مشخص می شود مثل کمترین یا بیشترین قیمت، باید داده های ورودی با توجه به تعداد مراحل که در ورودی از کاربر دریافت می شود به داده های ورودی و خروجی برای آن داده ها جدا سازی شود اگر تعداد مراحل بر فرض مثال ۳ در نظر گرفته شود ورودی باید برحسب بخش های سه تایی تقسیم بندی شود. این بخش بندی برای این منظور صورت می گیرد که الگوریتم یاد بگیرد که داده هایی که در هر بخش هستند برای پیش بینی باید به داده های ۳ روز قبل از خود دقت کند. برای نوع سری زمانی تک متغیره برای هر دنباله فقط ۱ مقدار به عنوان خروجی در نظر گرفته می شود و همچنین برای سری زمانی چند متغیره برای هر دنباله به تعداد متغیر آن بخش خروجی در نظر گرفته می شود. برای سری زمانی نیز چند متغیره ابتدا لازم است به تمام داده های مربوط به هر کدام از دیتا ست ها به صورت عمودی در هم ادغام شوند تا ۱ دیتای کلی از تمام دیتا ست ها به وجود آید که هر ستون بیانگر هر کدام از دیتاست ها می باشد

مرحله ی بعدی جداسازی و تقسیم داده ها به داده های آزمایشی و یادگیری می باشد و و برحسب بازه ای که برای داده های آزمایشی در نظر گرفته شده جداسازی انجام می پذیرد که در این تحقیق ۸۰ درصد از داده ها برای آموزش و ۲۰ درصد مابقی برای آزمایش مدل ها مورد استفاده قرار میگیرد.

۳-۵- سناریوهای تحقیق

پیش بینی قیمت دلار و همچنین بازارهای سهام از اهمیت بالایی برخوردار است حال علاوه بر پیش بینی داده ها به صورت تک متغیری به عنوان مثال پیش بینی قیمت دلار، بتوان تاثیر دیگر بازارهای مالی را نیز به روی یکدیگر پیدا کرد. بنابراین هدف این است که در پیش بینی یکی از سری های زمانی مثل دلار، تاثیر طلا، مسکن، خودرو و نفت را در این سری مشاهده کنیم و نتیجه پیش بینی علاوه بر خود، تاثیر عوامل دیگر را نیز شامل شود.

۳-۶- مدل های پیشنهادی مطالعه

یادگیری ماشین زیرشاخه ای از هوش مصنوعی است که بر توسعه الگوریتم هایی تمرکز دارد که می توانند از داده ها یاد بگیرند و بر اساس آن یادگیری، پیش بینی یا تصمیم بگیرند. هدف یادگیری ماشین این است که کامپیوترها را قادر سازد تا از تجربه یاد بگیرند و بدون برنامه ریزی صریح، پیشرفت کنند. سه نوع اصلی یادگیری ماشین وجود دارد: یادگیری تحت نظارت، یادگیری بدون نظارت و یادگیری تقویتی. در یادگیری نظارت شده، الگوریتم بر روی یک مجموعه داده برچسب گذاری شده آموزش داده می شود، به شکلی که داده های ورودی با خروجی صحیح مرتبط می شوند. الگوریتم یاد می گیرد که با به حداقل رساندن خطا بین خروجی پیش بینی شده و خروجی واقعی، ورودی را به خروجی نگاشت کند. این نوع یادگیری برای کارهایی مانند طبقه بندی، رگرسیون و پیش بینی استفاده می شود. در این مطالعه از مدل های شبکه

عصبی پیچشی شبکه عصبی^۱، حافظه کوتاه مدت طولانی شبکه عصبی بازگشتی، شبکه عصبی مصنوعی، شبکه عصبی واحد بازگشتی گیتی^۲، شبکه عصبی بازگشی ساده^۳ و نسخه دوطرفه^۴ تمام مدل ها و همچنین ترکیب آنها به عنوان یادگیری تجمیعی^۵ برای ساخت و آزمایش مدل ها برای سری های زمانی تک و چند متغیره بهره گرفته شده است.

شبکه های عصبی مصنوعی^۶ نوعی الگوریتم یادگیری ماشین هستند که برای ساخت آنها از ساختار و عملکرد مغز انسان الهام گرفته شده است. شبکه های عصبی مصنوعی متشکل از گره های به هم پیوسته یا نورون های مصنوعی هستند که اطلاعات را پردازش می کنند و یاد می گیرند بر اساس داده های ورودی پیش بینی کنند. اتصالات بین گره ها دارای وزن هستند و وزن ها در طول پردازش داده، برای بهبود دقت پیش بینی ها تنظیم می شوند. شبکه های عصبی مصنوعی به طور گسترده در کاربردهای مختلفی مانند تشخیص تصویر، تشخیص گفتار و پردازش زبان طبیعی استفاده می شوند. یکی از نقاط قوت شبکه مصنوعی ها توانایی آنها در یادگیری الگوهای پیچیده در مجموعه داده های بزرگ بدون برنامه ریزی صریح است. آنها همچنین می توانند از مثال ها یاد بگیرند و با موقعیت های جدید تطبیق پیدا کنند، که آنها را برای کارهایی که شامل محیط های نامشخص یا پویا هستند، مناسب می کند.

شبکه های عصبی پیشخور ابتدایی ترین نوع شبکه عصبی مصنوعی است که در آن اطلاعات تنها در یک جهت جریان دارد، از گره های ورودی به گره های خروجی. این شبکه ها برای کارهایی مانند طبقه بندی، رگرسیون و تشخیص الگو استفاده می شوند. شبکه های عصبی بازگشتی نیز یک حلقه بازخورد هستند که به آنها اجازه می دهد اطلاعات ورودی های قبلی را ذخیره کنند که آنها را برای کارهایی مانند پیش بینی توالی، مدل سازی زبان و تشخیص گفتار مناسب می کند. شبکه های عصبی کانولوشنی برای پردازش داده ها با توپولوژی شبکه ای مانند تصاویر و ویدئوها طراحی شده اند. آنها از یک سری لایه های کانولوشن برای استخراج ویژگی ها از داده های ورودی استفاده می کنند و معمولاً برای تشخیص تصویر، تشخیص اشیا و تجزیه و تحلیل ویدیو استفاده می شوند. شبکه ی عصبی بازگشتی نوعی شبکه عصبی است که حافظه ی داخلی دارد؛ به عبارت دیگر، این شبکه یک شبکه ی عصبی معمولی است که در ساختارش حلقه ای دارد که از طریق آن در هر گام خروجی گام قبلی، به همراه ورودی جدید، به شبکه وارد می شود. این حلقه به شبکه کمک می کند تا اطلاعات قبلی را در کنار اطلاعات جدید داشته باشد و بتواند براساس این اطلاعات خروجی مدنظر را به ما بدهد. این ویژگی شبکه ی بازگشتی این امکان را می دهد که بتوانیم با داده های ترتیبی^۷، مانند متن، صدا و غیره، کار کرد.

¹ CNN : convolutional neural network

² GRU : gated recurrent network

³ Simple RNN : recurrent neural network

⁴ Bidirectional


⁵ Ensemble Learning

⁶ ANN : artificial neural network

⁷ Sequential Data

سؤالى که پیش می آید این است که چرا با وجود شبکه‌ی عصبی بازگشتی، شبکه‌ی حافظه طولانی کوتاه مدت به وجود آمده است؟ دلیل اصلی این است که شبکه‌ی عصبی بازگشتی در مسائلى که نیاز باشد حافظه‌ی بلندمدت داشته باشد نمی‌تواند خیلی خوب عمل کند؛ برای مثال، اگر بخواهیم کلمه‌ی آسمان را در جمله ابرها در آسمان هستند پیش‌بینی کند این کار را به‌خوبی انجام می‌دهد؛ چون با داشتن اطلاعات کلمات همین یک جمله می‌تواند به‌راحتی کلمه‌ی آخر را پیش‌بینی کند. اما اگر بخواهیم کلمه‌ی فرانسه را در پاراگراف من در فرانسه بزرگ شدم. ... من خوب فرانسوی صحبت می‌کنم پیش‌بینی کند، متأسفانه از پس این کار برنمی‌آید؛ چون برای پیش‌بینی این کلمه نیاز دارد اطلاعات مربوط به کلمات خیلی قبل‌تر را هم در اختیار داشته باشد. درواقع هر قدر فاصله‌ی میان کلمه‌ای که باید پیش‌بینی کند و اطلاعات قبلی که به آن نیاز دارد برای این پیش‌بینی زیاده‌تر شود، شبکه‌ی بازگشتی توانایی یادگیری آن‌ها را از دست می‌دهد؛ پس به‌طور کلی می‌توانیم بگوییم شبکه‌ی بازگشتی حافظه‌ی کوتاه‌مدت خوبی دارد، اما حافظه‌ی بلندمدت نه. دلیل این موضوع مفهومی به‌نام محوشدگی گرادیان^۱ است.

شبکه‌ی عصبی حافظه کوتاه مدت طولانی نوع خاصی از شبکه‌ی بازگشتی است که مشکل حافظه‌ی بلندمدت شبکه‌ی بازگشتی را حل می‌کند. این شبکه سازوکارهایی داخلی به‌اسم گیت دارد. این گیت‌ها جریان اطلاعات را کنترل می‌کنند؛ همین‌طور مشخص می‌کنند چه داده‌هایی در توالی مهم هستند و باید هم‌چنان حفظ بشوند و چه داده‌هایی باید حذف بشوند؛ به‌این شکل، شبکه‌ی اطلاعات مهم را در طول زنجیره‌ی توالی عبور می‌دهد تا خروجی مدنظر را داشته باشیم. در این شکل ساختار یک شبکه‌ی عصبی LSTM را می‌بینیم:



شکل (۱۵): ساختار داخلی یک شبکه LSTM

^۱ Vanishing Gradient

همان طور که در شکل مشخص است، شبکه‌ی حافظه طولانی کوتاه مدت چندین عملیات مختلف در ساختار داخلی‌اش دارد. این عملیات به شبکه‌ی حافظه طولانی کوتاه مدت کمک می‌کند اطلاعات را حفظ یا فراموش کند. برای درک نحوه‌ی کار این شبکه گام به گام این عملیات را با هم بررسی می‌کنیم. مفهوم اصلی شبکه‌ی حافظه طولانی کوتاه مدت همان وضعیت سلولی^۱ و گیت‌های همراهش است؛ درواقع وضعیت سلولی مانند آزادراهی عمل می‌کند که اطلاعات را در طول زنجیره‌ی توالی جلو می‌برد. می‌توانیم به وضعیت سلولی به عنوان حافظه‌ی شبکه نگاه کنیم. گیت‌ها اطلاعات را در وضعیت سلولی به روز نگه می‌دارند. این گیت‌ها شبکه‌های عصبی مختلفی هستند که تصمیم می‌گیرند چه اطلاعاتی به وضعیت سلولی وارد بشوند. این گیت‌ها در طول آموزش شبکه یاد می‌گیرند چه اطلاعاتی باید حفظ یا فراموش شوند.

از آنجا که استفاده از شبکه‌های عصبی تمام‌متصل^۲ عمیق به قدرت محاسباتی (حافظه) بالایی نیاز دارد تا بتوان تعداد زیادی وزن و ضرب ماتریسی سنگین را مدیریت کرد، نوع جدیدی از شبکه‌های عصبی به نام شبکه‌ی عصبی کانولوشنی معرفی شد. در میان شبکه‌های عصبی، شبکه‌ی عصبی کانولوشنی یکی از بهترین‌ها برای حل مسائل حوزه‌ی بینایی ماشین، مانند شناسایی تصاویر، طبقه‌بندی تصاویر، تشخیص چهره و غیره، است. یک شبکه‌ی پیچشی از دو بخش کلی تشکیل شده است: استخراج ویژگی و طبقه‌بندی. درواقع زمانی که یک عکس به یک شبکه‌ی پیچشی وارد می‌شود، ابتدا به مرحله‌ی استخراج ویژگی وارد می‌شود. در این مرحله هر عکس ورودی از چندین سری لایه‌ی کانولوشن و تابع فعال‌ساز رلو^۳ و لایه‌ی پولینگ^۴ عبور می‌کند. سپس عکس‌های ورودی به طبقه‌بندی وارد می‌شوند؛ در این مرحله ابتدا مسطح‌سازی^۵ صورت می‌گیرد و سپس به یک لایه‌ی تمام‌متصل وارد می‌شوند و در نهایت یک تابع سافت مکس^۶ برای مسائل طبقه‌بندی چندکلاسه و یا تابع سیگموید^۷ برای مسائل طبقه‌بندی باینری روی آن اعمال می‌شود تا عکس‌ها براساس مقادیر احتمالی میان صفر و یک طبقه‌بندی شوند.

شبکه عصبی واحد بازگشتی گیتی^۸ نوع خاصی شبکه عصبی بازگشتی است. این شبکه تا حد زیادی مشابه شبکه عصبی حافظه کوتاه مدت طولانی است؛ به عبارت دیگر، شبکه بازگشتی گیتی نوع پیشرفته‌تری از شبکه عصبی بازگشتی و شبکه

^۱ Cell state

^۲ Fully connected

^۳ Relu activation function

^۴ Pooling layer

^۵ Flattening

^۶ Softmax

^۷ Sigmoid

^۸ Gated Recurrent Unit

حافظه کوتاه مدت طولانی است. با این تفاوت که به جای سه گیت، فقط دو گیت تنظیم مجدد^۱ و گیت به روزرسانی^۲ دارد؛ هم چنین شبکه بازگشتی گیتی چیزی به نام حالت سلول ندارد و برای انتقال اطلاعات از حالت نهان^۳ استفاده می کند.

۳-۶-۱- تعریف پارامترها

ما به اصطلاحاتی مانند دوره ها^۴، اندازه دسته ای^۵ و تکرارها^۶ فقط زمانی نیاز داریم که داده ها خیلی بزرگ باشند، که این مورد همیشه در یادگیری ماشین اتفاق می افتد و ما نمی توانیم همه داده ها را به یکباره به سیستم منتقل کنیم. در نتیجه، برای غلبه بر این مشکل باید داده ها را به اندازه های کوچکتر تقسیم کرده و یکی یکی به سیستم خود بدهیم و وزن شبکه های عصبی را در پایان هر مرحله به روز کنیم تا با داده های ورودی مطابقت داشته باشد. از آنجایی که یک دوره آنقدر بزرگ است که نمی توان آن را به یکباره به سیستم وارد کرد، آن را به چند دسته کوچکتر تحت عنوان دوره تقسیم می کنیم. ولی چرا از بیش از یک دوره استفاده می کنیم؟ همه ی ما می دانیم که انتقال کل مجموعه داده از طریق یک شبکه عصبی کافی نبوده و باید مجموعه داده را چندین بار به یک شبکه عصبی ارسال کنیم. اما به خاطر داشته باشید که ما از یک مجموعه داده محدود استفاده می کنیم و برای بهینه سازی یادگیری و نمودار از گرادین کاهشی استفاده می کنیم که فرآیندی تکراری است. بنابراین، به روزرسانی وزن ها با یک پاس دادن یا یک دوره کافی نیست. با افزایش تعداد دوره ها، تعداد دفعات تغییر وزن در شبکه عصبی بیشتر می شود و منحنی از کم برآزش^۷ به منحنی بهینه^۸ و بعد به منحنی بیش برآزش^۹ می رود. بنابراین همانطور که گفته شد، نمی توان کل مجموعه داده را به یکباره به شبکه عصبی منتقل کرد. بنابراین، مجموعه داده ها را به تعداد دسته ها یا مجموعه ها یا قطعات تقسیم می کنیم.

۳-۶-۲- پیاده سازی مدل ها در سری های تک و چند متغیره

ما می توانیم یک مدل پیچشی^{۱۰} یک بعدی را برای پیش بینی سری های زمانی تک متغیره به صورت زیر تعریف کنیم. یک مدل پیچشی یک بعدی یک مدل پیچشی است که دارای یک لایه مخفی کانولوشن است که روی یک دنباله یک بعدی عمل می کند. احتمالاً در برخی موارد، لایه کانولوشن دوم، مانند توالی های ورودی بسیار طولانی، و سپس یک لایه ادغام که وظیفه آن تقطیر خروجی لایه کانولوشن به برجسته ترین عناصر است، دنبال می شود. لایه های کانولوشن و

¹ Reset Gate

² Update Gate

³ Hidden State

⁴ Epochs

⁵ Batch Size

⁶ Iterations

⁷ Underfitting

⁸ Optimal

⁹ Overfitting

¹⁰ Convolutional Neural Network

ترکیبی توسط یک لایه کاملاً متراکم به هم پیوسته دنبال می شوند که ویژگی های استخراج شده توسط بخش کانولوشنال مدل را تفسیر می کند. یک لایه مسطح بین لایه های کانولوشن و لایه متراکم استفاده می شود تا نقشه های ویژگی را به یک بردار تک بعدی کاهش دهد.

define model

```
model = Sequential()
model.add(Conv1D(filters=64, kernel_size=2, activation='relu', input_shape=(n_steps, n_features)))
model.add(MaxPooling1D(pool_size=2))
model.add(Flatten())
model.add(Dense(50, activation='relu'))
model.add(Dense(1))
model.compile(optimizer='adam', loss='mse')
```

شکل (۱۶): نحوه تعریف یک مدل شبکه عصبی پیچشی که شامل ۵ لایه شده و در نهایت مدل با بهینه ساز و تابع زیان مناسب کامپایل خواهد شد.

کلید در تعریف شکل ورودی است. این همان چیزی است که مدل به عنوان ورودی برای هر نمونه از نظر تعداد مراحل زمانی و تعداد ویژگی ها انتظار دارد. ما با یک سری تک متغیره کار می کنیم، بنابراین تعداد ویژگی ها یک، برای یک متغیر است. تعداد گام های زمانی به عنوان ورودی، عددی است که هنگام آماده سازی مجموعه داده هایمان به عنوان آرگومان برای تابع انتخاب کردیم. شکل ورودی برای هر نمونه در آرگومان مربوطه^۱ در تعریف اولین لایه پنهان مشخص شده است. ما همیشه چندین نمونه داریم، بنابراین، مدل انتظار دارد مؤلفه ورودی داده های آموزشی دارای ابعاد یا شکل باشد، [samples, timesteps, features] این همان شکل ورودی است.

مدل در واقع داده ها را دارای مراحل زمانی نمی داند، در عوض، به عنوان دنباله ای تلقی می شود که می توان از طریق آن عملیات خواندن کانولوشنی را انجام داد، مانند یک تصویر یک بعدی. به عنوان مثال، ما یک لایه کانولوشن با ۶۴ نقشه فیلتر و اندازه هسته ۲ تعریف می کنیم. پس از آن یک لایه ادغام حداکثر و یک لایه متراکم برای تفسیر ویژگی ورودی وجود دارد. یک لایه خروجی مشخص شده است که یک مقدار عددی واحد را پیش بینی می کند. این مدل با استفاده از نسخه کارآمد نزول گرادیان تصادفی آموزش^۲ و با استفاده از میانگین مربعات خطا یا تابع ضرر^۳ ارزیابی می شود. زمانی که مدل تعریف شد، می توانیم آن را در مجموعه داده آموزشی قرار دهیم.

^۱ Input_shape

^۲ adam

^۳ MSE

```
# fit model
```

```
model.fit(X, y, epochs=1000, verbose=0)
```

شکل (۱۷) : مدل یادگیری را با ۱۰۰۰ دوره انجام خواهد داد.

مدل انتظار دارد که شکل ورودی سه بعدی با [نمونه‌ها، گام‌های زمانی، ویژگی‌ها] باشد، بنابراین، قبل از انجام پیش‌بینی باید نمونه ورودی واحد را تغییر شکل دهیم. که طبق کد زیر به حالتی با بعد (۱, ۳, ۱) تبدیل می‌شود.

```
# demonstrate prediction
```

```
x_input = array([70, 80, 90])
```

```
x_input = x_input.reshape((1, n_steps, n_features))
```

```
yhat = model.predict(x_input, verbose=0)
```

شکل (۱۷) : پیش بینی مدل با داده های ورودی فراهم شده

همچنین بعد از اینکه مدل آموزش داده شد، می توانیم از آن برای پیش بینی استفاده کنیم. که به عنوان مثال با ارائه ورودی [۷۰, ۸۰, ۹۰] می توانیم مقدار بعدی را در دنباله پیش بینی کنیم که انتظار می‌رود معادل عدد [۱۰۰] باشد.

برای سری زمانی چند متغیره در مدل شبکه عصبی پیچشی، تعداد مراحل زمانی و سری های موازی (ویژگی ها) برای لایه ورودی مدل مشخص می شود. همچنین تعداد سری های موازی نیز در تعیین تعداد مقادیر برای پیش بینی توسط مدل در لایه خروجی استفاده می شود. برای بهبود کارایی هر سری خروجی را می توان با یک مدل پیچشی خروجی جداگانه مدیریت کرد. می توانیم به این مدل پیچشی چند خروجی اشاره کنیم. بسته به ویژگی های مشکلی که در حال مدل سازی است، ممکن است انعطاف پذیری یا عملکرد بهتری ارائه دهد. ابتدا می توانیم اولین مدل ورودی را به عنوان یک مدل پیچشی یک بعدی تعریف کنیم.

```
visible = Input(shape=(n_steps, n_features))
```

```
cnn = Conv1D(filters=64, kernel_size=2, activation='relu')(visible)
```

```
cnn = MaxPooling1D(pool_size=2)(cnn)
```

```
cnn = Flatten()(cnn)
```

```
cnn = Dense(50, activation='relu')(cnn)
```


شکل (۱۸) : تعریف مدل شبکه عصبی پیچشی برای سری چند متغیره

سپس می توانیم برای هر سری که می خواهیم پیش بینی کنیم، یک لایه خروجی تعریف کنیم، جایی که هر زیرمدل خروجی یک مرحله زمانی واحد را پیش بینی می کند.

```
# define output 1
output1 = Dense(1)(cnn)
# define output 2
output2 = Dense(1)(cnn)
# define output 3
output3 = Dense(1)(cnn)
```

شکل (۱۹) : تعریف لایه های خروجی برای هر مدل

برای شفاف سازی معماری مدل، شماتیک زیر یک مثال برای سری زمانی ۳ متغیره است که به وضوح سه لایه خروجی مجزای مدل و اشکال ورودی و خروجی هر لایه را نشان می دهد.



شکل (۲۰) : دیاگرام معماری شبکه عصبی پیچشی برای سری چند متغیره

هنگام آموزش مدل، به سه آرایه خروجی مجزا در هر نمونه نیاز دارد. ما می توانیم با تبدیل داده های آموزشی خروجی که شکل [۳، ۷] را دارند به سه آرایه با شکل [۱، ۷] به این هدف برسیم.

```
# separate output
y1 = y[:, 0].reshape((y.shape[0], 1))
y2 = y[:, 1].reshape((y.shape[0], 1))
y3 = y[:, 2].reshape((y.shape[0], 1))
```

شکل (۲۱) : تغییر حالت ۳ آرایه خروجی مجزا

این آرایه ها را می توان در طول آموزش در اختیار مدل قرار داد.

```
# fit model
model.fit(X, [y1,y2,y3], epochs=2000, verbose=0)
```

شکل (۲۲) : آموزش مدل با خروجی های مرحله قبل و ۲۰۰۰ مرحله

در نهایت باتوجه به این که واحد زمانی ۳ واحد انتخاب شده و تعداد ویژگی ها نیز ۳ میباشد میتوانیم آخرین استپ دنباله را پس از تغییر حالت ۱ و ۳ و ۳ بعدی در اختیار مدل برای پیش بینی قرار دهیم.

```
# demonstrate prediction
x_input = array([[70,75,145], [80,85,165], [90,95,185]])
x_input = x_input.reshape((1, n_steps, n_features))
yhat = model.predict(x_input, verbose=0)
```

شکل (۲۳) : پیش بینی روی یک نمونه داده چند متغیره

اجرای مثال داده ها را آماده می کند، با مدل متناسب می شود و پیش بینی می کند.

```
[ array([[100.96118]]), dtype=float32),
  array([[105.502686]]), dtype=float32),
  array([[205.98045]]), dtype=float32) ]
```

شکل (۲۴) : نتیجه پیش بینی روی نمونه داده

شبکه عصبی حافظه طولانی کوتاه مدت را نیز می توان برای مدل سازی مشکلات پیش بینی سری های زمانی تک متغیره استفاده کرد. این پیش بینی نیز جز مسائل هست که از یک سری مشاهدات تشکیل شده است و یک مدل برای یادگیری از سری مشاهدات گذشته برای پیش بینی مقدار بعدی در دنباله مورد نیاز است. ما تعدادی از تغییرات این مدل را برای پیش بینی سری های زمانی تک متغیره نشان خواهیم داد. آنها عبارتند از: شبکه عصبی حافظه طولانی کوتاه مدت وانیلی^۱، شبکه عصبی حافظه طولانی کوتاه مدت انباشته^۲ و شبکه عصبی حافظه طولانی کوتاه مدت دوطرفه^۳. هر یک از مدل های ذکر شده برای پیش بینی سری های زمانی تک مرحله ای نشان داده خواهند شد، اما به راحتی می توان آنها را تطبیق داد و به عنوان بخش ورودی یک مدل برای انواع دیگر مشکلات پیش بینی سری های زمانی استفاده کرد. قابل ذکر است که نحوه استخراج داده ها به نمونه های ورودی و خروجی دقیقاً شبیه به مدل شبکه عصبی پیچشی میباشد. که دوباره یک دنباله از ۹ عدد را به ۶ نمونه ۳ تایی به عنوان ورودی و ۱ نمونه به عنوان خروجی تقسیم بندی میکنیم.

¹ Vanilla LSTM

² Stacked LSTM

³ Bidirectional LSTM

همانند شبکه پیچشی کلید در تعریف شکل ورودی است. این همان چیزی است که مدل به عنوان ورودی برای هر نمونه از نظر تعداد مراحل زمانی و تعداد ویژگی ها انتظار دارد. ما با یک سری تک متغیره کار می کنیم، بنابراین تعداد ویژگی ها یک، برای یک متغیر است. تعداد گام های زمانی به عنوان ورودی، عددی است که هنگام آماده سازی مجموعه داده هایمان به عنوان آرگومان برای تابع انتخاب کردیم. شبکه عصبی حافظه طولانی کوتاه مدت وانیلی نیز یک مدل شبکه عصبی حافظه طولانی کوتاه مدت است که دارای یک لایه پنهان واحد از واحدهای شبکه عصبی حافظه طولانی کوتاه مدت و یک لایه خروجی است که برای پیش بینی استفاده می شود.

```
# define model
model = Sequential()
model.add(LSTM(50, activation='relu', input_shape=(n_steps, n_features)))
model.add(Dense(1))
model.compile(optimizer='adam', loss='mse')
```

شکل (۲۵): تعریف شبکه عصبی حافظه طولانی مدت با ۵۰ واحد

چندین لایه پنهان شبکه عصبی حافظه طولانی کوتاه مدت را می توان یکی بر روی دیگری در مدلی که به عنوان شبکه عصبی حافظه طولانی کوتاه مدت انباشته نامیده می شود قرار داد.

```
# define model
model = Sequential()
model.add(LSTM(50, activation='relu', return_sequences=True, input_shape=(n_steps, n_features)))
model.add(LSTM(50, activation='relu'))
model.add(Dense(1))
model.compile(optimizer='adam', loss='mse')
```

شکل (۲۶): تعریف دولا به کوتاه مدت ۵۰ واحدی که خروجی هر واحد وارد واحد بعدی میشود

یک لایه شبکه عصبی حافظه طولانی کوتاه مدت به یک ورودی سه بعدی نیاز دارد و این مدل به طور پیش فرض یک خروجی دو بعدی را به عنوان تفسیری از انتهای دنباله تولید می کنند. ما می توانیم با تنظیم و فعال سازی آرگومان برگشت دنباله ها^۱ در لایه، با داشتن مقدار خروجی مدل برای هر مرحله زمانی در داده های ورودی، این مشکل را برطرف کنیم. که به ما اجازه می دهد تا خروجی سه بعدی از لایه مخفی را به عنوان ورودی به لایه بعدی داشته باشیم.

^۱ return_sequences=True

در برخی از مشکلات پیش بینی توالی، می توان به مدل شبکه عصبی حافظه طولانی کوتاه مدت اجازه داد که توالی ورودی را هم به جلو و هم به عقب یاد بگیرد و هر دو تفسیر را به هم پیوند دهد، می تواند مفید باشد. به این شبکه عصبی حافظه طولانی کوتاه مدت دوطرفه می گویند.

```
# define model
model = Sequential()
model.add(Bidirectional(LSTM(50, activation='relu'), input_shape=(n_steps, n_features)))
model.add(Dense(1))
model.compile(optimizer='adam', loss='mse')
```

شکل (۲۷): تعریف شبکه عصبی حافظه طولانی کوتاه مدت دوطرفه توسط به مدل LSTM ۵۰ واحدی

ما می توانیم یک شبکه عصبی حافظه طولانی کوتاه مدت دوطرفه را برای پیش بینی سری های زمانی تک متغیره با پیچاندن اولین لایه پنهان در یک لایه پوششی پیاده سازی کنیم. پس از تعریف مدل ها، نوبت به آموزش آنها میرسد تا در نهایت بتوانند یک دنباله ورودی را دریافت کرده و پس از اعمال تغییر حالت مورد نیاز، پیش بینی را انجام دهند.

```
# fit model
model.fit(X, y, epochs=200, verbose=0)
# demonstrate prediction
x_input = array([70, 80, 90])
x_input = x_input.reshape((1, n_steps, n_features))
yhat = model.predict(x_input, verbose=0)
```

شکل (۲۸): آموزش مدل با ۲۰۰ دوره و پیش بینی روی یک نمونه داده

همانطور که گفتیم داده های سری زمانی چند متغیره به معنای داده هایی است که در آن بیش از یک مشاهده برای هر مرحله زمانی وجود دارد. همچنین همانند شبکه پیچشی و همانند سری های زمانی تک متغیره، ما باید این داده ها را در نمونه هایی با عناصر ورودی و خروجی ساختار دهیم. یک مدل شبکه عصبی حافظه طولانی کوتاه مدت به زمینه کافی برای یادگیری نگاشت از یک دنباله ورودی به یک مقدار خروجی نیاز دارد. شبکه عصبی حافظه طولانی کوتاه مدت ها می توانند سری های زمانی ورودی موازی را به عنوان متغیرها یا ویژگی های جداگانه پشتیبانی کنند. بنابراین، ما باید داده ها را به نمونه هایی تقسیم کنیم تا ترتیب مشاهدات را در دنباله های ورودی حفظ کنیم. ما می توانیم ببینیم که در تبدیل سری های زمانی به نمونه های ورودی/خروجی برای آموزش مدل، باید برخی از مقادیر را از سری های زمانی خروجی که در گام های زمانی قبلی مقادیری در سری های زمانی ورودی نداریم، کنار بگذاریم. به نوبه خود، انتخاب اندازه تعداد گام های زمانی ورودی تأثیر مهمی بر میزان استفاده از داده های آموزشی خواهد داشت. همچنین تفکیک داده ها به نمونه های ورودی و خروجی دقیقاً مشابه مدل شبکه عصبی پیچشی است.

همانند شبکه پیچشی مسئله سری زمانی چند متغیره حالتی است که چندین سری زمانی موازی وجود دارد و باید برای هر یک مقداری پیش بینی شود. ممکن است بخواهیم مقدار هر یک از سه سری زمانی را برای مرحله زمانی بعدی پیش بینی کنیم که ممکن است به عنوان پیش بینی چند متغیره نامیده شود. ما میتوانیم از یکی از انواع شبکه عصبی حافظه طولانی کوتاه مدت مثل شبکه عصبی حافظه طولانی کوتاه مدت انباشته استفاده کنیم که در آن تعداد مراحل زمانی و سری های موازی (ویژگی ها) برای لایه ورودی مدل مشخص شده است. تعداد سری های موازی نیز در تعیین تعداد مقادیر برای پیش بینی توسط مدل در لایه خروجی استفاده می شود.

```
# define model
model = Sequential()
model.add(LSTM(100, activation='relu', return_sequences=True, input_shape=(n_steps, n_features)))
model.add(LSTM(100, activation='relu'))
model.add(Dense(n_features))
model.compile(optimizer='adam', loss='mse')
```

شکل (۲۹): تعریف یک LSTM انباشته با ۱۰۰ واحد

که در نهایت پس از آموزش و دادن اولین نمونه از داده ها برای پیش بینی انتظار داریم مدل تخمین نزدیکی را برآورد کند.

```
# fit model
model.fit(X, y, epochs=400, verbose=0)
# demonstrate prediction
x_input = array([[70,75,145], [80,85,165], [90,95,185]])
x_input = x_input.reshape((1, n_steps, n_features))
yhat = model.predict(x_input, verbose=0)
```

شکل (۳۰): نمونه داده های پردازش شده برای دیتای خوردو

در بخش های قبل دیدیم که چگونه مدل ها شبکه عصبی حافظه طولانی کوتاه مدت و شبکه عصبی پیچشی برای هر دو سری تک و چند متغیره پیاده سازی شدند، و لکن پیاده سازی بقیه مدل ها نیز دقیقاً مثل شبکه عصبی حافظه طولانی کوتاه مدت است با این تفاوت که هنگام تعریف هر کدام فقط نحوه تعریف مدل ها تغییر خواهد کرد. در حالت کلی یک روش یکسان برای تفکیک داده ها برای هر دو سری تک و چند متغیره پیاده شده و در هر پیش بینی این مدل است که تغییر میکند.

در این مطالعه علاوه بر مدل های نوین که به صورت تکی برای پیش بینی سری های زمانی مورد استفاده قرار میگیرد از ترکیب آنها با عنوان یادگیری تجمعی نیز برای پیش بینی بهره گرفته شده است. نحوه ترکیب مدل ها به اینصورت است که از بین مدل هایی که دارای کمترین خطا هنگام ارزیابی هستند، بر اساس انتخاب کاربر تعدادی از آنها برای ترکیب

مشخص می شوند که در نهایت میانگین آنها محاسبه شده و به جمع بقیه مدل ها برای مقایسه افزوده میشود و همچنین معیارهای ارزیابی برای آنها نیز مشخص میشود.

۷-۳- معیارهای ارزیابی مدل ها

برای ارزیابی مدل ها از معیار های میانگین مطلق خطا^۱، میانگین مربع خطا^۲، ریشه میانگین مربع خطا میانگین^۳، درصد مطلق خطا^۴ و مربع آر^۵ استفاده شده است.

میانگین خطای مطلق یک معیار معروف برای مسائل رگرسیون است. و واحدهای خطا با واحدهای متغیر هدف مطابق هستند. مثلاً اگر متغیر هدف بر حسب دلار امریکا باشد، خطای آن نیز بر حسب دلار امریکا است. میانگین خطای مطلق، قدر مطلق تفاوت بین مقادیر پیش بینی شده و واقعی را اندازه می گیرد و به صورت زیر محاسبه می شود که y مقدار واقعی، y_h مقدار پیش بینی شده و n تعداد مشاهدات در داده را مشخص می کند.

$$MAE = \frac{1}{n} \sum_{k=1}^n y_k - \hat{y}_k$$

این معیار برای درک این که چقدر پیش بینی ها از مقادیر واقعی دور هستند یک معیار کاملاً قابل تفسیر است. علاوه بر این، نسبت به داده های پرت مقاوم است زیرا خطاهای بزرگ را با مربع کردنشان، بزرگ نمی کند. به طور خاص برای جاهایی که خطاهای بزرگ به طور قابل ملاحظه ای از خطاهای کوچک مهم تر نیستند، و همچنین زمانی که هدف، ارزیابی عملکرد یک مدل رگرسیون باشد به طوری که وزن های مساوی برای همه ی خطاها و صرف نظر از دامنه ی آن ها باشد، میانگین خطای مطلق یک معیار مفید است.

میانگین مربع خطا اغلب زمانی استفاده می شود که هدف جریمه بیشتر خطاهای بزرگتر نسبت به خطاهای کوچکتر باشد. متوسط مربع خطا، متوسط مربع تفاوت میان مقادیر واقعی و پیش بینی شده را اندازه می گیرد و مانند زیر محاسبه می شود:

¹ Mean Absolute Error

² Mean Square Error

³ Root Mean Square Error

⁴ Mean Absolute Percentage Error

⁵ R Square

$$MSE = \frac{1}{n} \sum_{k=1}^n (y_k - \hat{y}_k)^2$$

معمولا این معیار زمانی به کار می رود که هدف، تاکید داشتن بر خطاهای بزرگ تر است چرا که تفاوت مقادیر واقعی و پیش بینی شده به توان ۲ می رسد. برای روشن تر شدن موضوع، به مقادیر واقعی و پیش بینی شده در زیر نگاه کنید و رشد سریع مربع خطا با افزایش انحراف پیش بینی ها را ببینید. در مقایسه با خطای مطلق که با افزایش انحراف به طور خطی افزایش می یافت، مربع خطا به طور خیر خطی و خیلی سریع تر افزایش می یابد، زیرا وزن بیشتری بر خطاهای بزرگ تر اعمال می کند. از میانگین مربع خطا می توان برای پیش بینی بورس با هدف حداقل کردن خطای کل پیش بینی استفاده کرد. در این مواقع، اهمیت قابل تفسیر بودن به اندازه ی صحت^۱ نیست. علاوه بر این، در اینجا جبران خطاهای بزرگ تر بحرانی تر است چرا که غالبا می تواند منجر به تلفات مالی قابل ملاحظه ای شود.

متوسط ریشه ی مربع خطا مانند ریشه ی مربع خطای یک معیار معروف برای زمانی است که هدف جریمه خطای بزرگ تر نسبت به خطای کوچکتر است. علاوه بر این، یک معیار شهودی تر هم هست زیرا واحد آن همانند واحد متغیر هدف است. به عبارت دیگر، اگر متغیر هدف دلار آمریکا باشد، واحد متوسط ریشه ی مربع خطا هم دلار آمریکاست. متوسط ریشه ی مربع خطا، مربع ریشه ی متوسط مربع تفاوت بین مقادیر واقعی و پیش بینی شده را اندازه می گیرد. به زبان ساده تر مربع ریشه ی مربع خطا است و مانند زیر محاسبه می شود:

$$RMSE = \sqrt{\frac{1}{n} \sum_{k=1}^n (y_k - \hat{y}_k)^2}$$

معیار مربع R یا R^۲ نشان می دهد که چقدر یک مدل رگرسیون با داده مطابقت دارد. مربع R به ضریب معین نیز معروف است و میزان واریانس در متغیر هدف که با پیش گو توضیح داده می شود را نشان می دهد. مربع R به صورت زیر محاسبه می شود:

$$R^2 = 1 - SSR/SST$$

SSR مجموع مربع ماقی مانده، SST مجموع کل مربعات و $\bar{y}$ مقدار متوسط نمونه است. بازه ی این معیار از ۰ تا ۱ است که ۰ نشان می دهد مدل، هیچ واریانسی در متغیر(وابسته) هدف ندارد و ۱ نشان می دهد که مدل تمام واریانسش را توضیح می دهد. پس می توانیم نتیجه بگیریم که هرچه معیار R^۲ بزرگتر باشد مدل با داده ی تحت بررسی مطابقت

¹ Accuracy

بیشتری دارد. با استفاده از نمونه داده بالا، نمره R^2 در واقع مقدار NaN می شود زیرا مقادیر واقعی مان ثابت هستند و SST را صفر می کند. ناگفته نماند که در عمل، ممکن است R^2 منفی شود. این اتفاق زمانی می افتد که مدل بدتر از یک خط افقی ساده (میانگین متغیر هدف) عمل کند. به عبارت دیگر یعنی پیش بینی های مدل حتی بدتر از میانگین متغیر هدف به عنوان یک پیش بینی برای همه ی مشاهدات باشد.

متوسط درصد خطای مطلق اغلب برای اندازه گیری صحت یک مدل پیش گو مورد استفاده قرار می گیرد. متوسط درصد خطای مطلق، متوسط درصد مطلق تفاوت میان مقادیر واقعی و مقادیر پیش بینی شده را اندازه می گیرد و به صورت زیر محاسبه می شود:

$$MAPE = \frac{1}{n} \sum_{k=1}^n |y_k - \hat{y}_k| / y_k$$

خروجی این معیار غیر منفی است. صفر بهترین مقدار ممکن است و نشان می دهد که مدل بهترین پیش بینی را بدون هیچ خطایی انجام می دهد.

برای ارزیابی مدل رگرسیونی خود از چند معیار استفاده کنید زیرا هر معیار نقاط ضعف و قوت خود را دارد. با این رویکرد، نمای کلی تری از عملکرد مدل از نظر دقت، مقاوم بودن و ثبات خواهید داشت. اگر واحد معیار خطا با متغیر هدف یکسان باشد، نمره ی میانگین خطای مطلق و متوسط ریشه ی مربع خطا را باید مد نظر قرار دهید. اما متوسط ریشه ی مربع خطا و ریشه ی مربع خطا در مقایسه با ی میانگین خطای مطلق نسبت به داده های پرت حساس تر هستند. معیار R^2 برای ارزیابی مطابقت کلی مدل با داده های تحت بررسی مناسب است اما هیچ اطلاعاتی در مورد پیش بینی های تکی در اختیار ما قرار نمی دهد. در آخر، MATE معیاری است که به راحتی قابل تفسیر است و بیشتر برای مسائل پیش بینی استفاده می شود زیرا شاخصی است که نشان می دهد چند درصد از پیش بینی ها اشتباه است. تصمیم گیری در مورد اینکه کدام معیار(ها) برای ارزیابی یک مساله رگرسیون باید انتخاب شوند به فاکتورهای زیادی بستگی دارند. باید ببینیم آیا جریمه خطای بزرگتر نسبت به خطای کوچکتر مساله ی ماست یا موضوع قابل تفسیر بودن معیار برای کاربر و مدیر.

فصل چهارم: نتایج و بحث

۴-۱- مقدمه

برای هر کدام از دیتاست های دلار، خودرو، فناوری، نفت و مسکن و برای هر کدام از قیمت های باز، بسته، کمترین و بیشترین و برای هر کدام از سری های تک و چند متغیره از مدل های ذکر شده در بخش قبل، برای یادگیری و پیش بینی استفاده شده است، که به طور مثال نماد دلار-بسته-چندمتغیره-پیچشی^۱ یک پیش بینی برای سری چند متغیره روی کمترین قیمت برای داده های دلار با مدل شبکه عصبی پیچشی است. همچنین برای هر دیتاست و برای هر کدام از قیمت ها معیارهای ارزیابی برای همه ی مدل های مذکور محاسبه شده است که به طور مثال نماد دلار-بسته-پیچشی-میانگین خطای مطلق^۲ نشانده ی میانگین مطلق خطا برای مدل شبکه عصبی پیچشی است که روی کمترین قیمت سری زمانی چند متغیره برای داده های دلار است. کل فرایند پیاده سازی و اجرای نرم افزار روی سیستم عامل ویندوز ۱۱ با سخت افزار به نسبت بالارده با مشخصات ۱۶ گیگابایت رم نسل DDR5، اس اس دی نسل ۴، پردازنده HX۱۳۶۵۰ Vi با ۱۴ هسته و ۲۰ ترد و گرافیک Nvidia Geforce RTX 4050 laptop 6GB VRAM آموزش، کامپایل و پیش بینی شده است.

۴-۲- شروع پیش بینی و تعامل با کاربر

فرمی که با کاربر برای پیش بینی در تعامل است به صورت زیر میباشد، در این فرم کاربر می تواند سری های مد نظر خود، داده های مربوطه^۳ برای انجام پیش بینی، قیمت هایی^۴ که مد نظر دارد، مدل هایی^۵ که می خواهد با آن ها عملیات پیش بینی را انجام دهد، متریک هایی اندازه گیری^۶ و ارزیابی مدل ها، تعداد مراحل زمانی^۷، تعداد دوره ها^۸، تعداد داده های آزمایشی^۹، اندازه دسته ای^{۱۰}، اندازه حذف داده ها^{۱۱}، تعداد برترین مدل ها که دارای کمترین خطا می باشند^{۱۲} را برای اجرای یادگیری تجمیعی انتخاب نماید، همچنین می تواند پیش بینی ترکیب برترین مدل ها را نیز انتخاب کرده که به عنوان مثال مدل تجمیعی پیچشی-کوتاه مدت-واحد بازگشتی^{۱۳} را در حالت های مختلف مثل پیچشی-کوتاه مدت^{۱۴} و کوتاه مدت-واحد

¹ Dollar-Close-Multivariate-CNN

² Dollar-Close-M-CNN-MAE

³ Datasets

⁴ Prices

⁵ Models

⁶ Evaluation Metrics

⁷ Number of Timesteps

⁸ Epochs

⁹ Test size

¹⁰ Batch size

¹¹ Dropout rate

¹² Number of Top models to Ensemble

¹³ CNN-LSTM-GRU

¹⁴ CNN-LSTM

بازگشتی^۱ پیش بینی و مشاهده نماید. به علاوه میتواند تعداد روزایی از آینده^۲ را مشخص کند که داده ای از آنها برای ارزیابی وجود ندارد و مدل باید برحسب یادگیری خود از گذشته آنها را پیش بینی کند. همچنین قابل ذکر است که همه نمودارهایی که برای پیش بینی داده ها رسم شده اند در محور افقی خود تاریخ میلادی و در محور عمودی قیمت آن سهام یا داده مربوطه را بر حسب ریال نمایش میدهند. برای تفکیک پیش بینی هر مدل از رنگ های متفاوت و برچسب های مربوط به آن در بالای نمودار ها استفاده شده است.

Prediction Properties

Choice Series ...	Choice Datasets ...	Choice Prices ...	Choice Models ...	Choice Metrics ...	Choice Date Range to Predict
☐ univariate	☐ Dollar	☐ <CLOSE>	☐ CNN	☐ MAE	2014-01-07 ~ 2022-05-16
☐ multivariate	☐ Home	☐ <HIGH>	☐ LSTM	☐ MSE	Number of Time Steps
	☐ Oil	☐ <OPEN>	☐ B_LSTM	☐ RMSE	3
	☐ Car	☐ <LOW>	☐ GRU	☐ MAPE	Number of Epochs
	☐ Tech		☐ B_GRU	☐ R2	100
			☐ ANN		Batch Size
			☐ B_ANN		32
			☐ RNN		Test Data Percentage
			☐ B_RNN		20
					Model Dropout Rate Percentage
					20
					Number of future days to predict
					120
					Number of Top Models To Ensemble
					0
					☐ Apply Combinations to Top Models

Predict


شکل (۳۱): فرم ارتباط با کاربر برای انجام عمل پیش بینی

^۱ LSTM-GRU


^۲ Number of future days to predict

در پیش بینی های بخش های زیر برای هر کدام از داده، هر نمودار شامل قیمت واقعی آن سهم که رنگ و برجستگی مشخصی دارد و قیمت های پیش بینی شده توسط مدل های مختلف می شود که به ما کمک میکند در بازه ۹ ساله ای که برای پیش بینی در نظر گرفتیم بتوانیم نحوه عملکرد مدل ها را به صورت بصری بررسی کنیم، که برای بررسی دقیق تر در انتهای این بخش همه مدل ها توسط معیار خاص ارزیابی خواهند شد. پس از اتمام بازه ۹ ساله با توجه به تعداد روزهایی که برای پیش بینی در آینده مشخص میشود، ادامه ی نمودار برای هر مدل نشان دهنده پیش بینی آن خواهد بود.

کاربر در پیش بینی سری های زمانی تک متغیره می تواند برای هر کدام از داده های موجود پیش بینی خود را انجام داده و نتایج رو مشاهده و ارزیابی کند. همانطور که در فرم میبینیم پیش بینی روی سری تک متغیره، قیمت بسته تمام داده ها از سال ۲۰۱۴ تا ۲۰۲۲ روی تمام مدل ها با ۳ مرحله زمانی، ۱۰۰ دوره، ۳۲ دسته ای، ۲۰ درصد تفکیک برای داده های آزمایشی، حذف ۲۰ درصدی داده ها در طول یادگیری انجام خواهد شد. همچنین ۱۲۰ روز آینده نیز پس از بازه ای که مشخص شده است توسط هر کدام از مدل های انتخابی پیش بینی می شود. پس از اینکه کاربر روی دکمه پیش بینی در فرم کلیک کرد برنامه شروع به اجرا کرده و مدل مربوطه را آموزش میدهد تا در نهایت نتیجه را روی داده های ورودی به برنامه تحویل دهد. همچنین ۲ نمونه از دیتاست های فناوری و نفت را روی همه مدل های قابل پیاده سازی در سری های زمانی تک متغیره در زیر قابل نمایش هستند که نام هر مدل از چند بخش تشکیل شده که به عنوان مثال U-B-GRU-Predict Price نشان دهنده قیمت پیش بینی شده روی سری زمانی چند متغیره برای مدل GRU دوطرفه میباشد. عناوین نمودار هم Tech-<Close> prices نشان دهنده ی قیمت نزدیک دیتاست سهام شرکت فناوری میباشد. منحنی Actual price نیز قیمت اصلی آن سهم را نمایش میدهد که در برنامه میتوان با محو کردن دیگر منحنی ها و نمایش دادن قیمت اصلی آن سهم و قیمت پیش بینی شده یکی از مدل ها، یک مقایسه کلی روی آن سهم انجام داد.




شکل (۳۲): نتایج پیش بینی و ارزیابی روی قیمت بسته شده های سهام شرکت فناوری با اجرای تمام مدل ها



شکل (۳۳): نتایج پیش بینی و ارزیابی روی قیمت بسته شده های سهام نفت با اجرای تمام مدل ها


Dollar-<CLOSE> Prices



شکل (۳۴): نتایج پیش بینی و ارزیابی روی قیمت بسته شده های دلار با اجرای تمام مدل ها


برای پیش بینی سری های زمانی چند متغیره نیز کاربر می تواند برای هر کدام از داده های موجود پیش بینی خود را انجام داده و نتایج رو مشاهده و ارزیابی کند. همانطور که در فرم میبینیم پیش بینی روی سری چند متغیره، قیمت بسته تمام داده ها از سال ۲۰۱۴ تا ۲۰۲۲ روی تمام مدل ها با ۳ مرحله زمانی، ۱۰۰ دوره، ۳۲ دسته ای، ۲۰ درصد تفکیک برای داده های آزمایشی، حذف ۲۰ درصدی داده ها در طول یادگیری انجام خواهد شد. همچنین ۱۲۰ روز آینده نیز پس از بازه ای که مشخص شده است توسط هر کدام از مدل های انتخابی پیش بینی می شود. برای این پیش بینی نیز مثل مورد قبلی روی ۲ تا از دیتاست های تصادفی مثل خودرو و مسکن صورت گرفته که نتایج روی نمودار قابل مشاهده میباشد.

Car-<CLOSE> Prices




شکل (۳۵): نتایج پیش بینی و ارزیابی روی قیمت بسته شده های سهام الکتریک خودرو با اجرای تمام مدل ها

Home-<CLOSE> Prices



شکل (۳۶): نتایج پیش بینی و ارزیابی روی قیمت بسته شده های سهام مسکن با اجرای تمام مدل ها


Dollar-<CLOSE> Prices



شکل (۳۷): نتایج پیش بینی و ارزیابی روی قیمت بسته شده های دلار با اجرای تمام مدل ها


در این برنامه یه ویژگی دیگری برای ترکیب بهترین مدل ها پیاده شده است. به این صورت که پس از اجرای برنامه روی مدل ها و مقایسه خروجی هر کدام برنامه ۳ تا از بهترین مدل ها را برگزیده و باهم ترکیب میکند. ترکیب کردن همان میانگین گرفتن نتیجه ی بهترین مدل ها میباشد. کاربر برای پیش بینی سری های زمانی تک متغیره می تواند با انتخاب ترکیب ۳ تا از برترین مدل ها برای هر کدام از داده های موجود پیش بینی خود را انجام داده و نتایج رو مشاهده و ارزیابی کند. همانطور که در فرم میبینیم پیش بینی روی سری تک متغیره، قیمت بسته شده تمام داده ها از سال ۲۰۱۴ تا ۲۰۲۲ روی تمام مدل ها با ۳ مرحله زمانی، ۱۰۰ دوره، ۳۲ دسته ای، ۲۰ درصد تفکیک برای داده های آزمایشی، حذف ۲۰ درصدی داده ها در طول یادگیری انجام خواهد شد. نام محنی های ترکیبی در شکل به عنوان مثال به صورت U-CNN-U-B-GRU-Ensembled-Predict Price است که نشان دهنده ی قیمت پیش بینی ترکیب شبکه عصبی پیچشی تک متغیره با یک GRU دوطرفه تک متغیره میباشد. در شکل های زیر نتایج روی دو نمونه از دیتاست ها قابل مشاهده است.

Home-<CLOSE> Prices



شکل (۳۸): نتایج پیش بینی و ارزیابی روی قیمت بسته شده های سهام مسکن با اجرای تمام مدل ها


Oil-<CLOSE> Prices




شکل (۳۹): نتایج پیش بینی و ارزیابی روی قیمت بسته شده های سهام نفت با اجرای تمام مدل ها

کاربر در یک پیش بینی دیگر نیز می تواند فقط روی سری چند متغیره و با انتخاب ترکیب ۳ تا از برترین مدل ها برای هر کدام از داده های موجود پیش بینی خود را انجام داده و نتایج رو مشاهده و ارزیابی کند. همانطور که در فرم میبینیم پیش بینی روی سری چند متغیره، قیمت بسته شده داده ها از سال ۲۰۱۴ تا ۲۰۲۲ روی تمام مدل ها با ۳ مرحله زمانی، ۱۰۰ دوره، ۳۲ دسته ای، ۲۰ درصد تفکیک برای داده های آزمایشی، حذف ۲۰ درصدی داده ها در طول یادگیری انجام خواهد شد.

Car-<CLOSE> Prices




شکل (۴۰): نتایج پیش بینی و ارزیابی روی قیمت بسته شده داده های سهام الکتریک خودرو با اجرای تمام مدل ها



شکل (۴۱): نتایج پیش بینی و ارزیابی روی قیمت بسته شده های سهام مسکن با اجرای تمام مدل ها


برای مقایسه تمام مدل های مذکور کاربر می تواند برای هر دو سری تک و چند متغیره و برای هر کدام از داده های موجود پیش بینی خود را انجام داده و نتایج رو مشاهده و ارزیابی کند. همانطور که در فرم میبینیم پیش بینی روی هر دو سری تک و چند متغیره، قیمت بسته تمام داده ها از سال ۲۰۱۴ تا ۲۰۲۲ روی تمام مدل ها با ۳ مرحله زمانی، ۱۰۰ دوره، ۳۲ دسته ای، ۲۰ درصد تفکیک برای داده های آزمایشی، حذف ۲۰ درصدی داده ها در طول یادگیری انجام خواهد شد. همچنین ۱۲۰ روز آینده نیز پس از بازه ای که مشخص شده است توسط هر کدام از مدل های انتخابی پیش بینی می شود.

Car-<CLOSE> Prices




شکل (۴۲): نتایج پیش بینی و ارزیابی روی قیمت بسته شده های سهام الکتریک خودرو با اجرای تمام مدل ها

Home-<CLOSE> Prices



شکل (۴۳): نتایج پیش بینی و ارزیابی روی قیمت بسته شده های سهام مسکن با اجرای تمام مدل ها


Dollar-<CLOSE> Prices



شکل (۴۴): نتایج پیش بینی و ارزیابی روی قیمت بسته شده های دلار با اجرای تمام مدل ها


در نهایت برای مقایسه مدل های ترکیبی روی تمام مدل ها کاربر می تواند برای هر دو سری تک و چند متغیره و با انتخاب ۳ تا از برترین مدل ها برای هر کدام از داده های موجود پیش بینی خود را انجام داده و نتایج رو مشاهده و ارزیابی کند. همانطور که در فرم میبینیم پیش بینی روی هر دو سری تک و چند متغیره، قیمت بسته تمام داده ها از سال ۲۰۱۴ تا ۲۰۲۲ روی تمام مدل ها با ۳ مرحله زمانی، ۱۰۰ دوره، ۳۲ دسته ای، ۲۰ درصد تفکیک برای داده های آزمایشی، حذف ۲۰ درصدی داده ها در طول یادگیری انجام خواهد شد.

Oil-<CLOSE> Prices



شکل (۴۵): نتایج پیش بینی و ارزیابی روی قیمت بسته شده های سهام نفت با اجرای تمام مدل ها

Tech-<CLOSE> Prices




شکل (۴۶): نتایج پیش بینی و ارزیابی روی قیمت بسته شده های سهام شرکت فناوری با اجرای تمام مدل ها

۳-۴- نتایج ارزیابی مدل ها

در این بخش نتایج ارزیابی همه مدل ها روی هردو سری تک و چند متغیره مشاهده می شود. برای ارزیابی نیز با توجه به زیاد بودن مدل ها و داده ها، فقط از معیار میانگین مطلق خطا برای ارزیابی استفاده شده است. همانطور که در نمودار ها مشاهده می کنیم محور عمودی نشان دهنده مدل ها و محور افقی نشان دهنده میزان خطای هر مدل میباشد. نمودار زیر خطای مربوط به داده خودرو میباشد که مدل های شبکه عصبی پیچشی تک متغیره و شبکه عصبی مصنوعی تک متغیره و شبکه عصبی بازگشتی تک متغیره به ترتیب بهترین پیش بینی و مدل واحد بازگشتی گیتی دوطرفه چند متغیره بدترین پیش بینی را کرده اند.

Car-<CLOSE>-MAE Metrics




شکل (۴۷): نتایج ارزیابی تمام مدل ها و همچنین مدل های ترکیبی روی داده های سهام الکتریک خودرو

نمودار زیر خطای مربوط به داده مسکن را نمایش میدهد و همانطور که در نمودار های پیش بینی آنها مشاهده می کنیم مدل های ترکیبی شبکه عصبی مصنوعی دوطرفه تک متغیره و شبکه عصبی مصنوعی تک متغیره و شبکه عصبی مصنوعی دوطرفه تک متغیره و ترکیب شبکه عصبی مصنوعی دوطرفه تک متغیره و شبکه عصبی مصنوعی تک متغیره و

شبکه عصبی بازگشتی دوطرفه تک متغیره به ترتیب بهترین پیش بینی و مدل م شبکه عصبی صنوعی دوطرفه چند متغیره بدترین پیش بینی را کرده اند.


Home-<CLOSE>-MAE Metrics



شکل (۴۸) : نتایج ارزیابی تمام مدل ها و همچنین مدل های ترکیبی روی داده های سهام مسکن

نمودار زیر خطای مربوط به داده نفت را نمایش میدهد و همانطور که در نمودار های پیش بینی آنها مشاهده می کنیم مدل های واحد بازگشتی گیتی دوطرفه تک متغیره و شبکه عصبی پیچشی تک متغیره و شبکه عصبی بازگشتی تک متغیره به ترتیب بهترین پیش بینی و مدل شبکه عصبی حافظه طولانی دوطرفه چند متغیره بدترین پیش بینی را کرده اند.


Oil-<CLOSE>-MAE Metrics



شکل (۴۹): نتایج ارزیابی تمام مدل ها و همچنین مدل های ترکیبی روی داده های سهام نفت

نمودار زیر خطای مربوط به داده دلار را نمایش می دهد و همانطور که در نمودار های پیش بینی آنها مشاهده می کنیم مدل های ترکیبی شبکه عصبی پیچشی و مصنوعی دوطرفه تک متغیره و ترکیبی شبکه عصبی پیچشی و شبکه عصبی بازگشتی دوطرفه تک متغیره و ترکیبی شبکه عصبی مصنوعی دوطرفه و شبکه عصبی بازگشتی دوطرفه تک متغیره به ترتیب بهترین پیش بینی و شبکه عصبی مدل حافظه طولانی چند متغیره بدترین پیش بینی را کرده اند.


Dollar-<CLOSE>-MAE Metrics



شکل (۵۰): نتایج ارزیابی تمام مدل ها و همچنین مدل های ترکیبی روی داده های دلار

نمودار زیر خطای مربوط به داده فناوری را نمایش می دهد و همانطور که در نمودار های پیش بینی آنها مشاهده می کنیم مدل های ترکیبی شبکه عصبی پیچشی و بازگشتی دوطرفه تک متغیره و ترکیبی شبکه عصبی پیچشی و شبکه عصبی حافظه طولانی دوطرفه تک متغیره و ترکیبی شبکه عصبی پیچشی و شبکه عصبی بازگشتی دوطرفه و شبکه عصبی حافظه طولانی دوطرفه تک متغیره به ترتیب بهترین پیش بینی و مدل شبکه عصبی واحد بازگشتی گیتی دوطرفه چند متغیره بدترین پیش بینی را کرده اند.

Tech-<CLOSE>-MAE Metrics



شکل (۵۱): نتایج ارزیابی تمام مدل ها و همچنین مدل های ترکیبی روی داده های سهام شرکت فناوری

برای درک عمیق تر و انجام یک مقایسه دقیق تر روی همه مدل های سری تک متغیره، میانگین مطلق خطا رو برای همه محاسبه و در جدول زیر قابل مشاهده است. هدف از این مقایسه این است که بفهمیم برای هر کدام از دیتاست ها، هر کدام از مدل ها چه عملکردی در پیش بینی داشته اند. بنابراین در جدول باید مقایسه رو به صورت ردیفی بین مدل ها انجام داد و بهترین و بدترین مدل ها که کمترین و بیشترین خطا رو داشته اند به ترتیب با رنگ های سبز و قرمز مشخص شده اند و همانطور که میبینیم شبکه عصبی پیچشی جز بهترین مدل ها هست. همانطور که قبلا هم اشاره شده حرف U برای سری تک متغیره و حرف M نیز برای سری چند متغیره بکار برده شده و واحد قیمت اعداد بر حسب ریال میباشد.

MAE	U-CNN	U-LSTM	U-B-LSTM	U-GRU	U-B-GRU	U-ANN	U-B-ANN	U-RNN	U-B-RNN
دلار	6991.89	9074.72	10550.68	12415.71	8064.98	9978.6	6501.73	23731.97	6488.12
سهام مسکن	585.59	972.81	511.08	644.83	606.27	492.36	380.81	662.43	504.12
سهام نفت	1536.61	2328.01	2996.74	1865.96	1336.39	1648.96	3795.28	1642.74	2246.78
سهام الکتریک خودرو	1137.6	2606.45	2362.78	3375.77	1508.96	1197.39	2464.05	1437.79	1665.61
سهام شرکت فناوری	3828.98	4858.63	4026.38	4032.38	4141.49	4461.53	8673.15	4241.55	3409.14

در جدول نیز یک مقایسه کلی برای مدل های سری چند متغیره میبینیم و شبکه عصبی بازگشتی دوطرفه جز بهترین مدل ها هست.

MAE	M-CNN	M-LSTM	M-B-LSTM	M-GRU	M-B-GRU	M-ANN	M-B-ANN	M-RNN	M-B-RNN
دلار	8917.65	89819.64	76771.05	78759.44	71623.99	35573.63	7581.4	81327.12	35297.5
سهام مسکن	1254.64	777.1	921.9	1122.25	701.11	531.71	1417.37	1098.72	677.3
سهام نفت	3697.93	9315.53	9598.18	7350.65	8011.78	3503.18	4879.68	8763.97	3054.21
سهام الکتریک خودرو	2047.4	3956.57	4289.57	4252.06	4926.36	2232.85	3104	4599.2	1993.39
سهام شرکت فناوری	4376.86	14118.33	16070.4	17148.97	11050.02	6643.11	5975.35	13723.12	5794.67

بنابراین ما در ۳ گام به صورت نموداری، ستونی و جدولی تونستیم همه مدل ها را روی دیتاست هایی که داشتیم مقایسه و شکل رفتار و دید کلی از پیش بینی هر کدام از مدل ها داشته و نسبت به داده های متفاوت، رفتار متفاوت از مدل هارو ببینیم و بهترین و بدترین مدل ها رو در هر مورد بررسی کنیم.

فصل پنجم: نتیجه گیری و پیشنهادها

در این پژوهش، نحوه توسعه مجموعه ای از مدل های یادگیری ماشین برای طیف وسیعی از مشکلات پیش بینی سری های زمانی استاندارد را کشف کردیم و به طور خاص، یاد گرفتیم:

۱. نحوه توسعه مدل ها برای پیش بینی سری های زمانی تک متغیره.

۲. نحوه توسعه مدل ها برای پیش بینی سری های زمانی چند متغیره.

همانطور که دیدیم پیش بینی بازارهای سهام در ایران از اهمیت بالایی برخوردار است و باتوجه به این که هدف اصلی استفاده از سری های زمانی چند متغیره بود قصد داشتیم تاثیر بازارهای مالی را روی همدیگر را مشاهده و ارزیابی کنیم و همانگونه که در نمودار های هر کدام از بازارها مشاهده شد نوسانات قیمت به شکل های گوناگون وابسته به یکدیگر بود و با کاهش یا افزایش یکی دیگری نیز از آن الگو میگرفت.

بر اساس بررسی های انجام شده، مدل های یادگیری ماشین می توانند در پیش بینی سری های زمانی تک و چند متغیره روی داده های بورس شرکت های مختلف، عملکرد خوبی داشته باشند. با این حال، عوامل مختلفی وجود دارند که می توانند بر دقت پیش بینی این مدل ها تأثیر بگذارند. برخی از عوامل تأثیرگذار بر دقت پیش بینی مدل های یادگیری ماشین در پیش بینی سری های زمانی تک و چند متغیره روی داده های بورس شرکت های مختلف عبارتند از:

۱. کیفیت داده ها: کیفیت داده های مورد استفاده برای آموزش مدل، تأثیر مستقیمی بر دقت پیش بینی آن دارد. داده های ناقص، نادرست یا نامعتبر می توانند دقت پیش بینی را کاهش دهند.

۲. طول دوره زمانی: طول دوره زمانی مورد استفاده برای آموزش مدل، تأثیر زیادی بر دقت پیش بینی آن دارد. مدل های آموزش دیده با داده های دوره زمانی طولانی تر، معمولاً دقت پیش بینی بهتری دارند.

۳. نوع مدل: نوع مدل یادگیری ماشین مورد استفاده، تأثیر زیادی بر دقت پیش بینی آن دارد. مدل های یادگیری عمیق معمولاً دقت پیش بینی بهتری نسبت به مدل های یادگیری آماری دارند.

۴. پارامترهای مدل: پارامترهای مدل یادگیری ماشین، تأثیر زیادی بر دقت پیش بینی آن دارند. تنظیم صحیح پارامترهای مدل، می تواند دقت پیش بینی را بهبود بخشد.

برای بهبود دقت پیش بینی مدل های یادگیری ماشین در پیش بینی سری های زمانی تک و چند متغیره روی داده های بورس شرکت های مختلف، می توان موارد زیر را پیشنهاد کرد:

۱. استفاده از داده های با کیفیت: استفاده از داده های با کیفیت، تأثیر زیادی بر دقت پیش بینی دارد. داده های مورد استفاده باید کامل، صحیح و نامعتبر باشند.
 ۲. استفاده از دوره زمانی طولانی: استفاده از دوره زمانی طولانی برای آموزش مدل، می تواند دقت پیش بینی را بهبود بخشد.
 ۳. استفاده از مدل های یادگیری عمیق: مدل های یادگیری عمیق معمولاً دقت پیش بینی بهتری نسبت به مدل های یادگیری آماری دارند.
 ۴. تنظیم صحیح پارامترهای مدل: تنظیم صحیح پارامترهای مدل، می تواند دقت پیش بینی را بهبود بخشد.
 ۵. علاوه بر موارد ذکر شده، می توان از روش های زیر نیز برای بهبود دقت پیش بینی مدل های یادگیری ماشین استفاده کرد:
 ۶. استفاده از تکنیک های یادگیری ترکیبی: تکنیک های یادگیری ترکیبی، می توانند دقت پیش بینی را بهبود بخشند.
 ۷. استفاده از روش های تصحیح خطای پیش بینی: روش های تصحیح خطای پیش بینی، می توانند دقت پیش بینی را بهبود بخشند.
 ۸. استفاده از داده های بیشتر و متنوع تر: داده های بیشتر، می تواند به مدل های یادگیری ماشین کمک کند تا الگوهای تکراری بیشتری را در داده ها شناسایی کنند. این الگوها می توانند به مدل ها کمک کنند تا روند قیمت سهام شرکت ها را در آینده پیش بینی کنند. داده های متنوع تر نیز می تواند به مدل ها کمک کند تا رفتار سری زمانی را در شرایط مختلف بهتر درک کنند.
 ۹. استفاده از الگوریتم های یادگیری ماشین پیشرفته تر: الگوریتم های یادگیری ماشین پیشرفته تر، می توانند به مدل ها کمک کنند تا الگوهای پیچیده تر را در داده ها شناسایی کنند. این الگوریتم ها می توانند به مدل ها کمک کنند تا پیش بینی دقیق تری در مورد سری های زمانی غیرخطی ارائه دهند.
 ۱۰. استفاده از روش های انتخاب ویژگی: روش های انتخاب ویژگی می توانند به مدل ها کمک کنند تا ویژگی های مهم و مرتبط با سری زمانی را شناسایی کنند. این ویژگی ها می توانند به مدل ها کمک کنند تا عملکرد بهتری در پیش بینی سری زمانی داشته باشند.
- با توجه به اهمیت پیش بینی سری های زمانی در بازارهای مالی، استفاده از مدل های یادگیری ماشین می تواند ابزاری ارزشمند برای سرمایه گذاران و شرکت های فعال در بازار بورس باشد. با استفاده از مدل های یادگیری ماشین، می توان با دقت بیشتری روند قیمت سهام را پیش بینی کرد و تصمیمات بهتری در زمینه سرمایه گذاری گرفت.

البته، باید توجه داشت که هیچ مدل پیش بینی ای نمی تواند با ۱۰۰٪ دقت، آینده را پیش بینی کند. با این حال، مدل های یادگیری ماشین می توانند ابزار ارزشمندی برای سرمایه گذاران و سایر فعالان بازار بورس باشند. این مدل ها می توانند به سرمایه گذاران کمک کنند تا تصمیمات آگاهانه تری در مورد سرمایه گذاری های خود بگیرند.

هم چنین در تحقیقات آینده میتوان روی سری های تک و چند متغیره با پیش بینی چند مرحله ای^۱ تمرکز کرد و از مدل ها جدید مثل حافظه طولانی بلند مدت پیچشی^۲ و یا مدل انکدر دیکودر^۳ که مدلی است که به طور خاص برای پیش بینی توالی خروجی با طول متغیر توسعه یافته است

¹ Multiple Parallel Input and Multi-Step Output

² ConvLSTM

³ Encoder Decoder Model

منابع و مآخذ

1. Lu, W., Li, J., Wang, J. *et al.* A CNN-BiLSTM-AM method for stock price prediction. *Neural Comput & Applic* **33**, 4741–4753 (2021). <https://doi.org/10.1007/s00521-020-05532-z>.
2. Wei Chen, Manrui Jiang, Wei-Guo Zhang, Zhensong Chen. A novel graph convolutional feature based convolutional neural network for stock trend prediction. *Information Sciences* **556**, 67-94 (2021). <https://doi.org/10.1016/j.ins.2020.12.068>.
3. Senapati, M.R., Das, S. & Mishra, S. A Novel Model for Stock Price Prediction Using Hybrid Neural Network. *J. Inst. Eng. India Ser. B* **99**, 555–563 (2018). <https://doi.org/10.1007/s40031-018-0343-7>
4. Kumar, A., Alsadoon, A., Prasad, P.W.C. *et al.* Generative adversarial network (GAN) and enhanced root mean square error (ERMSE): deep learning for stock price movement prediction. *Multimed Tools Appl* (2021). <https://doi.org/10.1007/s11042-021-11670-w>
5. Yang, F., Chen, J. & Liu, Y. Improved and optimized recurrent neural network based on PSO and its application in stock price prediction. *Soft Comput* (2021). <https://doi.org/10.1007/s00500-021-06113-5>
6. Dami, S., Esterabi, M. Predicting stock returns of Tehran exchange using LSTM neural network and feature engineering technique. *Multimed Tools Appl* **80**, 19947–19970 (2021). <https://doi.org/10.1007/s11042-021-10778-3>
7. Hongping Hu, Li Tang, Shuhua Zhang, Haiyan Wang. Predicting the direction of stock markets using optimized neural networks with Google Trends. *Neurocomputing* **285**, 2018, Pages 188-195, <https://doi.org/10.1016/j.neucom.2018.01.038>.
8. Zhao, J., Zeng, D., Liang, S. *et al.* Prediction model for stock price trend based on recurrent neural network. *J Ambient Intell Human Comput* **12**, 745–753 (2021). <https://doi.org/10.1007/s12652-020-02057-0>
9. Mukherjee, S., *et al.*: Stock market prediction using deep learning algorithms. *CAAI Trans. Intell. Technol.* 1– 13 (2021). <https://doi.org/10.1049/cit2.12059>
10. Hongfeng Xu, Lei Chai, Zhiming Luo, Shaozi Li. Stock movement prediction via gated recurrent unit network based on reinforcement learning with incorporated attention mechanisms. *Neurocomputing* **467**. 214-228 (2022). <https://doi.org/10.1016/j.neucom.2021.09.072>.
11. Shi, Y, Zheng, Y, Guo, K, Ren, X. Stock movement prediction with sentiment analysis based on deep learning networks. *Concurrency Computat Pract Exper.* 2021; 33:e6076. <https://doi.org/10.1002/cpe.6076>

12. Yu, P., Yan, X. Stock price prediction based on deep neural networks. *Neural Comput & Applic* **32**, 1609–1628 (2020). <https://doi.org/10.1007/s00521-019-04212-x>
13. Nikou, M, Mansourfar, G, Bagherzadeh, J. Stock price prediction using DEEP learning algorithm and its comparison with machine learning algorithms *Intell Sys Acc Fin Mgmt*. 2019; 26: 164– 174. <https://doi.org/10.1002/isaf.1459>.
14. He, B., Kita, E. The Application of Sequential Generative Adversarial Networks for Stock Price Prediction. *Rev Socionetwork Strat* **15**, 455–470 (2021). <https://doi.org/10.1007/s12626-021-00097-2>
15. Wu, J.MT., Li, Z., Herencsar, N. *et al.* A graph-based CNN-LSTM stock price prediction algorithm with leading indicators. *Multimedia Systems* (2021). <https://doi.org/10.1007/s00530-021-00758-w>
16. Hongli Niu, Kunliang Xu. A hybrid model combining variational mode decomposition and an attention-GRU network for stock price index forecasting[J]. *Mathematical Biosciences and Engineering*, 2020, 17(6): 7151-7166. doi: [10.3934/mbe.2020367](https://doi.org/10.3934/mbe.2020367)
17. Ayodele Ariyo Adebisi, Aderemi Oluyinka Adewumi, Charles Korede Ayo, "Comparison of ARIMA and Artificial Neural Networks Models for Stock Price Prediction", *Journal of Applied Mathematics*, vol. 2014, Article ID 614342, 7 pages, 2014. <https://doi.org/10.1155/2014/614342>
18. D. Lien Minh, A. Sadeghi-Niaraki, H. D. Huy, K. Min and H. Moon, "Deep Learning Approach for Short-Term Stock Trends Prediction Based on Two-Stream Gated Recurrent Unit Network," in *IEEE Access*, vol. 6, pp. 55392-55404, 2018, doi: [10.1109/ACCESS.2018.2868970](https://doi.org/10.1109/ACCESS.2018.2868970).
19. X. Yuan, J. Yuan, T. Jiang and Q. U. Ain, "Integrated Long-Term Stock Selection Models Based on Feature Selection and Machine Learning Algorithms for China Stock Market," in *IEEE Access*, vol. 8, pp. 22672-22685, 2020, doi: [10.1109/ACCESS.2020.2969293](https://doi.org/10.1109/ACCESS.2020.2969293).
20. Subba Rao Polamuri, Dr. Kudipudi Srinivas, Dr. A. Krishna Mohan. Multi-Model Generative Adversarial Network Hybrid Prediction Algorithm (MMGAN-HPA) for stock market prices prediction, *Journal of King Saud University - Computer and Information Sciences* ,<https://doi.org/10.1016/j.jksuci.2021.07.001>.
21. S. Kim, S. Ku, W. Chang and J. W. Song, "Predicting the Direction of US Stock Prices Using Effective Transfer Entropy and Machine Learning Techniques," in *IEEE Access*, vol. 8, pp. 111660-111682, 2020, doi: [10.1109/ACCESS.2020.3002174](https://doi.org/10.1109/ACCESS.2020.3002174).
22. Shen, J., Shafiq, M.O. Short-term stock market price trend prediction using a comprehensive deep learning system. *J Data* **7**, 66 (2020). <https://doi.org/10.1186/s40537-020-00333-6>.

23. Bruno Miranda Henrique, Vinicius Amorim Sobreiro, Herbert Kimura, Stock price prediction using support vector regression on daily and up to the minute prices, *The Journal of Finance and Data Science* **4**, (2018) ,183-201, <https://doi.org/10.1016/j.jfds.2018.04.003>.
24. S. Chen and C. Zhou, "Stock Prediction Based on Genetic Algorithm Feature Selection and Long Short-Term Memory Neural Network," in *IEEE Access*, vol. 9, pp. 9066-9072, 2021, doi: [10.1109/ACCESS.2020.3047109](https://doi.org/10.1109/ACCESS.2020.3047109).
25. Ding, G., Qin, L. Study on the prediction of stock price based on the associated network model of LSTM. *Int. J. Mach. Learn. & Cyber.* **11**, 1307–1317 (2020). <https://doi.org/10.1007/s13042-019-01041-1>.



Urmia University

**Faculty of Agriculture
Department of**

**A thesis submitted to the Graduate Studies Office in partial fulfillment of
the
requirement for the degree of Master of Science in**

Title

Stock Price Prediction

Under Supervision of Dr. Jamshid bagherzadeh

By

Mohamad reza Rezaei