

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



دانشکده مهندسی کامپیوتر

پایان نامه کارشناسی ارشد مهندسی هوش مصنوعی و رباتیکز

پیش‌بینی بازارهای مالی با استفاده از یادگیری عمیق

نگارنده: علی محمد سیاهکارزاده

استاد راهنما

دکتر مرتضی زاهدی

استاد مشاور

دکتر محسن رضوانی

شهریور ۱۴۰۰



مدیریت تحصیلات تکمیلی

باسمه تعالی

فرمهای ارزشیابی پایان نامه کارشناسی ارشد
مربوط به ورودیهای ۹۴ به بعد

شماره:

تاریخ:

ویرایش:

فرم شماره (۳) صورتجلسه نهایی دفاع از پایان نامه دوره کارشناسی ارشد

با نام و یاد خداوند متعال، ارزیابی جلسه دفاع از پایان نامه کارشناسی ارشد آقای علی محمد سیاهکارزاده با شماره دانشجویی ۹۸۰۶۹۵۴ رشته مهندسی کامپیوتر گرایش هوش مصنوعی و رباتیکز تحت عنوان پیش بینی بازارهای مالی با استفاده از یادگیری عمیق که در تاریخ ۱۴۰۰/۰۶/۱۰ با حضور هیأت محترم داوران در دانشگاه صنعتی شاهرود برگزار شد به شرح ذیل اعلام می گردد:

☒ الف) درجه عالی: نمره ۲۰-۱۹	☐ ب) درجه خیلی خوب: نمره ۱۸/۹۹-۱۸
☐ ج) درجه خوب: نمره ۱۷/۹۹-۱۶	☐ د) درجه متوسط: نمره ۱۵/۹۹-۱۴
☐ ه) کمتر از ۱۴ غیر قابل قبول و نیاز به دفاع مجدد دارد.	
نوع تحقیق: ☐ نظری ☐ عملی	

عضو هیأت داوران	نام و نام خانوادگی	مرتبه علمی	امضاء
۱- استاد راهنمای اول	مرتضی زاهدی	استادیار	
۳- استاد مشاور	محسن رضوانی	دانشیار	
۴- استاد داور اول	منصور فاتح	استادیار	
۵- استاد داور دوم	مریم خدابخش	استادیار	
۶- نماینده تحصیلات تکمیلی	محسن فرهادی	مربی	

نام و نام خانوادگی رئیس دانشکده:

تاریخ و امضاء و مهر دانشکده:



به پاس تعبیر عظیم و انسانی شان از کلمه ایثار و از خودگذشتگان

به پاس عاطفه سرشار و گرمای امید بخش وجودشان که در این سردترین روزگار ان بهترین پشتیبان است

به پاس قلب های بزرگشان که فریاد رس است و سرگردانی و ترس در پناهشان به شجاعت می گراید

و به پاس محبت های بی دریغشان که هرگز فروکش نمی کند

این مجموعه را به پدر و مادر عزیزم و استاد و تمام کسانی که مرایای نموده اند تقدیم می کنم

اکنون که بیاری پروردگار و یاری و راهنمایی اساتید بزرگ موفق به پایان این رساله شده ام و خفیه خود داشته که نهایت

ساکزاری را از تمامی عزیزانی که در این راه به من کمک کرده اند را به عل آورم:

در آغاز از اساتید بزرگ و دانشمند جناب آقای دکتر مرتضی زاهدی که راهنمایی این پایان نامه را به عهده داشته اند کمال تشکر را

دارم.

از جناب آقایان دکتر رضوانی که استاد مشاور این پایان نامه بوده اند نیز قدردانی می نمایم.

از داوران گرامی که زحمت داوری و تصحیح این پایان نامه را به عهده خواهند داشت کمال سپاس را دارم.

خالصانه از تمامی اساتید و معلمان و مدرسانی که در مقطع مختلف تحصیلی به من علم آموخته و مرا از سرچشمه دانایی سیراب

کرده اند تشکر می کنم.

علی محمد سیاهکارزاده

تیر ۱۴۰۰

اینجانب علی محمد سیاهکارزاده دانشجوی دوره کارشناسی ارشد رشته هوش مصنوعی و رباتیک دانشکده مهندسی کامپیوتر دانشگاه صنعتی شاهرود نویسنده پایان نامه پیش‌بینی بازارهای مالی با استفاده از یادگیری عمیق تحت راهنمایی دکتر مرتضی زاهدی متعهد می‌شوم.

- تحقیقات در این پایان‌نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است .
- در استفاده از نتایج پژوهشهای محققان دیگر به مرجع مورد استفاده استناد شده است .
- مطالب مندرج در پایان‌نامه تاکنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است .
- کلیه حقوق معنوی این اثر متعلق به دانشگاه صنعتی شاهرود می‌باشد و مقالات مستخرج با نام « دانشگاه صنعتی شاهرود » و یا « Shahrood University of Technology » به چاپ خواهد رسید .
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان‌نامه تأثیرگذار بوده اند در مقالات مستخرج از پایان‌نامه رعایت می‌گردد.
- در کلیه مراحل انجام این پایان‌نامه ، در مواردی که از موجود زنده (یا بافتهای آنها) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است .
- در کلیه مراحل انجام این پایان‌نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است اصل رازداری ، ضوابط و اصول اخلاق انسانی رعایت شده است .

تاریخ

امضای دانشجو

مالکیت نتایج و حق نشر

کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج ، کتاب ، برنامه های رایانه ای ، نرم افزار ها و تجهیزات ساخته شده است) متعلق به دانشگاه صنعتی شاهرود می‌باشد . این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود . استفاده از اطلاعات و نتایج موجود در پایان‌نامه بدون ذکر مرجع مجاز نمی‌باشد.

چکیده

مدل سازی و پیش‌بینی قیمت انواع سهام در بازارهای مالی به دلیل اهمیت بالا و تاثیر بسیار زیاد بر رشد اقتصادی کشورها و سازمان‌ها، از اهداف چالش برانگیز محققان، شرکت‌های سرمایه‌گذاری و بانک‌ها می‌باشد. با رشد در هوش مصنوعی و بویژه یادگیری عمیق، می‌توان وظیفه یادگیری ویژگی را به‌طور موثرتری از طریق شبکه‌های طراحی شده برای این اهداف انجام داد. در این پایان‌نامه، یک مدل از شبکه‌های عصبی با استفاده از معماری‌های CNN و LSTM و با الهام از شبکه عصبی چند فیلتری (MFNN) ارائه داده‌ایم که تفاوت عمده آن با سایر مدل‌های ارائه شده توانایی پیش‌بینی در قالب‌های زمانی کوتاه مدت می‌باشد و همچنین با بررسی روش‌های مختلف برای استخراج و تولید ویژگی، یک روش جدید، به‌طور خاص برای استخراج ویژگی در نمونه‌های سری‌زمانی مالی و پیش‌بینی روند قیمت پیشنهاد می‌کنیم. در این روش از ترکیب انواع شاخص‌ها، استراتژی‌های جدیدی تولید می‌شود که از آن در تولید ویژگی استفاده کرده‌ایم، با مقایسه دادگان پیشنهادی با سایر دادگان در شرایط یکسان شاهد افزایش دقت پیش‌بینی حداقل ۱.۸٪ و حداکثر ۶٪ بودیم. در ادامه با معرفی روشی جدید در هدف گذاری داده‌های مالی و مقایسه با سایر روش‌ها، مراحل پیش‌پردازش بر روی دادگان سری زمانی مالی را به اتمام می‌رسانیم. بعد از مقایسه روش‌های برچسب‌گذاری شاهد افزایش دقت حداقل ۱.۲۵ و حداکثر ۵ درصدی هستیم. همچنین در ادامه در مدل ارائه شده از ترکیب هر دو معماری شبکه عصبی CNN و LSTM استفاده شده است. ما روش خود را برای پیش‌بینی مهمترین و پر حجم‌ترین بازار مالی دنیا یعنی بازار تبادل ارزهای خارجی اعمال می‌کنیم. مدل پیشنهادی دقت ۷۸.۴۲٪ را ارائه می‌دهد که نسبت به بهترین عملکرد در مدل‌های معرفی شده رشد ۳ درصدی دارد.

کلمات کلیدی (۵ تا ۷ کلیدواژه): یادگیری عمیق، سری‌زمانی، بازارهای مالی، LSTM، CNN.

سیستم پیش‌بینی بازار مالی، تحلیل سری‌زمانی

فهرست مطالب

ی	فهرست جداول
ک	فهرست اشکال
۱	فصل ۱: مقدمه
۲	۱-۱ مقدمه
۴	۱-۲ بیان مسئله
۷	۱-۳ چالش‌های موجود در سیستم‌های تحلیل بازارهای مالی و راه‌کار مقابله آن
۹	۱-۴ هدف پایان‌نامه
۱۰	۱-۵ روش تحقیق
۱۰	۱-۶ نوآوری مسئله
۱۱	۱-۷ ساختار پایان‌نامه
۱۳	فصل ۲: مروری بر مفاهیم بازار تبادل ارز و کارهای انجام شده
۱۴	۲-۱ مقدمه
۱۴	۲-۲ بازار تبادل ارز و خصوصیات آن
۱۶	۲-۲-۱ پیچیدگی بازار تبادل ارز
۱۸	۲-۲-۲ تحلیل بازار تبادل ارز
۱۸	۲-۲-۳ تجزیه و تحلیل فنی
۲۰	۲-۲-۴ پیش‌بینی هزینه و روند
۲۱	۲-۳ کارهای انجام شده در پیش‌بینی سری زمانی
۲۳	۲-۳-۱ یادگیری ماشینی برای پیش‌بینی سری زمانی

۲۳	۲-۳-۲ سری زمانی در بازار تبادل ارز
۲۵	۲-۳-۳ پیش‌بینی سری زمانی
۲۹	۲-۳-۴ روش‌های رایج مورد استفاده برای پیش‌بینی بازار تبادل ارز
۳۳	۲-۳-۵ یادگیری عمیق
۳۵	۲-۴ جمع‌بندی

فصل ۳: روش پیشنهادی ۳۹

۴۰	۳-۱ مقدمه
۴۰	۳-۲ جمع‌آوری داده‌ها
۴۰	۳-۲-۱ جفت ارزهای رایج
۴۱	۳-۲-۲ شاخص‌های بازار و جمع‌آوری داده‌ها
۴۱	۳-۲-۳ ویژگی‌های استخراج شده از تجزیه و تحلیل فنی
۵۴	۳-۲-۴ آنالیز و انتخاب ویژگی
۵۹	۳-۳ تعیین هدف و برجسب داده‌ها
۵۹	۳-۳-۱ مقدمه
۶۰	۳-۳-۲ مفهوم پیپ و پیپت
۶۰	۳-۳-۳ روش هدف‌گذاری استفاده شده
۶۲	۳-۳-۴ تجزیه و تحلیل هدف پیش‌بینی
۶۵	۳-۴ دادگان آماده شده بعد از مراحل پیش‌پردازش و هدف‌گذاری
۶۸	۳-۴-۱ روش تعیین حد آستانه
۶۹	۳-۵ آموزش و انتخاب مدل برای پیش‌بینی فارکس
۶۹	۳-۵-۱ LSTM، CNN و فرآیند یادگیری
۷۶	۳-۵-۲ تنظیم ابرپارامترها و انتخاب مدل

۳-۶ جمع‌بندی ۷۷

فصل ۴ نتایج و آزمایش‌ها ۷۹

۴-۱ مقدمه ۸۰

۴-۲ تنظیمات ابرپارامترها ۸۰

۴-۳ مجموعه دادگان ۸۸

۴-۴ ارزیابی عملکرد روش پیشنهادی ۸۹

۴-۵ نتیجه‌گیری ۹۴

فصل ۵ جمع‌بندی و پیشنهادات ۹۷

۵-۱ جمع‌بندی و نتیجه‌گیری ۹۸

۵-۲ پیشنهادات برای ادامه فعالیت ۹۹

مراجع ۱۰۰

فهرست واژگان ۱۰۵

فهرست جداول

جدول ۳-۱	پنج قیمت اساسی بازار تبادل ارز	۵۰
جدول ۳-۲	شاخص های فنی مورد استفاده در این تحقیق	۵۰
جدول ۳-۳	نمونه هایی از دادگان	۵۷
جدول ۳-۴	توزیع داده ای بین کلاس های مختلف	۶۵
جدول ۳-۵	نمونه دادگان	۶۶
جدول ۳-۶	نمونه داده کلاس بندی شده	۶۹
جدول ۳-۷	نتیجه حاصل از آزمایش تنظیم لایه ها	۸۲
جدول ۳-۸	نتایج تنظیم پارامتر تعداد نرون	۸۳
جدول ۳-۹	نتایج تعیین اندازه دسته	۸۴
جدول ۳-۱۰	نتایج تعیین نرخ یادگیری	۸۵
جدول ۴-۱	ویژگی های دادگان پس از پیش پردازش های مختلف	۸۹
جدول ۴-۲	مشخصات الگوریتم های مورد استفاده	۸۹
جدول ۴-۳	نام و مشخصات مدل های بررسی شده	۹۱
جدول ۴-۴	قالب زمانی پانزده دقیقه	۹۳
جدول ۴-۵	قالب زمانی چهار ساعت	۹۳
جدول ۴-۶	قالب زمانی یک روز	۹۳

فهرست اشکال

شکل ۱-۱-۲	نرخ معاملات در بازار تبادل ارز	۱۶
شکل ۱-۳-۳	میانگین متحرک	۵۱
شکل ۲-۳-۳	واگرایی همگرایی	۵۲
شکل ۳-۳-۳	ADX	۵۲
شکل ۳-۴-۳	MACD	۵۳
شکل ۳-۵-۳	RSI	۵۳
شکل ۳-۶-۳	ایچی موکو	۵۴
شکل ۳-۷-۳	نمودار نمره‌ی ویژگی‌ها	۵۸
شکل ۳-۸-۳	توزیع داده‌ای براساس برچسب‌گذاری با روش افق زمان ثابت [۶]	۶۲
شکل ۳-۹-۳	نمودار پیش‌بینی نقطه به نقطه (Ganegedara, 2018)	۶۳
شکل ۳-۱۰-۳	مقایسه پیش‌بینی برای افق‌های زمانی متفاوت	۶۴
شکل ۳-۱۱-۳	محاسبه اختلاف قیمت برای تعیین برچسب	۶۷
شکل ۳-۱۲-۳	محاسبه حد آستانه	۶۸
شکل ۳-۱۳-۳	یک لایه tanh به عنوان ماژول تکرار در RNN استاندارد (Olah, ۲۰۱۵)	۷۱
شکل ۳-۱۴-۳	چهار لایه متقابل در یک ساختار LSTM (Olah, ۲۰۱۵)	۷۱
شکل ۳-۱۵-۳	مراحل آموزش	۷۶
شکل ۳-۱۶-۳	برای جلوگیری از حالت بیش‌برازش، در نقطه قرمز متوقف می‌شویم	۸۱
شکل ۴-۱-۳	مقایسه روش‌های پیش‌پردازش با روش پیشنهادی	۹۰
شکل ۴-۲-۳	مقایسه افق ثابت و افق متغیر	۹۰
شکل ۴-۳-۳	عملکرد انواع مدل‌ها در قالب زمانی پنج دقیقه‌ای	۹۳
شکل ۴-۴-۳	مقایسه میزان دقت مدل‌های مختلف برای انواع قالب زمانی	۹۴

فصل ۱: مقدمه

۱-۱ مقدمه

بازار مبادله ارز^۱ (فارکس) یک بازار مالی جهانی، غیرمتمرکز و بسیار روان برای مبادله ارزهای مختلف است [۱۵]. حجم معاملات بسیار بالا و تداوم آن باعث جذب سرمایه‌گذاران و بانک‌ها به دنیای فارکس شده است و هر روز سرمایه‌گذاران بیشتری از بازار سهام به بازار مبادله ارز روی می‌آورند. چراکه در مقایسه با بازار سهام، فارکس دارای سه ویژگی برجسته است که برای سرمایه‌گذاری بسیار جذاب و مفید می‌باشد [۱].

الف) فارکس یک بازار فعال ۲۴ ساعته در طول روزهای هفته در سراسر جهان می‌باشد.

در نتیجه سرمایه‌گذاران می‌توانند در هر روز از روزهای هفته که بخواهند در این بازار معامله کنند. در مقابل، معاملات منظم بورس در طول یک هفته به چند ساعت در هر روز محدود می‌شود و زمان باز و بسته شدن بورس در کشورهای مختلف متفاوت است. علاوه بر این، بازار سهام در بسیاری از کشورها محدودیت‌های خاص خود را دارد. به عنوان مثال، در چین، محدودیت‌های تجاری $T + 1$ یا $T + 2$ وجود دارد تا از حدس و گمان‌های غیر منطقی برای پیش‌بینی قیمت جلوگیری کند [۸]. یا در ایران برای سود و ضرر در یک روز محدودیت وجود دارد، مثلاً در یک روز حداکثر می‌توانید ۵ درصد سود و یا ضرر را تجربه کنید. و یا در برخی از کشورها فقط با خرید سهم می‌توان به سود رسید و از حالت نزولی یا فروش آن نمی‌توان سود کرد.

ب) به دلیل حجم قابل توجه معاملات، کنترل چنین بازار بزرگی، برای هیچ سرمایه‌گذار، گروه مالی، بانک و یا شرکت تجاری خاصی ممکن نمی‌باشد.

اهمیت این موضوع از این جنبه قابل بررسی است که به دلیل محدود بودن تعداد سهام یک شرکت، وقتی حجم زیادی از پول، برای خرید یک سهم خاص سرازیر می‌شود، ارزش این سهم بسیار تحت تاثیر قرار

^۱ Forex

خواهد گرفت، پس برخلاف بازار فارکس، باتوجه به این نکته که تعداد کل سهام در بازار بورس محدود است، هرگونه رفتار معاملاتی از یک سهامدار یا شرکت خاص می‌تواند تأثیر قابل توجهی بر قیمت سهم بگذارد.

ج) سرمایه‌گذاران می‌توانند در بازارهای صعودی یا نزولی در بازار تبادل ارز سود کسب کنند.

یعنی سرمایه‌گذاران می‌توانند به‌طور جداگانه از "بالا رفتن" یا "پایین آمدن" نمودار قیمت درآمد کسب کنند. البته لازم بذکر است برای برخی از کشورها این مورد به‌صورت "کوتاه مدت" در بازار بورس فعال شده است. در نهایت، این سه ویژگی باعث تمایز، محبوبیت و جذابیت بیشتر سرمایه‌گذاری در بازار تبادل ارز یا فارکس شده است.

به‌طور کلی، دو نوع روش پیش‌بینی برای بازار فارکس وجود دارد [۱۴،۱۵]: تحلیل بنیادی^۱ و تجزیه و تحلیل فنی^۲، که دارای تئوری‌های متفاوتی نسبت به هم می‌باشند. برای تحلیل بنیادی سه نظریه مشهور وجود دارد: نظریه برابری نرخ بهره^۳ (IRP)، نظریه برابری قدرت خرید^۴ (PPP) و نظریه بدهی بین‌المللی^۵ [۱۵]. بدست آوردن اطلاعات در مورد نظریه سوم اغلب با موانعی روبرو است در نتیجه دو نظریه اول بیشتر مورد استفاده عموم قرار می‌گیرد، شاخص‌های منعکس‌کننده قدرت خرید و نرخ بهره اغلب در تحلیل بنیادی برای پیش‌بینی بازار فارکس استفاده می‌شوند [۱۴،۱۵]. همچنین سه نظریه عمده وجود دارد که معمولاً در تحلیل فنی یا تکنیکال استفاده می‌شود. نظریه اول معتقد است که قیمت‌های گذشته و سابقه بازار همه چیز را شامل می‌شود، به این معنی که هر فاکتور موثر در بازار فارکس مانند انتظارات اقتصادی، منازعات و جوانب سیاسی و روانی به‌طور کامل در قیمت‌های بازار منعکس می‌شود. نظریه دوم این است که نرخ ارز همیشه با یک الگوی منظم تغییر می‌کند و می‌توان این الگوها را از داده‌های گذشته تشخیص

Fundamental Analysis ^۱

Technical Analysis ^۲

Interest Rate Parity ^۳

Purchasing Power Parity ^۴

Indebtedness International ^۵

داد. سرانجام، در سومین نظریه، تحلیل فنی به تکرار تاریخ اعتقاد دارد، بنابراین قیمت بازار ارز با ارزیابی قیمت‌های گذشته قابل پیش‌بینی و تحلیل می‌باشد [۱۵].

مقدمه فوق نشان داده است که تحلیل بنیادی و تجزیه و تحلیل فنی بر اساس نظریه‌های مختلف پیش‌بینی استوار هستند. این دو نوع روش تحلیل معمولاً به‌طور جداگانه در عمل مورد استفاده قرار می‌گیرند [۹]. و هر کدام از روش‌ها مزایا و معایب خاص خود را دارا می‌باشند. این تحقیق یک مطالعه سیستماتیک در مورد روش تجزیه و تحلیل فنی و همچنین ویژگی‌ها یا عوامل دخیل بر روی روش انجام داده است. فرض بر این است که قدرت جامع نگری و گستردگی این روش پیش‌بینی بازار فارکس را بهتر میسر می‌کند و نتایج تجربی این را ثابت کرده است.

همانطور که عنوان شد یادگیری ماشین، به‌ویژه یادگیری عمیق، اخیراً در بسیاری از زمینه‌ها به موفقیت بزرگی دست یافته است. به‌عنوان مثال AlphaGo1 در مارس ۲۰۱۶ لی‌سدول، قهرمان بازی پیچیده Go را شکست داد، این اولین باری بود که یک برنامه کامپیوتری در یک بازی تخته‌ای توانسته بود یک بازیکن حرفه‌ای را شکست دهد [۱۰]. از آن زمان، توجه جهانی به هوش مصنوعی (AI) جلب شد. اکنون اعتقاد عمومی بر این است که هوش مصنوعی قادر به غلبه بر انسان حداقل در یک سری از حوزه‌های خاص می‌باشد. یادگیری ماشین، به‌عنوان یک تکنیک هوشمند در هوش مصنوعی، توانایی زیادی در یادگیری خودکار از داده‌های داده شده را دارد. با استفاده از ویژگی‌ها یا عواملی که از تحلیل فنی برای پیش‌بینی سری‌های زمانی استفاده می‌شود، می‌توان از همین قابلیت برای پیش‌بینی قیمت در بازار فارکس نیز استفاده کرد [۲۰].

۲-۱ بیان مسئله

به‌منظور حمایت از تصمیمات معامله‌گران فارکس، پیش‌بینی دقیق قیمت این بازار مالی همچنان یک موضوع محبوب اما چالش برانگیز می‌باشد. با توجه به پیچیدگی بالای این بازار، همیشه این سوال وجود

دارد که پیش‌بینی بازار مالی فارکس تا چه اندازه می‌تواند موثر باشد. به‌طور کلی پیش‌بینی سری‌زمانی داده‌های مالی، به‌ویژه پیش‌بینی قیمت سهام، یکی از دشوارترین مسائل محققان و سرمایه‌گذاران بوده است [۱۱، ۱۱]. اما با افزایش محبوبیت بازار مالی فارکس، چگونگی پیش‌بینی دقیق معاملات این بازار در هر دو حوزه دانشگاهی و مالی به یک موضوع داغ و هیجان‌انگیز تبدیل شده است. پیش‌بینی‌های دقیق معاملات فارکس نه تنها برای تک‌تک سرمایه‌گذاران این حوزه سودمند است، بلکه می‌تواند به بانک‌ها، سازمان‌ها یا دولت‌ها در تصمیم‌گیری‌های مالی، برآورد بودجه و غیره کمک کند [۱۱، ۱۴، ۱۵].

با توسعه سریع هوش مصنوعی و یادگیری ماشین در دهه‌های گذشته، یادگیری عمیق به‌عنوان یکی از شاخه‌های یادگیری ماشین با موفقیت بسیاری در حوزه‌های مختلف از جمله بازارهای مالی اعمال شده است [۱۱]. در نتیجه، مقالات پژوهشی زیادی منتشر شده است که هدف آنها بهبود دقت پیش‌بینی بازارهای مالی از جمله فارکس می‌باشد [۱۱، ۱۸]. شبکه عصبی با حافظه بلند-کوتاه مدت (LSTM)، نوعی شبکه عصبی مصنوعی است که به‌طور گسترده‌ای مورد استفاده قرار گرفته است و بصورت ویژه برای تجزیه و تحلیل داده‌های سری‌زمانی طراحی شده است [۱۳]. به‌دلیل توانایی یادگیری قوی، شبکه عصبی LSTM در بسیاری از پژوهش‌ها برای پیش‌بینی معاملات پیچیده براساس داده‌های گذشته در بازارهای مالی از جمله بازار فارکس استفاده شده است. استفاده از یادگیری عمیق و سایر تکنیک‌ها و روش‌های هوش مصنوعی در پیش‌بینی بازارهای مالی هنوز در مرحله توسعه می‌باشد [۱۳].

هدف از این تحقیق بهبود دقت پیش‌بینی روند بازار تبادل ارز با استفاده از شبکه‌های عصبی عمیق مانند حافظه بلند-کوتاه مدت (LSTM) است. برای دستیابی به این هدف، این پایان‌نامه دارای پنج مرحله است که در زیر ذکر شده است:

- بررسی جامع الگوریتم‌های یادگیری ماشین، به‌ویژه یادگیری عمیق جهت پیش‌بینی روند در بازار.

- بررسی و انتخاب دادگان مناسب در بازار تبادل ارز.

- بررسی جامع تحلیل‌های تکنیکال و بنیادی جهت انتخاب روش برتر و استفاده از روش جدید در تولید ویژگی برای دادگان مالی و همچنین تعیین هدف‌گذاری.
 - انتخاب ویژگی‌ها یا شاخص‌های مناسب که تأثیر قابل توجهی در تعیین روند این بازار مالی دارند. و تصمیم‌گیری در مورد هدف^۱ مناسب برای پیش‌بینی بازار تبادل ارز.
 - طراحی و پیاده‌سازی مدل جدید مبتنی بر ترکیب شبکه عصبی LSTM و CNN برای پیش‌بینی روند فارکس.
 - اعتبارسنجی روش‌های پیش‌پردازش و مدل در مقایسه با انواع روش‌های پیش‌پردازش، مدل‌ها و الگوریتم‌های پایه.
- هدف اول این است که درک عمیقی از زمینه‌های تحقیقاتی مرتبط داشته و مجموعه داده‌های مناسبی را برای آموزش شبکه عصبی مورد نظر پیدا کنیم. کاملاً مشهود است که داده یکی از دو مؤلفه ضروری برای یادگیری ماشین (ML) است، زیرا ML نوعی یادگیری براساس داده‌های گذشته می‌باشد [۲۴].
- مرحله مهم بعدی تلاش برای تعیین هدف مناسب جهت پیش‌بینی روند بازار می‌باشد. مطالعات فعلی نشان داده است که پیش‌بینی قیمت و پیش‌بینی روند، دو هدف متفاوت هستند و تأثیرات متفاوتی در معامله فارکس دارند. و هنگامی که هدف در یادگیری ماشین استفاده می‌شود، قطعاً نتایج متفاوتی را در بر دارد، روند قیمت در زمان استفاده از یادگیری ماشین برای معاملات فارکس، هدف عملی و مناسب‌تری است [۱۱، ۱]، از این رو به‌عنوان هدف پیش‌بینی در این تحقیق انتخاب شده است. که در ادامه بتفصیل توضیح داده‌ایم.
- شبکه‌های عصبی مصنوعی^۱ (ANN) به‌عنوان نوعی ابزار قدرتمند یادگیری ماشین، به‌ویژه در این تحقیق برای پیش‌بینی سری‌های زمانی بازار فارکس مورد توجه و توسعه قرار گرفته است [۲۰]. ANN یک مدل

^۱ Target

ریاضی الهام گرفته از عملکرد شبکه‌های عصبی در مغز انسان² (HNN) می‌باشد. یکی از مهمترین ویژگی‌های شبکه‌های عصبی مصنوعی قابلیت آنها در مدیریت داده‌های ناقص است [۱۸،۱۱]. به‌طور خاص بازار فارکس شامل داده‌های پیچیده‌ای است که عدم اطمینان، غیرخطی بودن و اختلالات غیر گاوسی را تحمل می‌کند. برای مقابله با پیچیدگی عظیم مشکلات سری‌زمانی مانند بازار فارکس، معماری حافظه بلند-کوتاه مدت^۳ (LSTM) اغلب استفاده می‌شود و در این تحقیق نیز به‌عنوان بخشی از مدل اصلی برای پیش‌بینی روند فارکس استفاده می‌گردد [۱۸،۱۱].

این تحقیق با هدف بررسی امکان استفاده از یادگیری عمیق، به‌ویژه شبکه عصبی LSTM و CNN^۴ در بازار مبادله ارز و افزایش دقت پیش‌بینی در مقایسه با الگوریتم‌های پایه‌ای یادگیری ماشین انجام می‌شود. ویژگی‌های محلی توسط شبکه‌های عصبی CNN استخراج می‌شوند و وابستگی‌های طولانی‌مدت توسط LSTM کشف می‌شوند، بنابراین این مدل می‌تواند توانایی‌های CNN و LSTM را مهار کند [۱۱]. در این پایان نامه، تمام ویژگی‌های فنی مربوط به معاملات فارکس جمع‌آوری و مورد تجزیه و تحلیل جامع قرار گرفته است. سپس حالت‌های مختلف از ویژگی‌های تأثیرگذار انتخاب می‌شوند تا به‌عنوان ورودی‌های سیستم پیش‌بینی این بازار مالی استفاده شوند.

۳-۱ چالش‌های موجود در سیستم‌های تحلیل بازارهای مالی و راه‌کار مقابله آن

چالش‌های این حوزه به چند بخش تقسیم می‌شوند:

- چگونگی استفاده از علم و تجارب متخصصین معامله‌گری و اقتصاد، در مدل هوشمند.

Artificial Neural Networks¹

Human Neural Networks²

Long Short-Term Memory^۳

Convolutional Neural Network⁴

- طراحی یک روش برچسب‌گذاری جهت تامین نیاز معامله‌گران و حفظ حجم دادگان.
- ساخت و تنظیم یک مدل برپایه یادگیری عمیق جهت پیش‌بینی بازار فارکس.

یکی از نیازهای مهم و اساسی فارغ از بحث طراحی مدل و پیش‌پردازش‌های مرتبط با آن، بحث هدف‌گذاری می‌باشد. اگر یک هدف مناسب انتخاب نشود، تعداد قابل توجهی داده از دادگان ما حذف می‌شود. از طرف دیگر، ممکن است نامناسب بودن هدف باعث شود داده‌های زیادی انتخاب شوند که وجود برخی از این داده‌ها در مرحله آموزش منجر به کاهش دقت مدل می‌شود [۱۶].

معامله‌گران در معاملات فارکس، معمولاً از تحلیل بنیادی و یا تحلیل فنی جهت تصمیم‌گیری در معاملات خود استفاده می‌کنند [۱۱]. در تحقیقات علمی، بیشتر مطالعات از داده‌های تحلیل فنی برای یادگیری ماشین استفاده می‌کنند. البته تحقیقات اندکی نیز در مورد استفاده از ویژگی‌های شاخص‌های بنیادی و فنی، همزمان با هم برای پیش‌بینی بازار فارکس وجود دارد [۲۱]. در این پایان‌نامه، تحقیق جامعی در مورد همه ویژگی‌ها یا شاخص‌های خام و درگیر در تحلیل فنی انجام می‌شود، اما نکته حائز اهمیت تبدیل این دادگان خام به استراتژی‌های کاربردی و در نهایت تبدیل به سیگنال می‌باشد.

تعیین هدف مناسب برای دادگان مورد بررسی که متعلق به دنیای واقعی می‌باشند، بسیار مهم و تاثیرگذار خواهد بود. روش‌های مختلفی جهت تعیین هدف وجود دارد. در این تحقیق پس از بررسی مزایا و معایب اهداف مختلف، بررسی خواسته‌های واقعی معامله‌گران فارکس و همین‌طور نگاه به هدف به‌عنوان یک ویژگی در دادگان یادگیری ماشین، روشی جدید برای تعیین هدف معرفی می‌شود تا سود معاملات برای فعالان این بازار به حداکثر برسد.

ترکیب LSTM و CNN همراه با روش هدف‌گذاری و استخراج ویژگی جدید برای پیش‌بینی روند بازار فارکس طراحی و پیاده‌سازی شده است. پس از تنظیم ابر پارامترها، نتایج تجربی ثابت کرده است که

چنین مدل یادگیری عمیقی همراه با روش جدید در هدف‌گذاری و استخراج ویژگی، عملکرد بهتری نسبت به یادگیری با روش سنتی یادگیری ماشین دارد.

۴-۱ هدف پایان‌نامه

همان‌طور که در بخش قبل گفته شد، تاکنون مطالعات پژوهشی متنوعی در زمینه پیش‌بینی سری‌زمانی بازار مالی انجام شده است [۲۱]. هر یک از این مطالعات، از الگوریتم‌های مختلف برای دستیابی به هدفی مشخص استفاده نموده‌اند. اما هیچکدام از روش‌های ارائه‌شده کامل و بی‌نقص نیستند و با وجود تحقیقات و مقالات متعدد می‌توان گفت تحقیقات در این مورد هنوز در مرحله توسعه می‌باشد و چالش حل نشده بسیاری در این زمینه و به‌ویژه برای بازار مالی فارکس وجود دارد [۲۱]. از مهم‌ترین چالش‌ها، عدم دقت و کارایی مدل‌ها و روش‌های پیش‌پردازش موجود برای دادگان مختلف و همچنین ساخت مدل اغلب برای قالب‌های زمانی بلندمدت می‌باشد. هدف این پایان‌نامه ارائه‌ی راهکاری هوشمند و دقیق برای رفع چالش‌های ذکر شده، به همراه افزایش دقت تشخیص در این سیستم‌ها می‌باشد.

این تحقیق در مجموع به سؤالاتی می‌پردازد که با شش هدفی که در بالا (بخش ۲-۱) معرفی شد مطابقت دارد. این سؤالات عبارتند از:

- چه ویژگی‌ها یا عواملی برای پیش‌بینی این بازار مفید هستند و کدام ویژگی‌ها یا عوامل بیشترین تأثیر را در معاملات فارکس دارند؟
- کدام هدف قیمتی برای پیش‌بینی بازار تبادل ارز، به نفع معامله‌گران این بازار است؟
- چگونه می‌توان از دانش و تجارب متخصصین معامله‌گری و اقتصاد استفاده کرد؟
- چگونه می‌توان با استفاده از شبکه‌های عصبی LSTM و CNN، با ویژگی‌های فنی و استراتژی‌های معتبر این حوزه و همچنین تعیین دقیق هدف، روند قیمت بازار فارکس را در قالب زمانی کوتاه مدت پیش‌بینی کرد؟

۵-۱ روش تحقیق

در مرحله اول این تحقیق سعی شده است با بررسی کامل تجزیه و تحلیل فنی، تمام ویژگی‌های تأثیرگذار بر روی پیش‌بینی بازار استخراج و واکاوی شود، برخی از ویژگی‌ها نیاز به ترکیب شدن باهم و تبدیل به سیگنال خاص خرید و فروش داشتند، که در بخش‌های بعد به شرح این موضوع پرداخته شده است. دادگان استفاده شده از دنیای واقعی و جفت ارز GBPUSD¹ از سال ۲۰۱۰ میلادی در قالب زمانی^۲ کوتاه مدت (پنج دقیقه‌ای) می‌باشد. در این مرحله انواع اندیکاتورها و استراتژی‌های معاملاتی موجود بررسی و از هر کدام ویژگی‌های مورد نیاز استخراج خواهد شد.

و سپس با بررسی روش‌های هدف‌گذاری، یک روش جدید ارائه می‌شود. تعیین هدف و یا هدف‌گذاری برای داده‌های مالی وظیفه کلاس‌بندی داده‌ها را انجام می‌دهد. پس تعیین درست و مطلوب هدف باعث می‌شود داده‌های موجود در دادگان دور ریخته نشوند و همچنین با واقعیت سازگاری داشته باشند. داده‌ها در این مرحله، به سه کلاس صفر، یک و دو تقسیم میشوند که کلاس صفر مربوط به داده‌های بازار خنثی^۳ و کلاس یک مربوط به داده‌های روند صعودی^۴ و در نهایت کلاس دو نمایانگر روند نزولی^۵ می‌باشد. و سپس در مرحله‌ی بعد مدل ترکیبی LSTM/CNN ساخته می‌شود و با سایر مدل‌ها مقایسه می‌شود.

۶-۱ نوآوری مسئله

در این پایان‌نامه یک روش جدید، برای پیش‌بینی روند قیمت در بازار فارکس ارائه شده است. این روش با تولید ویژگی‌های جدید، بجای سیگنال‌های خام شاخص‌های تحلیل فنی، دادگان را در حالت بهینه

¹ Grand Brtania Pound Unted State Dollar

^۲ TimeFrame

^۳ Sideway

^۴ UpTrend

^۵ DawnTrend

درمی‌آورد، سپس با بررسی روش‌های هدف‌گذاری برای دسته‌بندی دادگان یک روش جدید، بررسی و مقایسه می‌شود و در پایان مدل ترکیبی LSTM و CNN ساخته، تنظیم و آموزش داده می‌شود.

۷-۱ ساختار پایان‌نامه

این پایان‌نامه شامل پنج فصل است. در ادامه و در فصل دوم، مروری خواهیم داشت بر بازارتبادل ارز فارکس، زیرساخت‌ها و روش‌های معامله در آن و همچنین تعدادی از فعالیت‌های پیشین مورد بحث و بررسی قرار خواهد گرفت. در فصل سوم روش پیشنهادی ارائه شده، معرفی می‌گردد، در فصل چهارم به بیان نتایج حاصل از روش پیشنهادی پرداخته و در فصل پایانی به بیان یک جمع‌بندی کلی از موضوع، به همراه فعالیت‌هایی که در آینده می‌توانند در این زمینه انجام گیرند، می‌پردازیم.

فصل ۲ : مروری بر مفاهیم بازار تبادل ارزش و کارهای انجام شده

۱-۲ مقدمه

بازار تبادل ارز (فارکس) بزرگترین بازار مالی در جهان می‌باشد. به‌عنوان مثال در سال‌های ۲۰۱۶ و ۲۰۱۷ میانگین تراکنش‌های روزانه این بازار ۵/۱ تریلیون دلار تخمین زده می‌شود [۲]. و باتوجه به رشد روز افزون معاملات در این بازار در سال ۲۰۲۰ فقط برای معاملاتی که یکی از ارزهای آن دلار است به‌طور میانگین روزانه مبلغی نزدیک به شش تریلیون دلار معامله شده است. به‌دلیل حجم و تعداد معاملات قابل توجه، نرخ جفت ارزهای مختلف در طول یک شبانه روز بشدت نوسان می‌کند. در نتیجه، بازار فارکس از نظر رشد اقتصادی، نرخ بهره جهانی و ثبات مالی تأثیر بسیار زیادی بر اقتصاد مدرن جهانی دارد [۳، ۴، ۵].


بنابراین باتوجه به حجم بالای معاملات روزانه، سرمایه‌گذاران و موسسات مالی می‌توانند سود چشمگیری از این بازار کسب کنند. البته اگر بتوانند تغییرات نرخ جفت ارزهای مورد نظر در بازار تبادل ارز را به‌درستی حدس بزنند و پیش‌بینی کنند. در ادامه، بخش ۲.۱.۱ به معرفی بازار تبادل ارز و خصوصیات آن می‌پردازیم و پیچیدگی بازار فارکس در رابطه با پیش‌بینی نرخ ارز در بخش ۲.۱.۲ مورد بحث قرار خواهد گرفت.

۲-۲ بازار تبادل ارز و خصوصیات آن

بازار فارکس یک بازار مالی غیرمتمرکز است که به معامله ارزهای مختلف می‌پردازد [۳۰]. بانک جهانی تخمین زده است که مبادله روزانه در بازار ارز در سال ۲۰۱۳ حدود ۵.۳ تریلیون دلار بوده است. با در نظر گرفتن نرخ قابل توجه گردش مالی، بازار فارکس به‌عنوان بزرگترین بستر تجارت در جهان در نظر گرفته شده است. گفته می‌شود که در مقایسه با بازار سهام نیویورک، بازار فارکس بیش از ۱۶۰ برابر بزرگتر است [۲۸]. در گذشته، معامله‌گران بازار فارکس محدود به صندوق‌های تجاری، بانک‌های مرکزی و همچنین بانک‌های خصوصی بزرگ می‌شدند. اما با افزایش رشد فناوری، بازار فارکس در سال‌های اخیر در دسترس معامله‌گران خرد قرار گرفته است و این موضوع اهمیت این بازار را دوچندان می‌کند [۲۸]. یک

روز معاملاتی در بازار تبادل ارز از زمانی آغاز می‌شود که فروشندگان، بازارهای آسیا و استرالیا را باز می‌کنند. فعالیت تجاری پس از آن در اروپا از جمله بازارهای لندن، فرانکفورت و پاریس دنبال می‌شود. با باز شدن بازار نیویورک در بعد از ظهر بازار اروپا تعطیل می‌شود. این عملیات همزمان بازار، حاکی از آن است که بازار زمانی در روز به‌طور رسمی بسته نمی‌شود، هرچند که از ساعت ۱۹:۰۰ تا ۲۲:۰۰ به وقت گرینویچ با توقف معامله‌گران نیویورک و معامله‌گران سیدنی حجم معاملات کاهش می‌یابد ولی بازار بسته نمی‌شود [۲۲]. وقتی بازارهای نیویورک و لندن باز هستند نقدینگی بازار در بالاترین سطح قرار دارد. با این وجود، در تراکنش معامله‌گران در زمان محلی مربوطه، نقدینگی برای جفت ارزهای فردی بسیار زیاد است [۲۸].

بازار تبادل ارز همچنین با ویژگی منحصر به فرد دیگری مشخص می‌شود و آن این است که دلار آمریکا ارز غالب مورد استفاده در بیش از ۷۵٪ از کل معاملات جفت ارزهای این بازار می‌باشد. غلبه دلار بر نقش آن در بازار حتی هنگام برخورد با جفت ارزهای جزئی که دلار به‌عنوان واحد پول اصلی استفاده نمی‌شود هم تأکید می‌کند. به‌عنوان مثال، معامله از پزوی مکزیکی به ین ژاپن را در نظر بگیرید، مبادله این جفت ارز به‌این صورت می‌باشد که ابتدا پزوی مکزیکی به دلار و سپس مبادله دلار به ین ژاپن انجام می‌شود. استفاده از ارز اصلی در معاملات فارکس تضمین می‌کند که نقدینگی در ارزهای فرعی محدود نمی‌باشد و در این روند هزینه‌های معامله را کاهش می‌دهد [۲۲]. در مورد یورو، ۴۶٪ از معاملات بازار تبادل ارز شامل یورو، به‌عنوان یک ارز اصلی می‌باشد. سایر ارزهای رایج شامل JPY و GBP است که به ترتیب ۲۰٪ و ۱۴٪ کل معاملات را تشکیل می‌دهند. به این چهار ارز در بازار فارکس ارزهای اصلی گفته می‌شود [۲۲].



شکل ۱-۲ نرخ معاملات در بازار تبادل ارز

۲-۲-۱ پیچیدگی بازار تبادل ارز

پیش‌بینی قیمت در بازار فارکس، حتی با کمک داده‌های معاملات گذشته، چالش‌های اساسی فراوانی دارد. ادامه رشد نقدینگی و رشد معامله‌گران در بازار فارکس، چالش‌های بیشتری را در تصمیم‌گیری برای کارگزاران و معامله‌گران ایجاد کرده است، آنها عواملی را شناسایی کردند که به احتمال زیاد بر حرکت قیمت تأثیر می‌گذارند. اما داده‌های سری‌زمانی معاملات همانطور که برای امور مالی اعمال می‌شود، غالباً پر خطا (نویز)^۱، پویا و ذاتاً آشفته هستند. علت نویز ذاتی دادگان، اطلاعات ناقص داده‌های فارکس از رفتار بازار در گذشته ناشی می‌شود و به سختی می‌توان وابستگی بین قیمت‌های گذشته و آینده را به دست آورد [۱۲]. همچنین پیش‌بینی با داده‌های سری‌زمانی مالی بسیار دشوار می‌باشد. مشکلات به‌دلیل بی‌ثباتی، پویا بودن، فضای پر نویز و همچنین ماهیت پیچیده بازار است [۱۷]. مشاهدات فوق همچنین توسط برخی دیگر از دانشمندان بررسی شده است، آنها تأیید کردند که پیش‌بینی قیمت در بازار فارکس

Noise ^۱

در نتیجه نويز و نوسان آسان نيست [۱۹]. برخي از آنها اعتقاد داشتند كه محدوديت تكنيك‌هاي پيش‌بيني خود مي‌تواند پيچيدگي را در پيش‌بيني تغييرات بازار توضيح دهد. اين موارد باعث ايجاد علاقه بين مشاغل تجاري و محققان دانشگاهي براي طراحي مدل‌هاي قابل پيش‌بيني بازار فاركس شده است [۱۹]. اخيراً، مدل‌هاي مبتني بر هوش مصنوعي مانند شبكه‌هاي عصبي مصنوعي در تحقيقات پيش‌بيني سري‌زمانی بسيار مهم شناخته شده‌اند [۱۹]. همچنين در [۲۳] يائو و تان متوجه شده‌اند كه پيش‌بيني بازارهاي مالي به يكي از مباحث محبوب پژوهشي در دوره‌هاي علمي و عملي تبديل شده است.

با اين حال، بسياري از محققان اكنون دريافته‌اند كه پيش‌بيني فاركس از زمان كنار گذاشتن مواردی مانند نرخ ثابت ارز، تنظيم مقررات نرخ فاركس و جذب سيستم مبادله شناور از دهه ۱۹۷۰ تاكنون، مشكلات تجربي و نظري قابل توجهي ايجاد كرده است [۲۳]. امروز، عدم اطمينان بازارهاي مالي از عوامل رواني، سياسي و اقتصادي بسيار همبسته و پيچيده ناشي مي‌شود [۲۳]. بنابراين، درك و حتي بررسي تعامل عوامل مختلفي كه بر پويائي بازار فاركس تأثير مي‌گذارد بسيار پيچيده است. مشابه بازار سهام، اطلاعات فاركس، چرخه‌ها و روندهاي فصلي منحصر به فردي را نشان مي‌دهد. براي دستيابي به پيش‌بيني مناسب اين بازار، طراحي يك مدل مناسب كه بتواند تركيبات جديد را كشف، برون‌يابي و شناسايي كند، به يك مشكل اساسي تبديل شده است [۲۳]. نويز زياد در داده‌هاي بازار تبادل ارز و ويژگي‌هاي غير ثابت داده‌هاي اين بازار كه با گذشت زمان تغييرات را حفظ مي‌كنند، پيش‌بيني اين بازار را بيشتر پيچيده مي‌كنند [۱۷].

همانطور كه در بخش‌هاي آينده بيشتر بحث خواهد شد، شبكه‌هاي عصبي به‌عنوان تكنيك‌هاي پيش‌بيني موثرتر پيشنهاد شده‌اند زيرا به‌طور كلي تحمل نويز را دارند. علاوه‌بر اين، ANN‌ها^۱ قادر به يادگيري داده‌هاي پيچيده با دادگان نويزي يا ناقص هستند [۳۱]. شبكه‌هاي عصبي معمولاً انعطاف پذيرتر قلمداد مي‌شوند زيرا مي‌توانند از طريق فرايندهاي بازآموزي با استفاده از اطلاعات جديد از سيستم‌هاي پويا ياد

^۱ Artificial Neural Network (ANN)

بگیرند[۱۷]. بر این اساس، مشخص است که پیش‌بینی روند تغییرات بازار تبادل ارز پیچیده است. برای غلبه بر مشکلات پیش‌بینی حرکات قیمت در فارکس، دانشمندان و محققان روش‌های مختلف جهت پیش‌بینی را معرفی کرده‌اند. این روش‌ها در بخش بعدی مورد بحث قرار خواهد گرفت.

۲-۲-۲ تحلیل بازار تبادل ارز

در طول سال‌ها، پیش‌بینی بازار فارکس به‌طور گسترده‌ای با استفاده از تجزیه و تحلیل فنی یا بنیادی انجام شده است[۲۳]. نوع بنیادی براساس تجزیه و تحلیل عواملی که بر تغییر روند قیمت جفت ارزها تأثیر می‌گذارد، انجام می‌شود و این موارد شامل سطح رشد اقتصادی یک کشور، انتظارات بازار، تحلیل وضعیت و شرایط سیاسی کشورها، مناطق و جهان می‌باشد. در مقابل، تجزیه و تحلیل فنی بر پیش‌بینی روند آینده نرخ ارز با مطالعه نرخ گذشته آنها با استفاده از روش‌های آماری، روانشناسی و سایر رشته‌ها متمرکز است[۲۹]. این دو روش تجزیه و تحلیل مفصل در زیر بخش‌های بعدی بحث شده است.

۲-۲-۳ تجزیه و تحلیل فنی

این روش تجزیه و تحلیل برای اطلاع از تصمیمات در پیش‌بینی بازار مالی نیاز به استفاده از حرکات قیمت در گذشته دارد. مارک تیلور در [۲۶] متذکر شد که تجزیه و تحلیل فنی، توصیه‌های تجاری یا پیش‌بینی‌های مبتنی بر قیمت‌های گذشته را ارائه می‌دهد، در حالی که تحلیلگران لزوماً جنبه‌های تحلیل بنیادی یا برخی دیگر از عوامل اقتصادی را در نظر نمی‌گیرند. در برخی موارد، تجزیه و تحلیل فنی از برخی خلاصه‌های کمی در مورد تغییرات قیمت گذشته، از جمله میانگین متحرک^۱ یا نوسانگرها (شاخص‌های حرکت) استفاده می‌کند[۲۶]. امروزه، بسیاری از سیستم عامل‌های تجارت الکترونیکی مبتنی بر تجزیه و تحلیل فنی، مانند MetaTrader، به‌طور گسترده برای ارائه پیش‌بینی بازارهای مالی استفاده شده‌اند[۲۷]. تجزیه و تحلیل فنی از حرکات‌های گذشته‌ی قیمت استفاده می‌کند که در قالب پیش‌بینی

^۱ Moving-Avrage

روند آینده و نمودارهای قیمت خلاصه می‌شود تا بتواند پیش‌بینی‌های بازار را انجام دهد. در اواخر دهه ۱۸۰۰، چارلز داو تجزیه و تحلیل فنی را که در تصمیم‌گیری حرفه‌ای تجارت و سرمایه‌گذاری استفاده شده است، توسعه داد [۳۶].

در سال ۱۹۹۱، پرینگ با مطالعه مفاهیم موجود در مورد ارزیابی داده‌های فنی بیان کرد. اساس تجزیه و تحلیل فنی محدود به ارزیابی روند گذشته قیمت‌ها می‌باشد و این تغییرات اغلب هنگامی ایجاد می‌شوند که نگرش سرمایه‌گذاران تحت تأثیر نیروهای روانی، سیاسی، پولی یا اقتصادی قرار بگیرند. در نتیجه، پرینگ متوجه شد که تجزیه و تحلیل تکنیکی بر مفهوم روانشناسی توده (جمعیت) عمل می‌کند. بنابراین، تجزیه و تحلیل فنی تمایل به پیش‌بینی حرکت‌های آینده قیمت بر اساس درک روانشناسی جمعیت دارد که در آن بدبینی بالقوه، وحشت، ترس، طمع، خوش‌بینی و اعتماد به نفس بیش از حد وجود دارد [۳۶]. شاخص‌های تجزیه و تحلیل فنی مورد استفاده در بازار فارکس به‌طور کلی در چهار دسته قرار می‌گیرند که شامل شاخص‌های قدرت یا حجم، شاخص‌های روند، شاخص‌های حرکت و شاخص‌های نوسانات می‌باشند [۳۳].

تحلیلگران فنی معتقدند که با مطالعه داده‌های گذشته می‌توان قیمت‌های آینده را پیش‌بینی کرد [۳۲]. این برخلاف فرضیه پیاده روی تصادفی^۱ می‌باشد که معتقد است تغییر قیمت مستقل از هرگونه اقدام یا روند گذشته می‌باشد. به همین ترتیب، طبق فرضیه کارآمد^۲ حرکت گذشته قیمت نمی‌تواند بازدهی غیرطبیعی را تضمین کند. همانطور که توسط فرضیه کارآمد پیشنهاد شده است، هرگونه انتظار در حرکت برگشت غیرعادی تقریباً به محض ورود سرمایه‌گذاران به بازار شکسته خواهد شد [۳۲]. بنابراین استفاده از پیش‌بینی‌های فنی مطمئن در بازار فارکس برای یک سرمایه‌گذار همیشه می‌تواند دشوار باشد.

^۱ Random Walk Hypothesis

^۲ Efficient Market Hypothesis

۲-۲-۴ پیش‌بینی هزینه و روند

اخیراً یک نظر قوی در زمینه تحقیقات پیش‌بینی فارکس وجود دارد که پیش‌بینی تغییرات قیمت کمکی به سرمایه‌گذاران این حوزه نمی‌کند. در عوض، پیش‌بینی تغییر روند بازار بیشتر مفید خواهد بود. به عنوان مثال، اگر پیش‌بینی قیمت برای جفت EUR/JPY در ۱.۴۸ انجام شود و سرمایه‌گذار دوباره بخواهد برای پنج روز بعد قیمت را پیش‌بینی کند، قیمت در حدود ۱.۴۶ یا ۱.۵ خواهد بود، این بدان معناست که در هر دو مورد، همان خطای ۰.۰۲ مفروض است. بنابراین، بهبود صحت پیش‌بینی قیمت برای کمک به سرمایه‌گذاران فارکس کافی نیست. در عوض، سرمایه‌گذاران و معامله‌گران می‌توانند از پیش‌بینی روند بیش از قیمت، جایی که تمرکز اصلی ارزیابی می‌باشد، بهره‌مند شوند [۲۶، ۲۹].

براون، موندکوسکی و شیو در [۳۸] با استفاده از عمق بازار^۱ به عنوان یک ویژگی سعی در پیش‌بینی حرکات قیمت ثانیه بعدی در جفت EUR/USD داشتند. این تحقیق سعی در غلبه بر محدودیت‌های حرکات کوتاه مدت قیمت داشت که تصور می‌شد به صورت تصادفی انجام می‌پذیرند و از این رو پیش‌بینی دشوار می‌باشد. یافته‌ها نشان داد عدم تعادل کافی در عمق بازار وجود دارد که می‌توان به کمک آن پیش‌بینی دقیق قیمت را در بازار فارکس انجام داد. علاوه بر این، محققان یک مدل مارکوف را آموزش و آزمایش کردند که با کمک آن نشان دادند که پتانسیل پیش‌بینی می‌تواند زیان‌های احتمالی را که منجر به سود می‌شود، برطرف کند. برخی از محققین از شبکه‌های عصبی برای پیش‌بینی روند نرخ ارز خارجی استفاده کردند. داده‌های سری‌زمانی با شاخص‌های فنی، به عنوان مثال، میانگین متحرک، برای کسب قوانین اساسی در مورد حرکات نرخ ارز به ANN معرفی شدند. محققان نشان دادند که RNN آموزش دیده قادر به پیش‌بینی روند در جفت ارزهای مختلف از جمله USD، EUR، GBP، CHF و JPY بود. نتایج نشان داد که شبکه‌های عصبی می‌توانند قیمت‌ها را با دقت قابل قبولی پیش‌بینی کنند [۳۴].

^۱ قیمت‌های لحظه‌ای ask و bid در هر لحظه عمق بازار را نشان می‌دهد.

دانشمندان در [۳۹] هنگام پیش‌بینی قیمت نرخ ارز درازمدت، نقاط ضعف استفاده از شبکه‌های عصبی کم-عمق را برای داده‌های سری‌زمانی شناسایی کردند. این بدان معنی است که شبکه‌های عصبی کم-عمق در پیش‌بینی روند بازار خیلی موثر نیستند. به همین دلیل، استفاده از چنین شبکه‌های عصبی برای پیش‌بینی قیمت فارکس نمی‌تواند سود پایدار داشته باشد. محققان پیشنهاد کردند که از طبقه‌بندی‌های یادگیری ماشین استفاده کنند و دریافتند که آنها نتایج بهتری نسبت به شبکه‌های عصبی کم عمق در پیش‌بینی روند ایجاد می‌کنند. همچنین در مورد شبکه‌های عصبی عمیق، موفقیت این شبکه‌ها در پیش‌بینی تغییرات بازار، به ظرفیت آنها در یادگیری ویژگی‌های انتزاعی از داده‌های خام نسبت داده شد. به‌عنوان مثال، شبکه‌های عصبی کانولوشن عمیق در پیش‌بینی نرخ جفت ارز GBP/USD, JPY/USD و EUR/USD عملکرد خوبی داشتند [۳۹]. بنابراین، در این پایان‌نامه، روند در پیش‌بینی فارکس مورد استفاده قرار خواهد گرفت زیرا در مقایسه با پیش‌بینی قیمت، تخمین کارآمدتری ارائه می‌دهد.

۲-۳ کارهای انجام شده در پیش‌بینی سری زمانی

پیش‌بینی در دوره‌های زمانی مختلف منجر به دقت‌های متفاوت می‌شود برخی از محققان اشاره کردند که، هنگام پیش‌بینی روند قیمت در روز بعد، روز ۳ و ۵، عملکرد شبکه‌های ANN بهتر از برخی مدل‌های دیگر مانند پیاده‌روی تصادفی^۱ است. برعکس، شبکه‌های ANN هنگام پیش‌بینی برای روز دهم و روز ۳۰ عملکرد بدتری داشتند [۳۴]. چون و کیم در [۳۷] برای شناسایی بهترین قالب‌های زمانی پیش‌بینی بر اساس از دست دادن اطلاعات، از مدل Lyapunov استفاده کردند و نتیجه نشان داد که استفاده از هوش مصنوعی در پیش‌بینی‌های مالی عملکرد بهتری در قالب زمانی کوتاه مدت دارد. پیش‌بینی‌های دقیق توسط شبکه‌های ANN تنها با استفاده از قالب‌های مناسب پیش‌بینی حاصل می‌شود. به‌طور کلی،

^۱ Random Walk

شبکه‌های عصبی می‌توانند برای بازه‌های کوتاه مدت و میان مدت پیش‌بینی‌های قابل اطمینان انجام دهند [۳۷].

بازه زمانی کوتاه مدت معمولاً به ۱ تا ۳ مرحله، میان مدت به ۴ الی ۸ مرحله و بلند مدت بیش از هشت مرحله اشاره دارد. اصطلاح "مرحله" برای اشاره به تکرار به‌روزرسانی اطلاعات استفاده می‌شود که می‌تواند در روزها، هفته‌ها، ماه‌ها یا فصل‌ها باشد. یو، وانگ و لای ۴۵ مقاله در مورد پیش‌بینی‌های کوتاه مدت، میان مدت و بلند مدت را بررسی کردند، از جمله آنها، ۳۹ مطالعه در مورد پیش‌بینی‌های کوتاه مدت، ۱۵ مطالعه در مورد پیش‌بینی میان مدت و شش مطالعه در مورد پیش‌بینی‌های بلند مدت می‌باشد. نتیجه‌گیری از تحقیق نشان می‌دهد که استفاده از پیش‌بینی‌های قالب زمانی طولانی مدت به‌طور بالقوه در پیش‌بینی‌های منفی نقش دارد و پیش‌بینی‌های کوتاه مدت منجر به پیش‌بینی‌های بهتری می‌شود [۳۵].

محققان توانستند برای پیش‌بینی قیمت در ۵ روز آینده، در قالب زمانی روزانه، و جفت ارز EUR/USD دقت ۷۸٪ به‌دست آوردند. همچنین برخی دیگر از پژوهش‌گران ارزیابی عملکرد در فرآیندهای آماری و یادگیری ماشین را براساس سه بازه زمانی ۱، ۵ و ۳۰ روزه انجام دادند. که در آن برای مدت ۱ و ۵ روز، ASTAR¹ از نظر متغیرهای Close و High نتایج بهتری را نشان داد، زیرا داده‌ها، الگوهای دوره‌ای را نشان می‌دهند. الگوریتم ژنتیک و شبکه‌های عصبی نتایج متفاوتی را ارائه دادند، اگرچه هنگام پیش‌بینی قیمت‌های low و open نتایج بهتری را نشان می‌دهند. ولی برای پیش‌بینی‌های طولانی مدت، نتایج متناقضی وجود داشت که این الگوریتم‌ها پیش‌بینی‌های قیمت high و open بهتری را ارائه می‌دادند و ASTAR در قیمت‌های high و close بهتر کار می‌کرد [۴۲]. دو محقق در [۴۰] یک سیستم عصبی-ژنتیکی را بمنظور تجارت در بازار فارکس و برای سرمایه‌گذاری کوتاه مدت در جفت ارز EUR/USD پیشنهاد داده‌اند. زیرمجموعه کوچکی از معاملات EUR/USD به‌عنوان داده ورودی استفاده شد. باتوجه

¹ Adoretive Spline Threshold Autoregression

به همبستگی‌های پیچیده میان ویژگی‌های فارکس، مانند قیمت فارکس و شاخص‌های فنی، GA برای دوره‌های زمانی کوتاه مدت مانند یک بازه ۵ روزه قوی‌تر است. تاماسون در سال ۱۹۹۹ همچنین تایید کرد که پیش‌بینی ۵ روز برای معاملات روزانه فارکس مناسب‌تر است. یافته‌های مشابه توسط برخی دیگر از محققان ارائه شده است. به‌عنوان مثال غزالی در [۳۶] اشاره کرد که RPNNS در مقایسه با برخی دیگر از مدل‌ها مانند PSNN، FLNN و MLP سود بالاتری را در دوره کوتاه مدت ۵ روز ایجاد می‌کند.

۲-۳-۱ یادگیری ماشینی برای پیش‌بینی سری زمانی

بسیاری از مقالات بررسی شده به‌طور گسترده موضوع پیش‌بینی و مدلسازی نرخ ارز را بررسی کرده‌اند. در دسترس بودن تکنیک‌های متعدد مدلسازی در واقع نشانگر ماهیت چالش برانگیز یافتن یک مدل مناسب است که به‌طور کامل نوسانات بازار تبادل ارز را توصیف کند [۲۳]. چالش‌های پیش‌بینی بازار فارکس در ابتدا توسط Meese و Rogoff در سال ۱۹۸۳ گزارش شد، زمانی که آنها پیش‌بینی نمونه‌هایی را از دو مدل سری‌زمانی و مدل‌های ساختاری مقایسه کردند. محققان دریافتند، اگرچه این مدل‌ها به خوبی با نمونه‌ها مطابقت دارند، اما هیچ یک از آنها پیش‌بینی بهتری نسبت به پیاده‌روی تصادفی با خطای پیش‌بینی مربع میانگین^۱ نداشتند. از سال ۱۹۸۳، بسیاری از محققان و معامله‌گران سعی در اصلاح مدل‌های سری‌زمانی برای بهبود پیش‌بینی نرخ ارز داشته‌اند اما هنوز مسیری طولانی در پیش است [۱۵، ۲۹].

۲-۳-۲ سری زمانی در بازار تبادل ارز

یک سری‌زمانی به مجموعه مشاهدات X_t اشاره دارد که در ترتیب زمانی t مرتب شده‌اند [۱۷]. سری‌های زمانی به‌عنوان نقاط داده‌ای موفق تعریف شده‌اند که بترتیب زمانی نمودار شده، فهرست شده یا نمایه سازی شده‌اند [۱۹]. وقتی داده‌های عددی در یک توالی خاص، در فواصل منظم و طی یک دوره زمانی

^۱ Mean Squared Error

مشخص جمع‌آوری می‌شوند، داده‌ها را یک سری زمان گسسته می‌نامند [۱۹]. آقای لی در [۴۳] اشاره کرد که سری‌های زمانی را می‌توان صداهای سفید دانست. منظور از صداهای سفید زمانی است که داده‌ای در جریان نیست یا زمانیکه بازار تعطیل می‌باشد. بنابراین، داده‌های سری‌زمانی به ناچار تقریباً در تمام تحلیل‌های پیش‌بینی فارکس دخیل هستند.

پیش‌بینی بازار تبادل ارز براساس سری‌های زمانی باید رویدادهای قبلاً ثبت شده را در نظر بگیرد [۵۰]. در چنین ارزیابی‌هایی، از تحلیل رگرسیون برای آزمون چگونگی تأثیر داده‌های گذشته بر روندهای گذشته در یک سری‌زمانی متفاوت استفاده شده است [۵۰]. وقتی از مدل‌های تصادفی در سری‌های زمانی استفاده می‌شود، در درجه اول بیانگر این است که مشاهدات نزدیک به هم بیشتر از آنچه که از یکدیگر فاصله دارند با یکدیگر مرتبط هستند. علاوه‌براین، محققان مشاهده کردند که سری‌های زمانی نیز به‌طور گسترده‌ای در رشته‌ها و موضوعات مختلف مورد استفاده قرار گرفته‌اند [۱۷، ۴۳، ۵۰]، از جمله برنامه‌های تجربی برای پیش‌بینی شاخص سهام با استفاده از ماشین‌های بردار پشتیبانی (SVM) [۴۴] و شبکه‌های عصبی مصنوعی [۱۱، ۳۱].

در بازار فارکس نشان داده شده است که ساختار داده‌های سری‌زمانی باتوجه به مشکلات پیش‌بینی تغییرات بازار، یک ابزار مهم تجزیه و تحلیل است [۱۳، ۲۱]. در گذشته، تحقیقات قابل توجهی انجام شده است که با استفاده از رویکردهای مبتنی بر سری‌زمانی برای بهبود پیش‌بینی بازار تبادل ارز انجام شده است [۱۳]. محققان با مقایسه سه جفت ارز، یعنی EUR/KZT، SGD/KZT و USD/KZT، نرخ ارز سالانه را براساس داده‌های هشت ساله از ۲۰۰۶ تا ۲۰۱۴ از قزاقستان مدل سازی کردند. آن‌ها از مدل ARIMA در پیش‌بینی نرخ سالانه بازار استفاده کردند و دقت مدل را با استفاده از RMSE، MAPE و MAE مقایسه کردند. یافته‌های این مطالعه نشان داد که برای سه ارز، استفاده از مدل ARIMA با استفاده از MAPE بیشترین تأثیر را در پیش‌بینی نرخ ارز سالانه داشت [۵۰]. سپس بدنبال توسعه و مقایسه دقت استفاده از GARCH [۲۱] به‌عنوان یک مدل سری‌زمانی در پیش‌بینی نرخ ارز روزانه بین

USD/LKR بودند. شاخص‌های فنی متحرک و مشاهدات گذشته به‌عنوان متغیرهای توضیحی در نظر گرفته شدند. مشخص شد که مدل ANN عملکرد بهتری نسبت به مدل GARCH در پیش‌بینی نرخ ارز دارد. مطالعات فوق نشان داده است که سری‌های زمانی می‌توانند اطلاعات ارزشمندی را برای پیش‌بینی بازار تبادل ارز ارائه دهند.

۲-۳-۳ پیش‌بینی سری زمانی

پیش‌بینی با استفاده از سری‌های زمانی، به استفاده از توالی داده‌ها، برای اندازه‌گیری همان مورد در یک دوره سفارش اشاره دارد [۴۱]. متناوباً، سری‌های زمانی را می‌توان به‌عنوان مجموعه‌ای از مقادیر عددی تعریف کرد، که هر یک دارای سابقه زمانی خاص خود هستند که توسط یک نام و مجموعه‌ای از ابعاد برچسب‌گذاری شده، تعریف می‌شوند [۴۵]. در بازار فارکس، الگوریتم‌های تجارت مستقل به‌طور مداوم داده‌های مربوط به نوسانات بازار را در طی یک دوره زمانی جمع می‌کنند [۲۹]. جمع‌آوری داده‌های سری‌زمانی، محققان را قادر می‌سازد تا گذشته را تجزیه و تحلیل کنند، حال را رصد کرده و آینده را پیش‌بینی کنند [۴۱]. برخی از روش‌های پیش‌بینی برای سری‌زمانی در بازار تبادل ارز وجود دارد. قبل از توضیح این روش‌ها، مجموعه آموزش و مجموعه تست باید توضیح داده شود. مجموعه آموزش برای استفاده از روش تجزیه و تحلیل داده‌ها جهت پیش‌بینی، و مجموعه آزمون برای ارزیابی عملکرد روش پیشنهادی، استفاده می‌شود. از آنجا که مقدار قابل توجهی از داده‌ها برای تجزیه و تحلیل داده‌ها مورد نیاز است، مجموعه آموزش معمولاً ۷۰-۹۰٪ از کل داده‌ها را تشکیل می‌دهد، و مجموعه آزمایش ۱۰-۳۰٪ را تشکیل می‌دهد [۲۱].

یک رویکرد ساده پیش‌بینی این است که آخرین مقدار مجموعه آموزش را برای مقداردهی روز بعد استفاده می‌کنیم. و فرمول این روش ساده را می‌توان به صورت زیر ارائه داد:

$$\hat{y}_{t+1} = y_t$$

این ساده‌ترین معادله پیش‌بینی سری‌زمانی است. با این وجود، بوسیله آزمون خطای میانگین مربع^۱، که خطای بین پیش‌بینی و مقدار واقعی را در مجموعه داده‌های تست نشان می‌دهد، اغلب بیانگر اینست که این روش ساده پیش‌بینی در بسیاری از موقعیت‌ها عملکرد ضعیفی دارد، به‌ویژه برای مواردی که اختلاف زیادی بین دو واحد زمانی وجود دارد.

روش ساده‌ی دیگری برای پیش‌بینی سری‌زمانی وجود دارد که متوسط ساده^۲ نامیده می‌شود. همانطور که در معادله زیر ارائه شده است، می‌توان از روش میانگین ساده برای تخمین مقدار روز بعد با استفاده از میانگین کل روزهای گذشته استفاده کرد:

$$\hat{y}_{x+1} = \frac{1}{x} \sum_{i=1}^x y_i$$

با این‌حال، هنگامی که در کل دوره زمانی افزایش یا کاهش قابل توجهی داشته باشید، عملکرد روش متوسط ساده بسیار بد می‌شود. به‌همین دلیل، می‌توان با در نظر گرفتن مقدار متوسط یک دوره زمانی کوتاه در گذشته، یعنی میانگین متحرک، رویکرد متوسط ساده را می‌توان بهبود بخشید. میانگین متحرک ساده پیش‌بینی‌های بهتری را نشان داده است و می‌تواند به‌صورت زیر ارائه شود [۴۶]:

$$\hat{y}_l = (y_{i-1} + y_{i-2} + y_{i-3} \dots y_{i-p})$$

که p تعداد واحدهای زمانی در بازه زمانی کوتاه می‌باشد.

با افزودن وزن بیشتر به مقادیر داده‌های جدیدتر، یعنی میانگین متحرک وزنی، مدل می‌تواند بیشتر بهبود یابد [۵۱]. اصل WMA^۳ این است که نقاط داده جدیدتر نقش مهمی در پیش‌بینی دارند.

$$\hat{y}_l = \frac{1}{m} (w_1 * y_{i-1} + w_2 * y_{i-2} + w_3 * y_{i-3} \dots w_m * y_{i-m})$$

Mean Square Error^۱

Simple Average^۲

Weighted Moving Average^۳

وقتی وزن‌های مناسب در یک دوره خاص اضافه می‌شوند و تمام مقادیر را به ۱ اضافه می‌کنند، تعریف ریاضی اهمیت داده‌های اخیر ممکن می‌شود [۵۱]. هر دو میانگین ساده و میانگین متحرک وزنی از نظر نحوه برخورد با یک مسئله در نقطه مقابل روش‌های سری‌زمانی هستند. از هموارسازی نمایی^۱ می‌توان برای افزودن ایده‌های هر دو روش با افزودن وزن بیشتر به نقاط داده اخیر استفاده کرد [۵۱]. روش هموارسازی نمایی ساده می‌تواند به صورت زیر ارائه شود:

$$\hat{y}_{T+1|T} = \alpha y_T + \alpha(1 - \alpha)y_{T-1} + \alpha(1 - \alpha)2y_{T-2} \dots$$

که در این فرمول، α پارامتر هموارکننده را نشان می‌دهد. با این حال، روش هموارسازی نمایی ساده نمی‌تواند تغییرات موجود در داده‌ها را در نظر بگیرد. روند خطی Holts این امکان را فراهم می‌کند که هموارسازی نمایی ساده‌ای برای پیش‌بینی داده‌ها با روند و سطح اعمال شود. این روند به الگوی کلی مقادیر در یک زمان معین اشاره دارد و سطح نشانگر مقدار متوسط در مجموعه می‌باشد [۵۱]. روش خطی Holt با استفاده از سه معادله، پیش‌بینی، روند و سطح دقت را بهبود می‌بخشد. همچنین معادلات به این صورت می‌باشند:

$$\hat{y}_{t+h|t} = l_t + hb_t \quad \text{معادله پیش‌بینی:}$$

$$l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad \text{معادله سطح:}$$

$$b_t = \beta * (l_t - l_{t-1})(1 - \beta)b_{t-1} \quad \text{معادله روند:}$$

اگرچه این مدل تحت برخی شرایط کار می‌کند، اما تغییرات داده‌ها را کاملاً حساب نمی‌کند. یک روش جهت بهبود، افزودن فصلی^۲ است، زیرا برخی از روندها به فصول بستگی دارند، به این روش Holt's Winter Method گفته می‌شود [۴۷].

$$l_t = \alpha(y_t - s_{t-s}) + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad \text{معادله سطح:}$$

^۱ Smoothing Simple Exponential
^۲ Seasonality

$$b_t = \beta * (l_t - l_{t-1}) + (1 - \beta)b_{t-1} \quad \text{معادله روند:}$$

$$f_{t+k} = l_t + kb_t + s_{t+k-s} \quad \text{معادله پیش‌بینی:}$$

$$s_t = \gamma(y_t - l_t) + (1 - \gamma)s_{t-s} \quad \text{معادله فصلی:}$$

تاکنون، همه این روش‌ها فقط داده‌های سری‌زمانی تک متغیره را در نظر می‌گیرند، به این معنی که داده‌ها فقط متغیرهای وابسته به زمان منفرد دارند. با این حال، در پیش‌بینی بازار فارکس، مقدار یک متغیر نه تنها به گذشته بستگی دارد بلکه از مقادیر گذشته‌ی متغیرهای دیگر نیز تحت تأثیر قرار می‌گیرند. این وابستگی‌ها برای پیش‌بینی مقادیر آینده باید در نظر گرفته شود و یک روش متداول که می‌تواند مورد استفاده قرار گیرد، روش خودگرایی برداری^۱ است. که براساس عملکرد خطی مقادیر گذشته آن و مقادیر ورودی‌های دیگر می‌باشد [۵۲]. از تکنیک‌های یادگیری ماشین اغلب برای آموزش از توالی داده‌ها استفاده می‌شود و از آن میان LSTM ها می‌توانند از توالی‌های طولانی‌تر داده‌ها یاد بگیرند [۱۳، ۵۲]. در پیش‌بینی بازار فارکس، سری‌زمانی، داده‌های چند متغیره است، از جمله قیمت‌های high, low, open و close، که فقط برای یادگیری تکنیک‌های یادگیری ماشین مانند RNN یا LSTM مناسب هستند [۱۳].

مدل‌های پیش‌بینی متداول مورد استفاده برای سری‌های زمانی چند متغیره، شامل خود رگرسیون برداری (VAR)، [۵۲] شبکه عصبی بازگشتی [۱۳] و LSTM می‌باشد. به دلیل پیچیدگی بازار تبادل ارز، انتخاب یک روش مناسب در بدست آوردن نتایج پیش‌بینی مطلوب جهت پیش‌بینی سری‌های زمانی ضروری می‌باشد. مدل مبتنی بر داده‌های سری‌زمانی می‌تواند بر اساس ماهیت مقادیر قبلی، خطی یا غیرخطی باشد [۱۳، ۲۱]. هوش مصنوعی تکنیک یادگیری آماری جدیدی را ارائه می‌دهد که برای پیش‌بینی مالی مورد توجه روزافزون قرار گرفته است [۲۱]. امروزه از چندین روش مبتنی بر هوش مصنوعی در پیش‌بینی این بازار استفاده می‌شود، که در بخش بعدی بحث خواهد شد.

^۱ Vector Autoregression (VAR)

۲-۳-۴ روش‌های رایج مورد استفاده برای پیش‌بینی بازار تبادل ارز

محققان و متخصصان سعی کرده‌اند طی سالیان گذشته تکنیک‌های مختلف پیش‌بینی را در بازار فارکس به کار گیرند. آقای فیلیپ و همکارانشان در [۴۸] اشاره کردند که میتوان روشها را براساس تکنیکهایی که در دست دارند تفکیک کرد. روش‌های کلاسیک پیش‌بینی سری‌زمانی تا حد زیادی بر مدل‌های آماری سنتی شباهت دارند. یک رابطه مکمل بین تجزیه و تحلیل سری‌زمانی مبتنی بر ANN و روش‌های پیش‌بینی آماری متداول وجود دارد [۴۸]. با این حال، بنظر می‌رسد که رویکردهای آماری سنتی برای پیش‌بینی سری‌های زمانی هنگام استفاده از داده‌های غیرخطی مانند شاخص‌های سهام به محدودیت‌های پایانی خود رسیده‌اند. در تلاش برای رفع محدودیت‌هایی که روش‌های آماری متداول دارند، آقایان یائو و تان در [۲۳] خاطرنشان کردند که شبکه عصبی مصنوعی قابلیت‌های قابل توجهی را برای پیش‌بینی‌های پیچیده شامل شناسایی، طبقه بندی و تخمین نشان داده است.

به‌عنوان مثال، مدل‌های مارکوف هنگامی که به‌عنوان یک ابزار پیش‌بینی معاملات استفاده می‌شود، ناپایدار هستند، بویژه در داده‌های بازار فارکس که عوامل زیادی برای تأثیرگذاری در نتایج نهایی دارند [۴۸]. مدل‌های Hidden Markov بسختی می‌تواند نتایج خروجی را بهبود ببخشد [۴۸]. ثبات و ماهیت قوی سه معماری شبکه عصبی و پنج معماری سنتی دیگر را در پیش‌بینی جفت ارز EUR/USD بررسی شده است. نتایج نشان می‌دهد که شبکه‌های عصبی $HONN^1$ و چند لایه پرسپترون، RNN و مدل‌های Psi Sigma پیش‌بینی بهتری نسبت به مدل‌های سنتی در پیش‌بینی روند EUR/USD طی هشت سال داشتند [۴۸].

همچنین آقای فیلیپ و همکارانش در [۴۸] از شبکه‌های عصبی برای پیش‌بینی تغییرات بازار با استفاده از داده‌های فارکس استفاده کردند. آنها هنگام آموزش شبکه، برای اصلاح وزن‌ها، از روش FeedForward استفاده کردند. همچنین ورودیها را با استفاده از تابع فعالساز سیگموئید به یک محدوده استاندارد [۰،۱]

¹ Higher Order Neural Network

تبدیل کردند. در حین یادگیری برای وزنهای مقادیر بین $[-0.1, 0.1]$ به طور تصادفی اختصاص دادند. البته این مدل نتیجه مطلوبی نداد در نتیجه به منظور بهبود مدل، در مرحله آموزش، از تانژانت هیپربولیک بجای سیگموید استفاده شد. و همچنین نرخ یادگیری را نیز افزایش دادند. و از backpropagation بجای شبکه‌های FeedForward استفاده کردند، در حالی که پیش‌بینی با استفاده از شبکه‌های چند لایه Perceptron انجام شد. این مدل در مقایسه با مشهورترین مدل پیش‌بینی نرخ ارز یعنی همان مارکوف پنهان^۱ که دقت ۶۹.۹٪ را ثبت کرد، میزان دقت ۸۱.۲٪ را نشان داد. بنابراین، مدل جدید نتیجه بهتری در پیش‌بینی نرخ ارز خارجی ارائه داد [۴۸].

در ادامه آقایان یو، وانگ و لای در [۵۳] یک روش غیرخطی جدید را برای پیش‌بینی بازار تبادل ارز تهیه کردند که شامل رگرسیون خطی خودکار^۲ میشد. آنها از شبکه‌های عصبی برای بهبود عملکرد پیش‌بینی و بدست آوردن یافته‌های قابل استفاده در فارکس استفاده کردند. اثربخشی و دقت مدل پیشنهادی در مقایسه با مدل‌های ترکیبی خطی و غیرخطی و مدل‌های پیش‌بینی غیرترکیبی مانند ANN و GLAR ارزیابی شد. نتایج حاصل از مطالعه نشان داد که مدل جدید در مقایسه با یافته‌های بدست آمده با استفاده از سایر رویکردها، پیش‌بینی بهتری داشته است. همچنین یافته‌ها نشان داد که مدل ساخته شده در این مقاله می‌تواند یک ابزار پیش‌بینی جایگزین در بازار فارکس برای دستیابی به دقت پیش‌بینی بهتر و بهبود کیفیت پیش‌بینی باشد [۵۳].

دی ماتوس در سال ۱۹۹۴ قابلیت اطمینان استفاده از شبکه بازگشتی و شبکه پرسپترون چند لایه را براساس اینکه این دو مدل می‌توانند معاملات آتی این ژاپن را پیش‌بینی کنند، مقایسه کرد. این یافته‌ها نشان داد که شبکه‌های feedforward خطاهای پیش‌بینی کمتری ایجاد می‌کنند. همچنین این مدل از مدل‌های کلاسیک و ساده یادگیری ماشین که داده‌های آنها فقط از قیمت ماه قبل استفاده می‌کرد،

^۱ Hidden Markov

^۲ Generalised Linear Auto-Regression

پیشی گرفتند[۴۹]. و یک سال بعد یعنی در سال ۱۹۹۵ اثربخشی پیش‌بینی RNN ها و MLFN ها را هنگام پیش‌بینی در مجموعه داده‌های مختلف فارکس نشان داد. نتایج نشان می‌داد که معیارهای^۱ (PSC) برای مقایسه شبکه‌های عصبی در پیش‌بینی نرخ فارکس مناسب است. با استفاده از PSC، مدل‌های شبکه عصبی پتانسیل و توانایی پیش‌بینی بهتر بازار را در مقایسه با مدل‌های دیگر مانند پیاده‌روی تصادفی نشان دادند[۱۱،۴۹]. محققان یک مدل خوشه‌ای با ANN برای پیش‌بینی جهت حرکت USD/DEM در بازار فارکس ایجاد کردند. یافته‌های آنها نشان داد که مدل جدید آنها در مقایسه با سایر روش‌های پیش‌بینی نتایج بهتری را کسب کرده است[۱۱].

آقای Tenti و همکارانش در سال ۱۹۹۶ از معماری RNN برای تعیین تغییرات نرخ ارز استفاده کرد. آنها تلاش کردند تا به کاربرد فزاینده ANN در پیش‌بینی بازار تبادل ارز بپردازد. که در نهایت نتیجه، کارایی و سودآوری این موضوع را نشان داد. آن‌ها سه مدل مبتنی بر RNN را بر اساس پیش‌بینی دقیق باهم مقایسه کردند. یافته‌ها نشان داد که هر سه مدل در معاملات بی‌درنگ پیش‌بینی سودآوری ایجاد کرده‌اند[۱۱،۲۱]. همچنین محققان یک مدل ترکیبی را توسعه دادند و در آن الگوریتم ژنتیک و ANN را برای چهار ارز مبتنی بر معاملات نقطه‌ای ۳ ماهه ترکیب کردند. این چهار ارز فرانک سوئیس، ین ژاپن، مارک آلمان و پوند انگلیس بود. یافته‌های عملی نشان داد که پیش‌بینی مدل برای نرخ آتی از نظر دقت، عملکرد بهتری دارد. Chen و Daouk در [۶۰] دقت پیش‌بینی شبکه عصبی MLFN و GRNN^۲ را مقایسه کردند. این یافته‌ها نشان داد GRNN نتیجه پیش‌بینی بهتری در مقایسه با MLFN برای جفت‌های مختلف ارز داشته است. همچنین آن‌ها از تکنیک‌های انسمبل در پیش‌بینی بازار تبادل ارز استفاده کردند و استفاده از روش‌های پارتیشن‌بندی سریالی^۳ و سیستماتیک را برای ساخت مدل‌های

Predictive Stochastic Complexity^۱
 Neural Network General Regression^۲
 Serial Partitioning^۳

انسمبل با ساختارهای مختلف NN پیشنهاد دادند. یافته‌ها نشان داد که شبکه انسمبل به‌طور مداوم در پیش‌بینی این بازار عملکردی بهتر از معماری تک شبکه‌ای دارد [۶۰].

اخیراً، مدل‌های پیش‌بینی بازار فارکس، ترکیب بهتری معرفی کرده‌اند، محققان توانستند روش‌های ANN را با چندین متد و روش متداول مانند مدل‌های سری‌زمانی و مدل‌های اقتصادسنجی ادغام کنند تا دقت پیش‌بینی بازار فارکس را افزایش دهند. مقالات موجود چندین مثال از ترکیب ANN ها با روش‌های معمولی مانند سری‌زمانی، روش میانگین متحرک و رگرسیون خودکار^۱ (ARIMA) و غیره دارند. به‌عنوان مثال، یو و همکارانش در [۵۳] به‌لزوم داشتن یک پلت فرم پیش‌بینی انسمبل غیرخطی، روشی ارائه دادند که GLAR ها را با ANN برای بهبود دقت نتایج پیش‌بینی تلفیق می‌کند. مدل جدید به ترتیب با مدل‌های غیرترکیبی از نوع ANN و GLAR مقایسه شد و نتایج نشان داد که پیش‌بینی با استفاده از مدل انسمبل غیرخطی یافته‌های بهتری را از نظر دقت پیش‌بینی ارائه می‌دهد [۵۳].

محققان در سال ۲۰۰۲ یک مدل برای پیش‌بینی داده‌های فارکس به نام SARIMABP را پیشنهاد کردند که شامل یک شبکه عصبی back-propagation و یک مدل SARIMA (ARIMA فصلی^۲) می‌باشد. یافته‌های این مطالعه نشان داد که SARIMABP در مقایسه با یافته‌های SARIMA نتیجه بهتری ایجاد کرده است [۲۱]. و مقادیر انواع خطاها مثل مقادیر MAPE، MAE و MSE همه در مورد SARIMABP کم بودند. علاوه بر این، SARIMABP نسبت به سایر تکنیک‌های پیشنهادی، در مقادیر ارزیابی مانند MAPE، MAE و MSE، عملکرد بهتری داشته است [۲۱]. یکی از محققان به نام ژانگ^۳ در سال ۲۰۰۳ یک مدل ترکیبی جدید را توسعه داد که با ترکیب مدل‌های ANN و ARIMA ساخته شده بود و با استفاده از نقاط قوت بالقوه در مدل‌های غیرخطی و خطی باعث بهبودی در پیش‌بینی سری‌زمانی شد [۲۱]. یافته‌های این مطالعات در مورد مجموعه داده‌های واقعی نشان داد که مدل پیشنهادی روشی

^۱ Auto-Regression Integrated Moving Averages

^۲ Seasonal ARIMA

^۳ Zhang

مطمئن و موثر برای بهبود پیش‌بینی‌های بازار فارکس نسبت به مدل‌های استفاده شده به صورت جداگانه ارائه می‌دهد. همچنین برخی از محققان در [۵۵] مشاهده کردند که بنظر می‌رسد مدل‌های خطی در پیش‌بینی‌های کوتاه مدت عملکرد بهتری دارند و عمدتاً زمانیکه انحرافات و تعادل بازار اندک باشد. در مقایسه، مدل‌های غیرخطی افق‌های بلند مدت را تحت سلطه خود قرار می‌دهند، عمدتاً وقتی انحراف و تغییر زیاد باشد [۵۵].

با این حال، یکی از محدودیت‌های این تکنیک‌ها این است که آنها نمی‌توانند اطلاعات طولانی مدت را بخاطر بسپارند. به همین ترتیب، این پایان نامه استفاده از مدل ترکیبی که بخشی از آن LSTM می‌باشد را پیشنهاد می‌کند، که می‌تواند اطلاعات طولانی مدت را در مقایسه با سایر سیستم‌های هوش مصنوعی بخاطر بسپارد. Kraus و Fischer در سال ۲۰۱۸ از LSTM برای پیش‌بینی حرکت و جهت نمودار قیمت در بازه‌ای بین سالهای ۱۹۹۲ و ۲۰۱۵ استفاده کردند [۵۶]. محققان گزارش دادند برای بازه‌های طولانی مدت عملکرد LSTM بسیار بهتر است، زیرا برخلاف مدل‌های خطی که قادر به اعمال توابع فعالسازی غیرخطی نبودند، LSTM در سری‌های زمانی غیرخطی مفید و موثر است. یعنی همانطور که میدانیم غیرخطی بودن داده‌های عظیم مالی توسط مدل یاد گرفته می‌شود. در نتیجه LSTM پیش‌بینی‌ها را بسیار دقیق‌تر می‌کند [۱۳، ۵۶]. و در ادامه باتوجه به مزایای آن، LSTM به عنوان گزینه‌ای برای پیش‌بینی بازار فارکس در این پایان نامه انتخاب شده است.

۲-۳-۵ یادگیری عمیق

در سال‌های اخیر، دانشمندان توانسته‌اند با استفاده از روش‌های یادگیری عمیق در حوزه‌های بینایی ماشین، تشخیص گفتار و برخی از مسائل شناسایی مانند شناسایی شخصیت با کمک دست نویس به نتایج چشمگیری برسند. تفاوت اصلی بین روش‌های سنتی و یادگیری عمیق این است که ساختار شبکه را می‌توان برای داده‌های خاص و انواع هدف براحتی تنظیم کرد [۲۱]. یادگیری عمیق مجموعه‌ای از

واحدها مانند واحد کانولوشن^۱ [۱۶]، واحد بازگشتی^۲ [۱۳]، واحد بازگشتی دروازه^۳ [۱۳] و واحد حافظه بلند-کوتاه مدت^۴ [۱۳] را برای استخراج ویژگی در نمونه‌هایی با ویژگی‌های مختلف فراهم می‌کند. فرایند استخراج ویژگی می‌تواند در شبکه‌ها ادغام شود و ساختارهای شبکه می‌توانند باتوجه به ویژگی‌های نمونه‌ها به صورت هدفمند طراحی شوند. مثلاً GoogLeNet و AlexNet [۲۱] برای افزایش توانایی یادگیری اطلاعات، از داده‌های پیکسل طراحی شده‌اند. شبکه عصبی AOA^۵ برای استخراج خودکار ویژگی‌ها از داده‌های متنی که می‌تواند در درک مطلب کاربرد داشته باشد، طراحی شدند. و یا CNN- LSTM برای تشخیص گفتار و یا R-CNN برای تشخیص ابعاد مقیاس پذیر پیشنهاد شده است [۱۶، ۲۱].

توانایی یادگیری شبکه‌ها می‌تواند با رشد عمق شبکه‌ها افزایش یابد. با این حال، ممکن است مشکلاتی مانند انفجار و ناپدید شدن شیب^۶ [۲۴] ایجاد شود. ترفندهایی مانند حذف تصادفی^۷، نرمال‌سازی دسته‌ای^۸ [۱۱] و غیره برای مقابله با این مشکلات و افزایش کارایی آموزش ارائه شده است.

برخی از روش‌های یادگیری عمیق در پیش‌بینی قیمت سهام استفاده شده است. به‌عنوان مثال یک شبکه عمیق کلاسیک برای مدل‌سازی داده‌های جریان با استفاده از ماشین بولتزمن به‌روز شد و عملکرد خوب آن با استفاده از برنامه پیش‌بینی نرخ بورس تأیید شد [۱۱]. همچنین شبکه عصبی بازگشتی برای طبقه‌بندی سیگنال تجاری اعمال شد، و توانست توانایی خود را برای بدست آوردن رابطه غیرخطی بین کندل‌های قیمت در بازه کوتاه مدت به نمایش گذاشت.

با این حال، بیشتر این کارها با استفاده از شبکه‌های عمیق تک نوع برای پیش‌بینی قیمت بازارهای مالی در قالب زمانی بلند مدت متمرکز شده‌اند. اگرچه برخی از آنها استخراج و انتخاب ویژگی را قبل از تغذیه

^۱ Convolutional

^۲ Recurrent

^۳ Gate Recurrent

^۴ Long-Short Memory Term

^۵ Attention-Over-Attention Neural Network

^۶ Exploding and Vanishing Gradient

^۷ Dropout

^۸ Batch Normalization

نمونه‌ها به شبکه‌ها انجام داده‌اند، اما توانایی شبکه‌های عمیق برای استخراج خودکار ویژگی بسیار بالا می‌باشد. در مجموع باید اشاره کرد که یادگیری و استخراج ویژگی، ساختار شبکه متناسب و یکپارچه به سختی در سری‌های زمانی مالی مورد بررسی قرار گرفته است. ما در این پایان نامه این شکاف را برطرف می‌کنیم و عملکرد استخراج و مهندسی ویژگی مبتنی بر یادگیری عمیق را در سری‌های زمانی مالی بررسی می‌نماییم.

۲-۴ جمع‌بندی

در این فصل ابتدا مروری بر مفاهیم بازار تبادل ارزهای خارجی داشتیم و خصوصیات آن را بیان کردیم. سپس به بیان پیچیدگی بازار فارکس و تحلیل کارهای انجام شده، در حوزه‌های، سری‌های زمانی و یادگیری ماشین پرداختیم. مرحله‌ی آخر به بررسی مفهوم یادگیری عمیق و شرح کارکرد دو مدل استاندارد CNN و LSTM پرداختیم. ما با بررسی انواع کارهای انجام شده به وسیله یادگیری ماشین برای پیش‌بینی بازارهای مالی دریافتیم که می‌توان با تمرکز بر روی پیش‌پردازش و استفاده از یادگیری عمیق، سیستمی هوشمند جهت پیش‌بینی بازار تبادل ارز ارائه داد. جدول ۱-۲ روش‌های مطرح و ارائه شده در مقالات را به طور خلاصه نمایش می‌دهد.

جدول ۱-۲ شرح خلاصه‌ای از فعالیت‌های کارهای پیشین

روش	روش پیشنهادی در هر مرجع
	انواع دادگان ارائه شده در مقالات مختلف
Full indicators [۳]	در این روش تمام اندیکاتورهای شاخص‌های یک تحلیل مثل تکنیکال یا فنی به طور کامل پیاده سازی می‌شود و سپس ویژگی‌های اندیکاتورهای به عنوان ویژگی در دادگان استفاده می‌شود. عملکرد این روش در بهترین حالت برابر با ۴۴.۳۵٪ می‌باشد.
Raw indicators [۲]	در این روش ویژگی‌های دادگان برابر با ویژگی‌های اصلی بازار است که شامل: قیمت باز شدن، قیمت بسته شدن، بیشترین قیمت در کندل، کمترین قیمت در کندل و اختلاف بین بیشترین و کمترین قیمت. عملکرد این روش در بهترین حالت برابر با ۴۳.۵٪ می‌باشد.

این دادگان ارائه شده تمام اندیکاتورها و شاخص‌های مورد تایید متاتریدر را پیاده‌سازی میکند و سپس ویژگی‌های هر شاخص را استخراج و به عنوان feature در دیتاست استفاده می‌کند. عملکرد این روش برابر با ۵۳.۶٪ می‌باشد.	based on MetaTrader features [۱۶]
در این دادگان، خاصیت‌های هرس شده‌ی شاخص‌های مورد تایید متاتریدر به عنوان ویژگی استفاده شده است. روش هرس کردن ویژگی‌ها با کمک ضریب همبستگی بوده است. عملکرد این دادگان و تاثیرش بر دقت مدل در بهترین حالت برابر با ۵۵.۲٪ می‌باشد.	MetaTrader pruned indices [۲۱]
روش‌های برچسب‌گذاری	
در این روش براساس روند موجود در هر کندل برچسب‌گذاری انجام می‌شود. به این صورت که اگر روند مثبت باشد کندل وارد کلاس یک می‌شود و اگر روند منفی باشد وارد کلاس منفی یک می‌شود. از معایب این روش عدم تحلیل بازار در آینده و گذشته می‌باشد. دقت حاصل از روش دودویی برابر با ۵۲.۳۵٪ است.	Binary [۶]
روش افق ثابت یکی از پرکاربردترین روش‌های برچسب‌گذاری می‌باشد. در این روش براساس تعیین یک حد آستانه و بررسی بازار در آینده در هر کندل برچسب‌گذاری انجام می‌شود. دقت استفاده از این روش برابر با ۶۱.۴۷٪ می‌باشد.	Fixed- Time Horizon [۶]
مدل‌های هوشمند جهت پیش‌بینی بازار	
در این مقاله با استفاده از شبکه عصبی عمیق ترکیبی CNN-LSTM، مدلی برای پیش‌بینی بازار سرمایه مثل بورس نیویورک طراحی کرده است. دقت نهایی حاصل از این روش برابر با ۸۳.۴۵٪ می‌باشد.	[۱۶]
محققان در این مقاله مشاهده کردند که بهترین اندازه پنجره زمانی، برای LSTM ها ده می‌باشد. عملکرد شبکه GA-LSTM با استفاده از MAPE و MAE بر روی قیمت‌های بسته شدن واقعی ارزیابی شد. دقت پیش‌بینی مدل معیار، تنها ۴۵.۲٪ بود، در حالی که با استفاده از MSE دقت پیش‌بینی شده توسط GA-LSTM تا ۸۸.۱۸٪ افزایش یافت.	[۱۳]
این مقاله کاربرد بهینه سازی کلونی مورچه ها (ACO) را برای بهبود شبکه های عصبی LSTM از طریق ساختارهای سلولی تصفیه شده مورد بررسی قرار داد. داده های مورد استفاده برای آموزش از	[۲۵]

سوابق پرواز و ارتعاشات هواپیمایی به دست آمد. نتایج ، تاثیر LSTM مبتنی بر ACO را تأیید کرد، هنگامی که تنوع ساختار LSTM ایجاد و ارزیابی شد. سلول‌های تکامل یافته و جدید LSTM عملکرد بهتری برای پیش بینی (تا ۱.۳ درصد) داشتند.	
---	--

فصل ۳ : روش پیشنهادی

۱-۳ مقدمه

در فصل اول به تعریف مسئله پرداخته شد و در ادامه تعدادی از فعالیتهای پیشین مورد بررسی قرار گرفت، سپس برخی از مفاهیم اولیه در مورد بازار تبادل ارز مرور گردید. در این فصل نحوه پیش‌بینی روند، در بازار فارکس با استفاده از مدل یادگیری عمیق ارائه شده است. بخش ۳.۲ کار مقدماتی برای آموزش شبکه‌عصبی عمیق، از جمله جمع‌آوری داده‌های خام و منطق آن، انتخاب ویژگی و تجزیه و تحلیل استراتژی‌های مختلف جهت تولید ویژگی‌های جدید را معرفی می‌کنیم. در بخش ۳.۳، روش‌های مربوط به هدف‌گذاری و همچنین روش‌های رایج در این حوزه مورد ارزیابی و بررسی قرار می‌گیرد و محدودیت‌های آن توضیح داده شده است. در بخش آخر، شبکه عصبی CNN-LSTM و طراحی دقیق شبکه آن برای پیش‌بینی بازار فارکس در قالب زمانی کوتاه مدت توضیح داده شده است. عملکرد استفاده از این مدل در پیش‌بینی روند بازار نیز در این بخش بیان شده است.

۲-۳ جمع‌آوری داده‌ها

۱-۲-۳ جفت ارزهای رایج

در کل جهان نزدیک به ۲۰۰ کشور وجود دارد و بسیاری از کشورها ارزهای خاص خود را دارند. اگرچه برخی از کشورها از یک ارز واحد استفاده می‌کنند، مانند کشورهای اروپایی که در آن‌ها از یورو استفاده می‌شود، اما هنوز تعداد زیادی ارز منحصر بفرد در جهان وجود دارد. پیش‌بینی‌های دقیق قیمت ارز مبادله‌ای نه تنها به معامله‌گران فارکس کمک می‌کند، بلکه شرکت‌های بین‌المللی نیز استراتژی‌های صحیحی برای معاملات اتخاذ می‌کنند [۱۴، ۱۵].

در این تحقیق از جفت ارز GBP/USD برای پیش‌بینی روند بازار فارکس استفاده می‌شود. استفاده از ارزهای اصلی به‌عنوان دادگان از این رو ارزشمند است که حجم بالای معاملات آنها باعث اتکا بیشتر به

تحلیل‌های فنی می‌شود [۱۵]. جفت ارز انتخاب شده از مشهورترین و پر معامله‌ترین جفت ارزهای رایج می‌باشد همچنین کشورهای انگلیس و ایالات متحده از قدیمی‌ترین اقتصادهای مدرن در جهان هستند. از نظر سیاسی بسیار نزدیک به هم می‌باشند، اهمیت این موضوع از این رو است که منازعات سیاسی میتواند بر نوسانات جفت ارزها تاثیرگذار باشد [۱۴]. همچنین دو کشور میزان زیاد ایمنی را نشان می‌دهند به این معنا که دارای ثبات ارزی می‌باشند و در بین سرمایه‌گذاران این موضوع بسیار مهم است [۱۴]. نقدینگی و حجم بسیار زیادی در این جفت وجود دارد. نقدینگی فراوان، ورود و خروج معامله‌گرها را به راحتی در بازار امکان پذیر می‌کند. و همچنین کسب اطلاعات در مورد دو کشور در مقایسه با سایر کشورها مانند چین نسبتاً آسان می‌باشد [۱۴].

۲-۲-۳ شاخص‌های بازار و جمع‌آوری داده‌ها

روزانه به‌طور معمول چهار واحد قیمت ثبت می‌شود. که عبارتند از: قیمت Open، قیمت High، قیمت Low و قیمت Close. به‌طور کلی، مقدار Close، سطح قیمت برای یک جفت ارز در بازار فارکس می‌باشد و واحدهای دیگر عمدتاً برای تجزیه و تحلیل فنی استفاده می‌شوند [۹]. در این پایان‌نامه از قیمت Close پنج دقیقه‌ای جفت ارز GBP/USD از ۲۰۱۰/۰۱/۰۱ تا ۲۰۲۰/۰۷/۳۱ به‌عنوان داده‌گان مورد مطالعه، استفاده می‌شود. برای پیش‌بینی دقیق‌تر، از اطلاعات انواع استراتژی و تجزیه و تحلیل فنی در این تحقیق استفاده شده است.

۲-۲-۳ ویژگی‌های استخراج شده از تجزیه و تحلیل فنی

همانطور که در بخش قبل عنوان شد در بازار تبادل ارز معمولاً چهار واحد اساسی به‌عنوان داده‌های فنی ثبت می‌شود، که عبارتند از قیمت باز و بسته، بالاترین و کمترین قیمت و البته باید از مقدار حجم معاملات به‌عنوان پنجمین شاخص نام برد [۱۴، ۱۵]. با این حال، حجم معاملات غیر قابل شمارش است. زیرا فارکس یک بازار فرابورس (خارج از بورس) می‌باشد، این بدان معناست که تجارت بدون نظارت انجام

می‌شود. به همین دلیل، ثبت کل حجم معاملات در سراسر جهان غیرممکن است [۱۴]. بنابراین، فقط چهار قیمت از تجزیه و تحلیل فنی در این پایان‌نامه استفاده شده است، یعنی قیمت افتتاحیه، قیمت بسته شدن، بالاترین قیمت و کمترین قیمت که در هر پنج دقیقه تولید می‌شوند.

براساس این چهار مقدار، شاخص‌های فنی مشتق شده‌ی زیادی وجود دارد [۹]. به‌طور کلی، از شاخص‌های فنی برای تجزیه و تحلیل روابط بین عناصر مختلف از طریق آمار با هدف پیش‌بینی قیمت Close در یک قالب زمانی مشخص مثلاً پنج دقیقه‌ای استفاده می‌شود [۱۵]. همانطور که در فصل ۲ معرفی شد، چهار گروه از شاخص‌های فنی وجود دارد، که شامل حجم، روند، حرکت و نوسانات می‌باشد. از آنجاکه نمی‌توان حجم معاملات فارکس را جمع‌آوری کرد، سه گروه دیگر از شاخص‌های فنی در این تحقیق استفاده می‌شود. در سال ۲۰۱۹ Admiral Markets [۵۷] محبوب‌ترین و معتبرترین شاخص‌ها را در هر گروه ارائه داد، که در ادامه توضیح داده شده است.

۱-۳-۲-۳ شاخص‌های روند

براساس ادمیرال مارکت (Admiral Markets) در [۵۷، ۵۸، ۵۹]، پنج شاخص وجود دارد که به‌عنوان شاخص‌های روند دسته‌بندی می‌شوند، و به شرح زیر می‌باشند:

- **میانگین متحرک^۱:** میانگین متحرک (MA)، یک مقدار به صورت پیوسته از میانگین قیمت

(که می‌تواند قیمت پایانی، قیمت شروع، بیشترین قیمت و یا کمترین قیمت باشد) در طی یک

دوره مشخص حساب می‌شود. فرمول میانگین متحرک به شرح زیر است:

میانگین متحرک (n) کندل: مجموع قیمت‌های پایانی (n) کندل گذشته / (n)

در سری‌های زمانی فارکس، میانگین متحرک ارائه دهنده‌ای از روند قیمت می‌باشد. مثلاً صعودی

یا نزولی بودن قیمت را می‌توان با کمک این شاخص مشاهده کرد، همچنین (MA) در مقابل

^۱ Moving Average

تغییرات کندل جاری به‌طور منصفانه‌ای مقاوم می‌باشد و مقدارش براحتی تغییر نمی‌کند. باید توجه کرد که روند (MA) فقط زمانی تغییر می‌کند که تغییر چشمگیری در قیمت ایجاد شود. علاوه‌بر این (MA) را می‌توان در دوره زمانی‌های مختلف مانند پنج یا ده روز محاسبه نمود. و از مقدار بدست آمده در هر دوره به‌عنوان ویژگی مرتبط استفاده کرد.

• شاخص میانگین جهت^۱:

شاخص میانگین جهت‌دار (ADX) معمولاً قدرت تغییرات قیمت را مشخص می‌سازد اما می‌تواند منعکس کننده جهت روند باشد. (ADX) شامل دو شاخص همراه است، (+DI) و (-DI) و کاربرد آن بدین صورت است که زمانی که (+DI > -DI) قیمت در حال افزایش می‌باشد و قیمت زمانی که در حال کاهش است عبارت (-DI > +DI) برقرار می‌باشد.

معمولاً وقتی که (ADX) زیر ۲۰ باشد روند ضعیف است و زمانی که (ADX) بالای ۲۵ خوانده شود روند قوی می‌باشد و این فرصت خوبی برای خرید یا فروش است. روابط زیر فرمول‌های (ADX) را نشان می‌دهد:

$$+DI = \frac{Smoother + DM}{ATR} * 100$$

$$-DI = \frac{Smoother - Dm}{ATR} * 100$$

$$DX = \frac{+DI - -DI}{+DI + -DI}$$

$$ADX = \frac{(prior ADX * 9) + current DX}{10}$$

که در آن:

$$+DM = \text{Current High} - \text{Previous High}$$

$$-DM = \text{Previous Low} - \text{Current Low}$$

$$\text{Smoothed } +/-DM = \text{sum of 10 periods of DM} - (\text{sum of 10 periods DM} / 10) + \text{Current DM}$$

^۱ Average Directional Index

ATR = با دامنه میانگین ده

دوره زمانی برای (ADX) به طور پیش فرض ۱۴ کندل است، که نشان دهنده دو هفته است، اما چون در فارکس، بازار در آخر هفته بسته می شود، پس می توان (ADX) را برای ده کندل محاسبه کرد. علاوه بر این لازم به ذکر است که:

$$ADX = \frac{\text{sum of 10 DX}}{10}$$

در نتیجه همان طور که پیش تر بیان شد می توان از سه شاخص (+DI, -DI, ADX) استفاده کرد.

• ichimoku Kinko Hyo

- شاخص ایچیموکو یک نمودار با شش عنصر گرافیکی است، که هدف آنها کمک به شناسایی محل حمایت و مقاومت است، همچنین نشان دهنده روند رو به رشد، یا رو به نزول بازار نیز می باشد. عناصر گرافیکی در زیر توضیح داده شده است. (Admiral Markets 2019):

$$\text{Tenkan} - \text{sen} = \frac{(\text{highest high} + \text{lowest low})}{2}$$

به طور متوسط در هفت دوره گذشته

$$\text{Kijun} - \text{Sen} = \frac{(\text{highest high} + \text{lowest low})}{2}$$

به طور متوسط در بیست و دو دوره گذشته

$$\text{Senkou span A} = \frac{(\text{Tenkan} - \text{sen} + \text{Kijun} - \text{sen})}{2}$$

بیست و دو دوره پیش رو رسم می کند.

$$\text{Senkou span B} = \frac{(\text{highest high} + \text{lowest low})}{2}$$

به‌طور متوسط در ۴۴ دوره گذشته و ۲۲ دوره قبل ترسیم شده است.

نمودار قیمت فعلی را در ۲۲ دوره قبل نشان می‌دهد = **Chikouspan**

گپ بین (Senkou Span B) و (Senkou Span A) را نشان می‌دهد = **Komo**

به‌طور سنتی، ایچیموکو از دوره‌های (۹،۲۶،۵۲) استفاده می‌کند، زیرا، در ژاپن و در سال ۱۹۳۰، شش روز کاری در هفته وجود داشت. با توجه به اینکه شاخص مبتنی بر (۱.۵ هفته، یک ماه و دو ماه) است، دوره در این تحقیق به (۷،۲۲،۴۴) تغییر یافته است.

شایان ذکر است (Chikou Span) داده‌ها را به ۲۶ دوره زمانی قبل منتقل می‌کند. به این معنی که داده‌های قبلی از داده‌های آینده به عنوان شاخص استفاده می‌کنند. بر این اساس از چیکواسپن در این تحقیق استفاده نمی‌شود تا بتوان از تاثیر در داده‌ای آینده جلوگیری شود. علاوه بر این ابر موکو را نمی‌توان با اعداد نشان داد، زیرا فقط یک نمودار برای کمک به سرمایه‌گذار در تجزیه و تحلیل است. بنابراین از ابر موکو هم استفاده نخواهد شد. اما از آن به عنوان سیگنال استفاده می‌شود. که در ادامه به آن می‌پردازیم.

• میانگین متحرک همگرایی / واگرایی^۱:

میانگین متحرک همگرایی / واگرایی (MACD) یک شاخص برای تشخیص شتاب گرفتن، روند است. (MACD) توسط (Gerald Appel) در سال ۱۹۷۰ ساخته شده است. (Ye et al) (۲۰۱۶). محاسبه (MACD) را بشرح زیر می‌باشد:

$$EMA_{12} = \frac{11}{13} \times EMA_{12} \text{ of last day} + \frac{2}{13} \times \text{the closing price of day}$$

$$EMA_{26} = \frac{25}{27} \times EMA_{26} \text{ of last day} + \frac{2}{27} \times \text{the closing price of day}$$

^۱ Moving Average Convergence/Divergence

$$DIF = EMA_{12} + EMA_{26}$$

$$DEA = \frac{8}{10} \times DEA \text{ of last day} + \frac{2}{10} \times DIF$$

$$MACD = (DIF - DEA) \times 2$$

توجه داشته باشید که:

$$EMA_n = \text{SUM of the close price for past } n \frac{\text{day}}{n}$$

در نهایت برای MACD، از سه شاخص (DIF, DEA, MACD) در این تحقیق استفاده شده است.

• شاخص سهموی توقف و برگشت^۱:

شاخص (Parabolic Stop and Reverse Indicator) یا باختصار (PSAR) توسط یک معامله‌گر برای تعیین جهت روند و برگشت احتمالی قیمت استفاده می‌شود. محاسبه (PSAR) بسیار پیچیده است، این معادله که به‌وسیله (Ursell) در سال ۲۰۱۵ ساخته شده است، به‌عنوان راهنما برای پیاده‌سازی (PSAR) استفاده می‌شود.

$$\begin{aligned} \text{Rising PSAR} &= \text{Prior PSAR} + [\text{Prior AF} (\text{Prior EP} - \text{Prior PSAR})] \\ \text{Falling PSAR} &= \text{Prior PSAR} - [\text{Prior AF} (\text{Prior EP} - \text{Prior PSAR})] \end{aligned}$$

و از معادله‌ها:

AF

= Acceleration Factor. It starts at 0.02 and increases by 0.02 up to a maximum of 0.2 each time the extreme point makes a new low (falling SAR) or high (rising SAR)

EP = Extreme Point. The lowest low in the current downtrend (falling SAR) or the highest high in the current uptrend (rising SAR)

به‌عنوان یک شاخص مهم استخراج شده از (PSAR) در این تحقیق استفاده می‌شود.

۲-۳-۲ شاخص‌های حرکت^۱:

سه شاخص اصلی به‌عنوان شاخص‌های حرکت طبقه‌بندی شده‌اند این شاخص‌ها که توسط Admiral Markets گزارش شده‌اند. و ما آنها را در زیر توضیح داده‌ایم:

• شاخص مقاومت نسبی^۲:

شاخص مقاومت نسبی (RSI) یک اندیکاتور از نوع حرکتی است که اندازه تغییر قیمت را اندازه می‌گیرد (Chen, 2019). در این تحقیق، (RSI) در یک دوره ۵ و ۱۴ روزه محاسبه شده است. که فرمول آن بشرح زیر می‌باشد:

$$RSI(STEP\ one) = 100 - \left[\frac{100}{1 + \frac{Ave\ Gain}{Ave\ loss}} \right]$$

(Ave Gain) یا (Ave Loss) به‌ترتیب میانگین درصد سود یا زیان طی یک دوره مشخص می‌باشد. باید توجه داشت که از مقادیر مثبت برای محاسبه میانگین خطا استفاده می‌شود. بعد از اولین (RSI)، (RSI) بعدی بشرح زیر محاسبه می‌شود:

$$N\ days\ RSI(STEP\ two) = 100 - \left[\frac{100}{1 + \frac{Previous\ Ave\ Gain \times (N - 1) + Current\ Gain}{Previous\ Ave\ Loss \times (N - 1) + Current\ Loss}} \right]$$

• نوسان‌ساز تصادفی^۳:

نوسان‌ساز (Oscillator)، شاخصی حرکتی است که یک قیمت بسته شدن خاص را با قیمت بسته شدن در یک دوره مقایسه می‌کند. (Hayes (2019) برای نوسان‌ساز (Oscillator) این معادلات را ارائه داد:

$$\%K = \left(\frac{C - L14}{H14 - L14} \right) \times 100$$

^۱ Momentum Indicators

^۲ Relative Strength Index

^۳ Stochastic Oscillator

که در آن:

(C): آخرین قیمت بسته شدن است

(L14): کمترین قیمت در ۱۴ روز گذشته

(H14): بیشترین قیمت در ۱۴ روز گذشته

(%K): (این المان شاخص تصادفی بودن را نشان می‌دهد)

یک شاخص دیگر به نام (fast-stochastic) به صورت $(\%D = 3)$ تعریف می‌شود، که در آن وقتی %K از %D عبور می‌کند، سیگنال‌های معامله را نشان می‌دهد. در این تحقیق از %K و %D استفاده می‌شود.

▪ دامنه ویلیامز^۱:

معادله (Williams % range) ($R\%$)، برای نشان دادن نقاط ورود و خروج استفاده می‌شود که این معادله در ادامه نشان داده می‌شود:

$$\text{Williams \% R} = \frac{(\text{Nth High} - \text{Close price})}{(\text{Nth High} - \text{Nth Low}) \times 100}$$

که در آن "Nth High" مخفف بیشترین قیمت High و "Nth Low" مخفف کمترین قیمت LOW می‌باشد. در این تحقیق از $N = 14$ استفاده شده است.

۳-۲-۳ شاخص‌های نوسانات^۲

همچنین سه شاخص وجود دارد که به عنوان شاخص‌های نوسانات گزارش شده توسط (Admiral Markets 2019) گروه‌بندی شده‌اند. آنها بشرح زیر می‌باشند:

• دامنه متوسط واقعی^۳:

متوسط دامنه واقعی (ART)، برای نشان دادن نوسانات بازار استفاده می‌شود و این معیار اندازه‌گیری نوسانات توسط (Wilder 1978) معرفی شد که معادلات آن در زیر بررسی شده‌اند:

^۱ Williams Range

^۲ Volatility Indicators

^۳ Average True Range

$$ATR(first) = \frac{1}{N} \sum_{i=1}^n TR_i$$

$$ATR = \frac{\text{Previous ATR} \times 13}{14} + \frac{TR}{14}$$

که در آن:

$$TR_i = \max[(\text{high} - \text{low}) \text{abs}(\text{high} - \text{previous close}) \text{abs}(\text{low} - \text{previous close})]$$

و

n: دوره زمانی به کار گرفته شده (در اینجا ۱۴ کندل)

• گروههای بولینگر^۱:

بولینگر بند (BBs) می‌تواند در همه بازارهای مالی اعمال شود و در بیشتر بازه‌های زمانی استفاده شود. این شاخص از سه خط تشکیل شده است: یک خط MA و دو خط که مقادیر آنها دو برابر انحراف معیار از MA هستند. فرمول‌های (BBs) در دوره ۲۰ کندلی بشرح زیر می‌باشد:

$$\text{Upper band} = \text{MA} + 2 \times \text{Standard deviation}$$

$$\text{Middle band} = \text{MA}$$

$$\text{Lower band} = \text{MA} - 2 \times \text{Standard deviation}$$

$$\text{standard deviation} = \sqrt{\frac{\sum_{j=1}^n (x_j - \text{MA})^2}{n}}, n = 20$$

در نتیجه، برای استفاده از (BBs) سه شاخص اصلی (بالا، میانه و پایین) وجود دارد.

• نمونه انحراف استاندارد:

نمونه انحراف معیار (SSD)، برای اندازه‌گیری تغییر بین قیمت فعلی و میانگین استفاده می‌شود، SSD یک اندازه‌گیری آماری در امور مالی برای انعکاس اطلاعات گذشته است.

$$\text{Sample standard deviation} = \sqrt{\frac{\sum_{j=1}^n (x_j - \text{MA})^2}{n - 1}}, n = 20$$

۴-۳-۲-۳ خلاصه شاخص های تجزیه و تحلیل فنی

به عنوان مبنای شاخص تجزیه و تحلیل فنی، قیمت های Open، High، Low، Close و تغییرات قیمت نیز مطابق جدول ۳.۱ در نظر گرفته شده است. بنابراین در مجموع، ۲۴ شاخص از تجزیه و تحلیل فنی وجود دارد که می تواند در این تحقیق استفاده شود (در جدول ۳.۲ نشان داده شده است).

جدول ۳-۱ پنج قیمت اساسی بازار تبادل ارز

قیمت بسته شدن کندل در GBP/USD	واحدهای پایه و اساسی در تجزیه و تحلیل فنی برای جفت ارز GBP/USD
قیمت باز شدن کندل در GBP/USD	
بیشترین قیمت کندل در GBP/USD	
کمترین قیمت کندل در GBP/USD	
فاصله بین بیشترین و کمترین قیمت کندل در GBP/USD	

جدول ۳-۲ شاخص های فنی مورد استفاده در این تحقیق

شاخص های مشتق شده	شاخص فنی	گروه شاخص های فنی
با دوره ۵ در نوع SMA	Moving Average	شاخص های روند
با دوره ۱۰ در نوع SMA		
دوره ۱۰ +DI	Average Directional Index	
دوره ۱۰ -ID		
Adx		
Tenkan-sen	Ichimoku Kinko Hyo	
Kijun-sen		
Senkou span A		
Senkou span B		
DIF	میانگین متحرک همگرایی / واگرایی	
DEA		
MACD		
PSAR	شاخص توقف و برگشت	
PSAR TREND		
۵ کندل برای قدرت نسبی	Relative Strength Index (RSI)	شاخص های حرکتی
۱۴ کندل برای قدرت نسبی		
k'.	Stochastic Oscillator	

d%		شاخص‌های نوسانی
R%	Williams % range (%R)	
دوره ۱۴ کندلی ATR	Average True Range (ATR)	
خط میانی	Bollinger Bands (BB)	
خط بالایی		
خط پایینی		
انحراف معیار	انحراف معیار	

در ادامه با بررسی استراتژی‌های رایج در بین معامله‌گران و همچنین با بررسی سیگنال‌های خروجی شاخص‌ها، ویژگی‌های جدیدی به دادگان مان اضافه می‌کنیم. البته لازم بذکر است مقادیر مجاز برای این ویژگی‌ها عدد ۱، ۰ و ۱- می‌باشد که بترتیب نمایانگر بازار و روند صعودی، روند نوسانی یا خنثی و همچنین بازار و روند نزولی هستند. همچنین باید گفت اغلب استراتژی‌ها و سیگنال‌های شاخص‌ها بر اساس کتاب بیل ویلیامز استخراج شده است.

▪ میانگین متحرک:

طبق گفته ویلیامز از میانگین متحرک بسیار استفاده می‌شود، این شاخص پایه و اساس بسیاری از شاخص‌های دیگر می‌باشد. همچنین بسیاری از استراتژی‌های پر کاربرد حال حاضر از این شاخص استفاده می‌کنند.

باتوجه به موقعیت میانگین متحرک در نمودار میتوان سیگنال متناسب استخراج کرد. که در زیر چند مورد آن را بررسی می‌کنیم.



شکل ۱-۳ میانگین متحرک

همانطور که در بالا ذکر شد در دادگان از دو میانگین متحرک با دوره‌های ۵ و ۱۰ استفاده می‌شود که بسته به موقعیت‌شان نسبت به هم و نسبت به نمودار معنای خاص و سیگنالی را به معامله‌گران نشان می‌دهند.

همان گونه که در شکل مقابل مشاهده می‌کنیم علاوه بر نمودار دو خط قرمز و آبی در شکل مشاهده می‌شود که خط آبی شاخص میانگین متحرک با دوره ۵ و خط قرمز با دوره ۱۰ را نشان می‌دهد. اولین سیگنال دریافتی از شاخص‌ها این است که هرگاه هر دو خط بالای نمودار باشند روند نزولی را نشان می‌دهند و برعکس، همچنین سیگنال دیگری که می‌توان از این شاخص دریافت کرد زمانی است که خط آبی در بالای نمودار باشد و خط قرمز آن را از پایین قطع کند و بالعکس، در این صورت یک سیگنال قوی فروش/خرید دریافت می‌شود.

▪ Average Directional Index : از این شاخص به این صورت سیگنال می‌گیریم که اگر مقدار



شکل ۳-۳ ADX

خط آبی (ADX) بیشتر از ۲۵ را نشان می‌داد و اگر خط -DMI (قرمز) بالای سبز بود به معنی نزول روند می‌باشد و بالعکس، همچنین اگر خط آبی از ۲۵ کمتر بود یعنی بازار در حالت خنثی یا نوسانی قرار دارد.


		Bullish Divergence	Bearish Divergence
Strong	Price		
	Oscillator		
Hidden	Price		
	Oscillator		

شکل ۳-۲ واگرایی همگرایی

▪ حالت واگرایی و همگرایی: این حالت ممکن است برای تمام شاخص‌های روند پیش بیاید، وقتی که ما نمودار شاخص را با قیمت مقایسه می‌کنیم. به دو قله یا دره آخر هر دو نگاه


می‌کنیم. وضعیت این دو قله/دره نسبت به هم یکی از حالات زیر می‌باشد که به‌عنوان مثال اگر دو قله در نمودار قیمت صعودی باشند ولی در شاخص نزولی واگرایی رخ داده است و احتمال روند نزولی را می‌دهد.

- MACD: نحوه سیگنال گرفتن از این شاخص می‌تواند براساس مقایسه قله و دره‌های MACD با نمودار قیمت باشد.



شکل ۳-۴ MACD

- یعنی همان بحث همگرایی/واگرایی، می‌تواند هم براساس میانگین متحرک تعریف شود.
- Relative Strength Index (RSI): یکی از مشهورترین شاخص‌های ویلیامز RSI می‌باشد.



شکل ۳-۵ RSI

سیگنال گیری از این شاخص با کمک مفاهیم فروش بیش از حد^۱ یا خرید بیش از حد^۲ انجام می‌شود، به این صورت که اگر مقدار شاخص در هریک از این مناطق باشد سیگنال مناسب دریافت می‌شود.

▪ Ichimoku Kinko Hyo: استخراج سیگنال یکی از این شاخص با بقیه متفاوت و سخت‌تر می‌باشد، این شاخص از پنج المان تشکیل شده است که نسبت به موقعیت نمودار قیمت سیگنال استخراج می‌کنند. به عنوان مثال یکی از استراتژی‌ها قرار گرفتن خطوط کیجون‌سن و تنکن‌سن در زیر نمودار قیمت و همزمان وجود ابرموکو به رنگ سبز نشان دهنده سیگنال صعودی می‌باشد.



شکل ۶-۳ ایچی موکو

۴-۲-۳ آنالیز و انتخاب ویژگی

استفاده از استراتژی‌های رایج به عنوان ویژگی، همچنین سیگنال‌های استخراج شده از عناصر استراتژی، در کنار انواع شاخص‌های فنی، عملکرد و قابلیت اطمینان پیش‌بینی روند در بازار فارکس را بهبود می‌بخشد. ویژگی‌های استخراج شده از استراتژی‌های رایج را می‌توان علل تغییرات قیمت در بازار فارکس دانست. و شاخص‌های مورد استفاده در تجزیه و تحلیل فنی نتایج تغییرات مداوم قیمت می‌باشد که شامل تجزیه و تحلیل آماری گذشته است.

^۱ Oversell

^۲ Overbuy

۱-۴-۲-۳ انتخاب ویژگی^۱

در کنار هم قرار دادن تمام شاخص‌های تحلیل فنی و همچنین ویژگی‌های مستخرج از استراتژی‌ها و سیگنال‌های انواع شاخص‌ها، در مجموع ۷۵ ویژگی/شاخص بوجود می‌آورد که همگی مرتبط با تجزیه و تحلیل و پیش‌بینی روند در بازار فارکس هستند. با این حال، این ویژگی‌ها از قابلیت‌ها و سودمندی‌های متنوعی در پیش‌بینی روند بازار برخوردارند، بنابراین بررسی اینکه اولین ویژگی‌ها چه تأثیراتی دارند بسیار ضروری است [۱۶،۲۱]. علاوه بر این، چنین مجموعه بزرگی از ویژگی‌ها بر روی آموزش شبکه عصبی عمیق نیز تأثیر می‌گذارد، بنابراین برای مقابله با داده‌های ابعاد بالا باید انتخاب ویژگی اعمال شود [۱۳]. انتخاب ویژگی گام مهمی در تجزیه و تحلیل داده‌ها است [۲۱]، زیرا می‌تواند ابعاد داده را کاهش دهد. داده‌هایی با ابعاد بالا اغلب در عمل مشکلاتی ایجاد می‌کنند، مانند [۲۱]:

- زمان بیشتری برای آموزش صرف می‌کند.
 - مشکلات بیش‌برازش^۲ را بدنبال دارند.
- هدف از انتخاب ویژگی حذف ویژگی‌هایی که ممکن است در آموزش سیستم کم استفاده شوند [۲۱]. داشتن ویژگی کمتر، می‌تواند به کاهش پیچیدگی سیستم کمک کرده و مشکل بیش‌برازش را کاهش دهد [۱۱،۱۳،۱۶].

آندره و همکارانش در سال ۲۰۰۳ در [۶۱] این جمله را نقل می‌کنند: "هدف از مرحله انتخاب ویژگی سه مورد است: بهبود عملکرد پیش‌بینی‌ها، ارائه پیش‌بینی‌های سریعتر و مقرون به صرفه‌تر و همچنین ارائه درک بهتر از روند اساسی تولید داده‌ها."

سه نوع روش انتخاب ویژگی وجود دارد: Filter [۶۸]، Wrapper و Embedded Methods [۲۹،۶۸]. روش Filter با محاسبه واریانس هر ویژگی، ارتباط بین ویژگی‌ها و خروجی سیستم را اندازه‌گیری می‌کند

^۱ Feature Selection
^۲ Overfitting

(به عنوان مثال، روش انتخاب ویژگی مبتنی بر همبستگی^۱). روش Wrapper با استفاده از انتخاب ویژگی متوالی^۲، با افزودن هر بار ویژگی برای آزمایش عملکرد سیستم، ویژگی‌ها را انتخاب می‌کند. روش جاسازی شده شامل روش‌های قاعده‌گذاری L1، L2 و روش مبتنی بر درخت تصمیم‌گیری^۳ است که نمره اهمیت هر ویژگی را محاسبه می‌کند و ویژگی‌هایی را با نمرات بالاتر انتخاب می‌کند [۶۸]. در مقایسه با سایر روش‌ها، روش انتخاب ویژگی مبتنی بر تصمیم به دلیل توانایی انتخاب ویژگی‌هایی که برای طبقه‌بندی مهم هستند، کاملاً مشهور است [۶۸].

همانطور که میدانیم پیش‌بینی روند بازار فارکس، به مساله طبقه‌بندی تعلق دارد [۲۱]. ما در این پایان‌نامه، از انتخاب ویژگی مبتنی بر درخت تصمیم استفاده می‌کنیم، البته دلیل اصلی استفاده از انتخاب ویژگی مبتنی بر درخت تصمیم این است که می‌تواند روابط غیرخطی و فعل و انفعالات بین متغیرها را کشف کند. مزایای دیگری نیز برای انتخاب ویژگی مبتنی بر درخت تصمیم وجود دارد، مانند اینکه برای تهیه داده‌ها به تلاش کمتری احتیاج دارد و تفسیر و توضیح آنها آسان است [۶۲].

در این تحقیق، انتخاب ویژگی مبتنی بر درخت تصمیم‌گیری با استفاده از تخمین‌گرهای مبتنی بر تصمیم، از scikitlearn، که یک کتابخانه یادگیری ماشین در پایتون است [۱۱،۲۱] و همچنین SelectFromModel از کتابخانه scikitlearn، حاصل می‌شود. به منظور اجرای انتخاب ویژگی مبتنی بر درخت تصمیم، از دو قطعه کد از sci-kit-learn استفاده می‌شود:

```
clf = ExtraTreesClassifier()
clf = clf.fit(X, Y)
```

که در آن X مجموعه ویژگی‌ها و Y هدف است که باید در کنار ویژگی‌ها محاسبه شود. در این تحقیق، از ۷۵ ویژگی جمع‌آوری شده در بخش قبلی به عنوان ورودی استفاده می‌شود و با توجه به اهداف تعیین شده، که برای اندازه‌گیری اهمیت ویژگی‌های مختلف استفاده می‌شوند. می‌توان انتخاب ویژگی مبتنی بر

^۱ Correlation-Based

^۲ Sequential Feature Selection

^۳ Decision-Tree-Based Method

درخت تصمیم انجام داد. نمونه‌هایی از X و Y در جدول ۳.۳ نشان داده شده است. (لازم بذکر است روش هدف‌گذاری در ادامه شرح داده شده است).

جدول ۳-۳ نمونه‌هایی از دادگان

X					Y
ویژگی شماره ۱	ویژگی شماره ۲	... سایر ویژگی‌ها...	ویژگی شماره ۷۴	ویژگی شماره ۷۵	برچسب
7.7997	7.8051		7.7973	0.007696	-۱
7.796	7.7986		7.7931	0.007725	-۱
6.5418	6.5598		6.5568	0.017958	۰
6.5542	6.5598		6.5334	0.018775	۱


با استفاده از انتخاب ویژگی مبتنی بر درخت تصمیم به ۷۵ ویژگی، نمره اهمیت هر شاخص داده می‌شود که نمره و ترتیب شاخص‌های اصلی در جدول ۳،۴ ذکر شده است.

ویژگی‌ها و نمره اهمیت آنها ۴-۳ جدول

نام	نمره
Low volatility expected level	0.0144256
Medium volatility expected level	0.01573557
High volatility expected level	0.0163292
OPENGBPUSD	0.01766726
HIGHGBPUSD	0.02497798
LOWGBPUSD	0.0210636
change	0.01728699
EURGBP	0.01853005
GBPCNY	0.0250449
GBPAUD	0.01984544
GBPCAD	0.01846976
USDCAD	0.01970475
AUDCAD	0.0160411
5-day MA	0.0199682
10-day MA	0.02040288
+DI10	0.02163546
-DI10	0.02386905
Adx	0.02104654
Tenkan-sen	0.01818315
Kijun-sen	0.01626759
Senkou span A	0.02037011
Senkou Span B	0.01708821
Dif	0.02381489
Dea	0.02307371

macd	0.02357935
PSAR	0.02022879
PSAR TREND	0.01080886
relative strength5	0.02076135
relative strength14	0.02746579
%k	0.02321379
%d	0.02166815
%R	0.01977334
Middle Bollinger band	0.02281278
upper Bollinger band	0.01881956
lower Bollinger band	0.02153124
standard deviation	0.02487522
USDCNY	0.02449895
TR14	0.02363601

هیچ قاعده استاندارد در مورد نحوه انتخاب آستانه (کمترین نمره اهمیت) برای انتخاب ویژگی وجود ندارد. آستانه‌ها معمولاً بسته به برنامه‌های کاربردی و اغلب تجربیات طراح تعیین می‌شوند. در این پایان‌نامه، به‌عنوان آستانه تشخیص ویژگی‌های مهم و غیر مهم انتخاب شده است، زیرا ما با رسم پلات مربوط به نمره‌ها یک شکاف آشکار بین ۰.۰۱۰۸۰۸۸۶ تا ۰.۰۱۴۳۴۴۹۴ پیدا کردیم، همانطور که در شکل ۳.۷ نشان داده شده است.



شکل ۳-۷ نمودار نمره‌ی ویژگی‌ها

در نتیجه، ۳۹ ویژگی ساخته شده بالاتر از ۰.۰۱۴۳۴۴۹۴ (شاخص فرکتالی^۱) تا ۰.۰۲۷۴۶۵۷۹ (۱۴ rsi) کندلی را نشان می‌دهد، و سایر موارد از ۰.۰۰۱۸۰۸۹۹ تا ۰.۰۱۰۸۰۸۸۶ تأثیر بسیار کمتری دارند. لازم

^۱ Fractile

بذکر است ویژگی‌های مهم انتخاب شده به‌عنوان ورودی‌های پیش‌بینی بازار فارکس در پایان‌نامه استفاده می‌شوند.

۳-۳ تعیین هدف و برچسب داده‌ها

۳-۳-۱ مقدمه

همان‌طور که اشاره شد در سالهای اخیر از روش‌های یادگیری ماشین به‌طور گسترده‌ای در پیش‌بینی سری‌زمانی مالی استفاده شده است. نحوه برچسب‌گذاری داده‌های سری‌زمانی مالی، برای تعیین دقت پیش‌بینی مدل‌های یادگیری ماشین و متعاقباً تعیین بازده سرمایه‌گذاری نهایی، موضوع جذابی است [۱۱، ۲۱]. روش‌های موجود برچسب‌گذاری سری‌های زمانی مالی عمدتاً با مقایسه داده‌های فعلی با داده‌های یک دوره کوتاه مدت در گذشته، داده‌ها را برچسب‌گذاری می‌کنند. اما، داده‌های سری‌زمانی مالی معمولاً غیرخطی و آشفته می‌باشند [۲۱]. بنابراین، این روش‌های برچسب‌گذاری ویژگی‌های روند داده‌های سری‌زمانی مالی را به دست نمی‌آورند، و درنهایت منجر به تفاوت بین نتایج برچسب‌گذاری آنها و روند واقعی بازار می‌شود [۲۱]. در این تحقیق، از یک روش برچسب‌گذاری برای رفع مشکل فوق استفاده شده است. در مرحله پیش‌پردازش ویژگی، این روش می‌تواند از مشکل صرف نگاه ثابت به گذشته یا حال در فرآیندهای برچسب‌گذاری داده‌ها جلوگیری کند. همچنین باید اشاره کرد برخی از روش‌های برچسب‌گذاری داده‌ها بسیار پیچیده و سخت‌گیرانه است که منجر به تقسیم‌بندی اکثر داده‌ها در کلاس صفر یا خنثی می‌شود [۱۶].

در مجموع و به‌طور کلی یکی از مهمترین مراحل پیش‌پردازش مرحله برچسب‌زنی داده‌ها می‌باشد [۱۶]. تعیین کلاس برای داده‌ها در حوزه‌های مختلف امری واضح و مشخص است، مثلاً برای تشخیص تصاویر گربه از سگ کافیت به عکس‌های گربه کلاس صفر و برای کلاس سگ برچسب یک را اختصاص دهیم.

اما در مورد داده‌های بازار مالی اوضاع متفاوت است، ما باید در ابتدا برای تعیین هدف داده‌ها را تقسیم بندی کنیم مثلاً آیا قرار است هر داده یک برچسب مخصوص به خود را داشته باشد یا اینکه با تلفیق تعدادی از داده‌ها باهم یک برچسب برای هر دسته از داده‌ها اختصاص داد[۱۶].

در ادامه در ابتدا با مفاهیم پیپ^۱ و پیپت^۲ آشنا می‌شویم سپس با بررسی روش‌های هدف‌گذاری روشی که در این تحقیق استفاده شده است را شرح می‌دهیم.

۳-۳-۲ مفهوم پیپ و پیپت

به علت حجم بالای معاملات در بازار تبادلات ارزی (فارکس) معمولاً نرخ برابری ارزها تا پنج رقم صحیح بعد از اعشار محاسبه می‌شوند. در اغلب موارد، در ارزهای اصلی به جز ین ژاپن برابری ارزها به شکل یک رقم صحیح و چهار رقم اعشار آورده می‌شوند[۱۵،۲۲]. در جفت ارزهایی که نرخ برابری آنها تا چهار رقم اعشار محاسبه می‌شود، به رقم چهارم بعد از اعشار پیپ (Pips) یا (Point) می‌گویند. مثلاً اگر قیمت یورو به دلار از ۱/۳۳۸۲ به ۱/۳۳۸۴ برسد، می‌گوییم ۲ پیپ افزایش یافته است. در جفت ارزهایی که شامل ین ژاپن هستند (و طبق آنچه گفته شد تا دو رقم اعشار محاسبه می‌شوند) رقم دوم بعد از اعشار را پیپ یا پوینت می‌نامیم. به عنوان مثال اگر قیمت GBP/JPY از ۱۸۸/۹۹ به ۱۸۸/۸۸ برسد می‌گوییم ۱۱ پیپ افزایش یافته است[۱۵،۲۲].



۳-۳-۳ روش هدف‌گذاری استفاده شده

محققان در انواع مقالات و کتاب‌ها، روش‌های مختلفی را برای هدف‌گذاری انتخاب کرده‌اند. که به برخی از آنها در ادامه اشاره می‌کنیم.

Pip^۱

Pipet^۲

- روش برچسب‌گذاری باینری: همانطور که می‌دانیم هر کندل در هر قالب زمانی می‌تواند مثبت، منفی و البته دوجی^۱ (خنثی) باشد یکی از روش‌های برچسب‌گذاری استفاده از نوع کندل می‌باشد مثلاً اگر کندل مثبت بود کلاس یک، اگر منفی بود کلاس دو، البته قابل ذکر است در این روش، کلاس دوجی وجود ندارد. توزیع داده‌ها براساس این روش طبق [6] بصورت زیر است.



شکل ۳.۸ توزیع دادگان XAUUSD با روش لیبلینگ باینری [6]


- افق زمان ثابت^۲: در این روش تفاوت بین کلاس‌ها براساس تعیین یک حد آستانه می‌باشد پس اولین کاری که می‌توانیم برای در نظر گرفتن این تفاوت‌ها انجام دهیم افزودن آستانه‌ای است که برچسب‌ها با آن محاسبه می‌شوند. در فصل ۳ از [۷]، توسط مارکوس لویز دو پرادو، روشی بنام افق زمان ثابت به‌عنوان یکی از روش‌های اصلی برای برچسب‌گذاری داده‌ها در هنگام پردازش سری‌های زمانی مالی برای یادگیری ماشین ارائه شده است.

این روش ساده و بسیار پرطرفدار می‌باشد. که می‌تواند با عبارت زیر تعریف شود:

$$y_i = \begin{cases} -1, & \text{if } r_{t_0, t_1} < -\tau \\ 0, & \text{if } |r_{t_0, t_1}| \leq \tau \\ 1, & \text{if } r_{t_0, t_1} > \tau \end{cases}$$

^۱ Doji

^۲ Fixed-Time Horizon



شکل ۳-۸ توزیع داده‌ای براساس برچسب‌گذاری با روش افق زمان ثابت [۶]


روش‌های هدف‌گذاری پیچیده‌ی دیگری نیز وجود دارد مانند روند برچسب‌زدن مداوم^۱ که مهمترین مشکل این روش‌ها نادیده گرفته شدن بسیاری از داده‌ها می‌باشد. تمام روش‌ها مزایا و معایبی دارند اما روش افق زمان ثابت به دلیل سادگی، پرکاربرد بودن و همچنین سازگار بودن با سیستم‌های سخت‌افزاری موجود به عنوان روش برچسب‌گذاری این تحقیق انتخاب شده است.

۳-۳-۴ تجزیه و تحلیل هدف پیش‌بینی

هدف اصلی از تحقیقات بر روی بازارهای مالی معمولاً پیش‌بینی این بازارها بصورت بسیار دقیق برای تجارت بهتر است. بیشتر کارهای موجود در زمینه پیش‌بینی فارکس مربوط به تعیین و حدس قیمت دقیق کندل بعد است [۷۰]. با این حال، طبق گفته Jakob Aungiers، که معاون سابق رئیس تیم استراتژی سرمایه‌گذاری جهانی HSBC Asset Management و بنیانگذار و مدیر عامل شرکت Altum Intelligence است، "آموزش داده‌ها برای پیش‌بینی نقطه به نقطه، احتمالاً باعث می‌شود تا مدل بتواند مقداری خیلی نزدیک به قیمت را برای کندل بعدی پیش‌بینی کند اما توجه کنید، این یک موضوع خیلی فریبنده است!" [۶۳]. این بدان دلیل است که در پیش‌بینی نقطه به نقطه، همیشه یک رابطه قوی بین

^۱ Continuous Trend Labeling

قیمت فعلی و قیمت قبلی وجود دارد - یعنی پیش‌بینی قیمت احتمالی (t) نزدیک به قیمت واقعی (t-1) می‌باشد بنابراین، پیش‌بینی قیمت روز بعد بسیار راحت به قیمت روز قبل می‌چسبد.



شکل ۹-۳ نمودار پیش‌بینی نقطه به نقطه (Ganegedara, 2018)

دلیل مشکل پیش‌بینی بصورت نقطه به نقطه را می‌توان به دو صورت توضیح داد:

۱. Aungiers در [۶۳] توضیح داد که نقطه پیش‌بینی براساس کل مجموعه داده‌های

قبلی می‌باشد. به همین دلیل، روش‌های پیش‌بینی معمولاً نیازی به یادگیری اطلاعات یا الگوی موجود در سری‌های زمانی ندارند. آنها فقط می‌فهمند که محل پیش‌بینی باید نزدیک به نقطه قبلی باشد.


۲. این مسئله را می‌توان از نظر ریاضی نیز توضیح داد. هنگام استفاده از یادگیری

ماشین، میانگین مربع خطا (MSE) یا میانگین خطای مطلق (MAE) و غیره، به‌طور کلی به‌عنوان توابع خطا استفاده می‌شوند. در شبکه‌های عصبی هنگام پیش‌بینی مقدار بعدی، محاسبه خطاهای فعلی بسیار کاربرد دارد. به‌طوری که می‌توان گفت فرآیند آموزش شبکه عصبی فرآیند بهینه‌سازی عملکرد ضرر است [۶۳]. به‌دلیل نوسانات نسبتاً کم قیمت در بازار فارکس در دو کندل متوالی، بعد از بدست آوردن مقدار ضرر متوجه می‌شویم که خطا بسیار کم است پس

می‌توانیم اینگونه پیش‌بینی کنیم که: $Price(t) = Price(t-1)$

همانطور که پیش‌تر گفته شد به‌تازگی، پیشنهادی برای پیش‌بینی روند در بازارهای تبادل ارز به‌جای قیمت دقیق، ارائه شده است که عملی‌تر و مفیدتر خواهد بود [۵۷، ۵۸، ۵۹]. معمولاً دانستن نرخ دقیق ارز برای معامله‌گران مفید نمی‌باشد و آنها به این موضوع علاقه‌ای ندارند. درعوض، آنها بیشتر به جهت حرکت نرخ ارز یا روند بازار علاقه‌مند هستند [۶۴]، که ما در این پایان‌نامه همین موضوع را مد نظر قرار دادیم.

هنگام پیش‌بینی روند آینده یک جفت ارز در بازار فارکس، سه خروجی ممکن است وجود داشته باشد: "افزایش"، "کاهش" و "بدون تغییر". داده‌های مالی یک ویژگی خاص دارند - هرچه اطلاعات بیشتر استفاده شود، نسبت سیگنال/ نویز بهتر است [۶۴]. یعنی پیش‌بینی داده‌های یک کندل بعد، در مقایسه با پیش‌بینی داده‌های ده کندل بعدی، دقت پایین‌تری دارد.



شکل ۱۰-۳ مقایسه پیش‌بینی برای افق‌های زمانی متفاوت

نتیجه نشان می‌دهد که هرچه افق پیش‌بینی طولانی‌تر باشد، دقت پیش‌بینی بالاتر است. با این حال، یک افق پیش‌بینی طولانی منجر به یک فرکانس تجاری پایین و از این رو، احتمالاً سود کمتری خواهد شد. فرکانس پیش‌بینی به معنی تعداد پیش‌بینی‌هایی است که در یک بازه زمانی مشخص اجرا می‌شوند. به‌طور کلی، اگر نتیجه پیش‌بینی افزایش روند باشد، معامله‌گران جفت ارز بازار فارکس را با قیمت پایین خریداری کرده و پس از مدتی مشخص آن را می‌فروشند تا سود کسب کنند. برعکس، اگر نتیجه پیش‌بینی کاهش روند باشد، معامله‌گران می‌توانند برای کسب سود جفت فارکس را "Sell" کنند [۲۲، ۳۱]. در نتیجه، فقط یک معامله در یک افق پیش‌بینی وجود دارد، بنابراین در یک بازه زمانی تعیین شده برای

پیش‌بینی، تعداد معاملات محدودی وجود دارد. به‌عنوان مثال، مقایسه پیش‌بینی با افق پنج‌تایی درمقابل پیش‌بینی با افق ده‌تایی، اولی دو برابر بیشتر از دومی در یک بازه زمانی خاص معامله می‌کند. البته معمولاً تصمیم گرفته می‌شود که افق پیش‌بینی به استراتژی معامله‌گر بستگی داشته باشد. همچنین باید درنظر گرفت که موضوع فرکانس سیگنال اصولاً برای قالب زمانی پایین مطرح نیست [۱۶]. در این تحقیق، پیش‌بینی کندل دهم به‌عنوان افق پیش‌بینی انتخاب شده است.

۳-۴ دادگان آماده شده بعد از مراحل پیش‌پردازش و هدف‌گذاری

۵۲ ویژگی برای پیش‌بینی بازار فارکس در این تحقیق انتخاب شده است. داده‌های معاملات بازار تبادل ارز از تاریخ ۲۰۱۰/۰۱/۰۱ تا ۲۰۲۰/۰۷/۳۱ جمع‌آوری شده است که درنتیجه برای هر ویژگی ۷۶۱،۲۴۶ ارزش وجود دارد. بعد از محاسبه و تعیین هدف و سپس کلاس‌بندی دادگان تعداد داده‌های هر کلاس به‌صورت زیر می‌باشد:

جدول ۳-۴ توزیع داده‌ای بین کلاس‌های مختلف

تعداد	نام کلاس (برچسب)
۱۱۷۱۳۵	کلاس یک (صعودی)
۹۷۱۳۵	کلاس دو (نزولی)
۵۴۶۷۸۶	کلاس صفر (خنثی)

برای حفظ تعادل^۱ در دادگان بعد از کلاس‌بندی داده‌ها، کلاسی که کمترین تعداد داده را دارد مبنای تعادل می‌شود [۱۳، ۲۱]، و تمام کلاس‌ها به آن مقدار تنظیم می‌شوند. که در دادگان این تحقیق هر کلاس ۹۷۱۳۵ نمونه در خود دارد.

^۱ Balance

$\text{minLength} = \min(\text{len}(\text{label_set_zero}), \text{len}(\text{label_set_pos}), \text{len}(\text{label_set_neg}))$

همانطور که توضیح داده شد برای هر کلاس ۹۷،۱۳۵ نمونه وجود دارد پس در مجموع دادگان ما دارای ۲۹۱،۴۰۵ نمونه و ۵۳ ویژگی (با احتساب ویژگی کلاس) می‌باشد. که نمونه‌هایی از آن در جدول زیر نشان داده شده است.


جدول ۳-۵ نمونه دادگان

Date & Time	Feature 1	Feature 2	... (۴۹ data)	Feature 52	class
۲۰۱۰.۰۱.۰۱ ۰۰:۰۰	۱.۶۵۳۰	۱.۵۳۶۰	... (۴۹ data)	۱.۲۵۱۵۴	۱
۲۰۱۰.۰۱.۰۱ ۰۰:۰۵	۱.۶۴۳۰	۱.۵۴۱۵	... (۴۹ data)	۱.۲۵۲۰۱	۱
... (۲۹۱،۴۰۱ data)	... (۲۹۱،۴۰۱ data)	... (۲۹۱،۴۰۱ data)	... (۲۹۱،۴۰۱* ۴۹ data)	... (۲۹۱،۴۰۱ data)	... (۲۹۱،۴۰۱ data)
۲۰۲۰.۰۷.۳۱ ۲۳:۵۰	۱.۳۰۸۰۰	۱.۳۰۸۷۰	... (۴۹ data)	۱.۵۲۸۰	۰
۲۰۲۰.۰۷.۳۱ ۲۳:۵۵	۱.۳۰۸۲۲	۱.۳۰۸۵۹	... (۴۹ data)	۱.۵۳۸۲۳	۰

قیمت‌های پایانی GBP/USD از ۲۰۱۰/۰۱/۰۱ تا ۲۰۲۰/۰۷/۳۵ برای نشان دادن روند این جفت ارز استفاده می‌شود. روند از روز جاری تا روز پنجم به‌عنوان داده خروجی پردازش می‌شود. در این مطالعه،

سه نوع روند وجود دارد: بالا، پایین و خنثی که قبلاً معرفی شد. ما از این روندها به عنوان کلاس استفاده می کنیم.

اما نحوه تعیین روند و در نتیجه برچسب دادگان، براساس اختلاف قیمت پایانی در روز جاری با پنج یا ده روز آینده مطابق شکل، به این صورت می باشد، که به ازای هر نمونه، تا پنج روز آینده اختلاف قیمت محاسبه می شود و سپس با حد آستانه تعیین شده مقایسه می گردد که بصورت کلی سه حالت بالا، پایین و خنثی وجود دارد.




مطابق شکل، هدف دریافت تعدادی کندل و پیش بینی چند کندل آینده مثلاً پنج یا ده می باشد.



شکل ۱۱-۳ محاسبه اختلاف قیمت برای تعیین برچسب

همانگونه که در شکل زیر مشاهده می کنیم اختلاف قیمت بین کندل جاری و پنج کندل آینده و سپس مقایسه با حد آستانه مبنای تعیین برچسب هریک از داده ها می باشد.




نشان ۳-۱۰ نمایش نمودار هدف و پیش‌بینی

۳-۴-۱ روش تعیین حد آستانه

تعیین حد آستانه به عنوان یکی از مراحل برچسب‌گذاری با روش‌های مرسوم آزمون و خطا تعیین می‌شود. نکته‌ای که در این حین باید به آن توجه داشت، منطقی بودن حد آستانه از نگاه معامله‌گرهای این بازار است و از آنجایی که حد آستانه برای دسته‌بندی داده‌ها نقش کلیدی دارد، اگر مقدار زیاد و یا کم باشد این تعادل بهم می‌خورد پس با آزمون و خطا می‌توان به مقدار ایده‌آل دست پیدا کرد [۱۶].

برای آزمون و خطا می‌توان از الگوریتم‌های هیوریستیک یا ابتکاری^۱ کمک گرفت. الگوریتم مورد استفاده‌ی ما در این تحقیق استفاده از میانگین پنج کندل قبل برای تعدادی بازه‌ی مشخص مانند شکل می‌باشد.



شکل ۳-۱۲ محاسبه حد آستانه

در شکل بالا حد آستانه برای کندل کاندید به این صورت تعیین می‌شود که در هفت گروه ده‌تایی قبلی

^۱ Hierarchical or Innovative

مقدار اختلاف قیمت شروع و پایان بین کندل اول و دهم محاسبه میگردد و میانگین این اختلافها محاسبه می‌شود. حد آستانه، مقدار میانگین این اختلافات می‌باشد. و برای تعیین برچسب با مقایسه اختلاف قیمت ده کندل بعد از کندل کاندید با حد آستانه به صورت زیر عمل می‌کنیم:

روند صعودی: قیمت بسته شدن کندل دهم - قیمت بسته شدن کندل جاری < حد آستانه (با علامت ۱)

روند نزولی: قیمت بسته شدن کندل دهم - قیمت بسته شدن کندل جاری < منفی حد آستانه

روند خنثی: قیمت بسته شدن کندل دهم - قیمت بسته شدن کندل جاری > قدرمطلق حد آستانه

جدول ۶-۳ نمونه داده کلاس‌بندی شده


تاریخ	برچسب
2010-01-04 00:00:00	۱
2010-01-04 00:05:00	۱
....	
2021-04-28 18:00:00	۲
2021-04-28 18:05:00	۲

۵-۳ آموزش و انتخاب مدل برای پیش‌بینی فارکس

۵-۳-۱ LSTM، CNN و فرآیند یادگیری

CNN این خاصیت را دارد که به مهمترین و بارزترین ویژگی‌ها در دادگان توجه می‌کند، بنابراین در مهندسی یا استخراج ویژگی به‌طور گسترده مورد استفاده قرار می‌گیرد. بدین معنی که مرحله استخراج ویژگی با کمک CNN به صورت خودکار انجام می‌شود. LSTM باتوجه به سری‌زمانی داده‌ها، دارای

ویژگی انبساط است و به‌طور گسترده ای در سری‌های زمانی مورد استفاده قرار می‌گیرد. باتوجه به ویژگی‌های CNN و LSTM، یک مدل پیش‌بینی بازار مالی فارکس براساس CNN-LSTM ایجاد شده است. نمودار ساختار مدل در شکل زیر نشان داده شده است و ساختار اصلی CNN و LSTM است که شامل لایه ورودی^۱، لایه کانولوشن^۲ یک بعدی، لایه استخر^۳، لایه مخفی^۴ LSTM و لایه اتصال کامل است [۱۱، ۱۸، ۲۰، ۲۴].



شکل ۳-۱۴ نمودار ساختار CNN-LSTM.

۳-۵-۱-۱ LSTM

از ساختار LSTM در این پایان‌نامه برای پیش‌بینی روند فارکس استفاده می‌شوند، زیرا همان‌طور که می‌دانیم داده‌های فارکس از نوع سری‌زمانی هستند. LSTM نوعی شبکه عصبی بازگشتی (RNN) است


Input Layer^۱

Convolution Layer^۲

Pooling Layer^۳

Hidden Layer^۴


که قادر به یادگیری وابستگی بین ویژگی‌ها در یک توالی می‌باشند. این ساختار، به‌طور خاص برای سری‌های زمانی طراحی شده است. در مقایسه با RNN‌های سنتی، مشکلات شیب در حال انفجار^۱ و ناپدید شدن شیب^۲ به راحتی در LSTM حل می‌شوند [۱۱، ۱۳].



شکل ۳-۱۳ یک لایه tanh به عنوان ماژول تکرار در RNN استاندارد (Olah، ۲۰۱۵)

LSTM‌ها به‌ویژه برای رفع مشکل وابستگی‌های طولانی مدت ساخته شده‌اند [۱۶]. یعنی آنها می‌توانند اطلاعات را در دوره‌های طولانی گذشته به خاطر بسپارند. همه RNN‌ها دارای ماژول تکرار هستند. اما در RNN‌های معمولی، ماژول تکرار دارای ساختار ساده‌ای مانند لایه tanh (تانژانت هیپربولیک) می‌باشد [۱۳، ۱۶].

LSTM‌ها ساختارهای مشابهی دارند، اگرچه ماژول‌های تکرار شونده دارای ساختار متفاوتی می‌باشند [۱۶]. به جای داشتن یک لایه شبکه عصبی، یک ماژول LSTM دارای چهار لایه NN است که به روشی منحصربه‌فرد تعامل می‌کنند، همانطور که در شکل ۳.۱۵ نشان داده شده است.



شکل ۳-۱۴ چهار لایه متقابل در یک ساختار LSTM (Olah، ۲۰۱۵)

^۱ Exploding gradient

^۲ vanishing gradient

همانطور که در شکل ۱۵ میبینیم، ساختار LSTM دارای سه دروازه به نامهای ورودی^۱، فراموشی^۲ و خروجی^۳ می باشد. این دروازه ها وظیفه انتخاب سیگنالی را دارند که باید به گره^۴ بعدی برود [۱۳]. محاسباتی که در یک سلول روی می دهد به این صورت می باشد که ابتدا باید تصمیم گرفته شود کدام اطلاعات در وضعیت فعلی سلول دور انداخته شود، این تصمیم به وسیله لایه سیگموئید که Forget Gate نام دارد انجام می شود، فرمول زیر این محاسبه را نشان می دهد [۱۳].

$$f_t = \sigma(x_t U^f + h_{t-1} W^f)$$

قدم بعدی این است که تصمیم بگیریم چه اطلاعاتی را در سلول ذخیره کنیم، این مرحله شامل دو قسمت می باشد. قسمت اول لایه سیگموئید که Input Gate Layer نام دارد و تصمیم می گیرد چه مقادیری به روز شوند و قسمت دوم لایه تانژانتی که یک بردار از مقادیر کاندید را ایجاد می کند و می توانند به حالت فعلی سلول اضافه شوند، سپس این دو با هم ادغام می شوند تا یک بروزرسانی برای حالت فعلی ایجاد شود فرمول زیر این محاسبه را نشان می دهد [۱۳].

$$i_t = \sigma(x_t U^i + h_{t-1} W^i)$$

$$\tilde{C}_t = \tanh(x_t U^g + h_{t-1} W^g)$$

بعد از این محاسبات زمان آن است تا وضعیت قدیمی سلول C_{t-1} را به روز رسانی کنیم C_t و در آخر تصمیم بگیریم چه خروجی تولید شود، که با محاسبات زیر نمایش می دهیم [۱۳].

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

$$o_t = \sigma(x_t U^o + h_{t-1} W^o)$$

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

^۱ Input Gate

^۲ Forget Gate

^۳ Output Gate

^۴ Node

در فرمول‌های بالا W نشان دهنده ارتباط بین لایه قبلی و لایه مخفی فعلی است، U ماتریس وزن‌ها، $\tilde{C}$ نشان دهنده کاندیدها و C حافظه داخلی واحد مورد نظر است [۱۳].

CNN ۳-۵-۱-۲

یک ساختار شبکه عصبی عمیق توسط Lecun و همکارانش در سال ۱۹۹۸ به نام CNN پیشنهاد شد [۲۲]. CNN نوعی شبکه عصبی پیشگام^۱ است که عملکرد خوبی در پردازش تصویر و پردازش زبان طبیعی دارد [۲۳]. همچنین می‌تواند به‌طور موثری در پیش‌بینی سری‌های زمانی اعمال شود. درک محلی^۲ و تقسیم وزن^۳ در CNN می‌تواند تعداد پارامترها را تا حد زیادی کاهش دهد، بنابراین کارایی یادگیری مدل را بهبود می‌بخشد [۲۴]. CNN عمدتاً از دو قسمت تشکیل شده است: لایه کانولوشن^۴ و لایه استخراج^۵. هر لایه کانولوشن شامل تعداد زیادی از هسته‌های کانولوشن است و فرمول محاسبه آن در زیر نشان داده شده است. بعد از عملیاتی که به کمک فرمول زیر و در بالا گفته شد (عملیات موسوم به کانولوشن)، ویژگی‌های داده استخراج می‌شوند، اما ابعاد ویژگی استخراج شده بسیار زیاد است، بنابراین برای حل این مشکل و کاهش هزینه‌های آموزش شبکه، یک لایه جمع کننده بعد از کانولوشن اضافه می‌شود لایه برای کاهش بعد ویژگی:

$$l_t = \tanh(x_t * k_t + b_t)$$

که در آن L مقدار خروجی را پس از کانولوشن نشان می‌دهد، $\tanh$ تابع فعال سازی، X بردار ورودی، K وزن هسته کانولوشن و B بایاس هسته کانولوشن می‌باشد.

^۱ FeedForward

^۲ Local Perception

^۳ Weight Sharing

^۴ Convolution

^۵ Pooling

۳-۱-۵-۳ فرآیند یادگیری مدل برای پیش‌بینی بازار

فرآیند یادگیری مدل هوش مصنوعی، برای پیش‌بینی روند GBP/USD را می‌توان به شرح زیر بیان کرد:

(۱) داده‌های ورودی: داده‌های پیش‌پردازش شده و مورد نیاز برای آموزش CNN-LSTM را وارد می‌کنیم.

(۲) استاندارد سازی داده‌ها: چون در داده‌های ورودی اختلاف زیادی بین مقادیر وجود دارد، به‌منظور آموزش بهتر مدل، روش استاندارد سازی نمره z^1 برای استاندارد سازی داده‌های ورودی اتخاذ می‌شود، همانطور که در فرمول زیر نشان داده شده است:

$$y_i = \frac{x_i - \bar{x}}{s}$$

$$x_i = y_i * s + \bar{x}$$

به این صورت که y_i مقدار استاندارد شده است، x_i داده ورودی، $\bar{x}$ متوسط داده ورودی و s انحراف معیار داده‌های ورودی می‌باشد.

(۳) مقداردهی اولیه شبکه: وزن و بایاس هر لایه CNN-LSTM را مقدار دهی اولیه می‌کنیم.

(۴) محاسبات لایه CNN: داده‌های ورودی به‌طور متوالی از لایه کانولوشن و لایه استخراج در لایه CNN عبور داده می‌شوند، استخراج ویژگی داده‌های ورودی انجام می‌شود و مقدار خروجی بدست می‌آید.


(۵) محاسبات لایه LSTM: داده‌های خروجی لایه CNN از طریق لایه LSTM وارد محاسبات می‌شوند و مقدار خروجی بدست می‌آید.

(۶) محاسبات لایه خروجی: مقدار خروجی لایه LSTM برای بدست آوردن مقدار خروجی به لایه اتصال کامل^۲ وارد می‌شود.

(۷) خطای محاسبه: مقدار خروجی محاسبه شده توسط لایه خروجی با مقدار واقعی این گروه از داده‌ها مقایسه می‌شود و خطای مربوطه بدست می‌آید.

^۱ Z-Score
^۲ Fully Connected

- (۸) مقایسه خطا برای بررسی شرایط نهایی: شرایط پایان برای تکمیل تعداد از پیش تعیین شده چرخه^۱ است، وزن کمتر از یک آستانه خاص است و میزان خطای پیش‌بینی کمتر از یک آستانه خاص می‌باشد. اگر یکی از شرایط پایان وجود داشته باشد، آموزش به پایان می‌رسد، کل شبکه CNN-LSTM را به روز می‌کنیم و به مرحله ۱۰ می‌رویم. در غیر این صورت، به مرحله ۹ باز می‌گردیم.
- (۹) باز انتشار مجدد خطا: خطای محاسبه شده را در جهت مخالف گسترش می‌دهیم، وزن و بایاس هر لایه را بروزرسانی می‌کنیم و برای ادامه آموزش شبکه به مرحله ۴ می‌رویم.
- (۱۰) ذخیره مدل: مدل آموزش دیده را برای پیش‌بینی ذخیره می‌کنیم.
- (۱۱) داده‌های ورودی: داده‌های ورودی مورد نیاز برای پیش‌بینی را وارد می‌کنیم.
- (۱۲) استاندارد سازی داده‌ها: داده‌های ورودی طبق مرحله (۲) استاندارد می‌شوند.
- (۱۳) پیش‌بینی: داده‌های استاندارد را وارد مدل آموزش دیده CNN-LSTM می‌کنیم و سپس مقدار خروجی مربوطه را بدست می‌آوریم.
- (۱۴) بازیابی استاندارد داده‌ها: مقدار خروجی بدست آمده از طریق مدل CNN-LSTM مقدار استاندارد شده است و مقدار استاندارد شده به مقدار اصلی باز می‌گردد. همانطور که در فرمول مرحله (۲) نشان داده شده است.
- (۱۵) نتیجه خروجی: نتایج بازیابی شده را برای تکمیل فرآیند پیش‌بینی استخراج می‌کنیم.
- چارت مراحل به‌طور خلاصه در شکل ۳،۱۶ نشان داده شده است.



شکل ۱۵-۳ مراحل آموزش

۳-۵-۲ تنظیم ابرپارامترها و انتخاب مدل

۳-۵-۲-۱ سیستم مورد نیاز

به منظور اثبات تأثیر پیش‌پردازش‌های جدید نسبت به حالت‌های مختلف پیش‌پردازش‌ها، انواع روش‌ها را در الگوریتم SVM مقایسه کردیم، همچنین برای اثبات تأثیر CNN-LSTM، ما این روش را با MLP، CNN، RNN، LSTM و CNN-RNN با استفاده از همان مجموعه آموزش و داده‌های مجموعه آزمایش تحت همان محیط عملیاتی مقایسه کردیم. آزمایشات تحت محیط گوگل کولب در حالت حساب ویژه با ۳۵ گیگ رم، در حالت TPU ویا تحت محیط Intel i7-6700H 2.6 گیگاهرتز، ۱۶ گیگابایت رم، ۵۰۰

گیگابایت هارد اس اس دی و ویندوز ۱۰ انجام شده است.

۳-۶ جمع بندی

در این فصل ابتدا بررسی جامعی از شاخص‌های درگیر در تحلیل فنی برای پیش‌بینی بازار فارکس، با استفاده از جفت ارز GBP/USD ارائه شده است. همچنین روش نوین تولید ویژگی با استفاده از استراتژی نیز شرح داده شد و در آن شاخص‌های تأثیرگذار که تأثیر بیشتری بر پیش‌بینی فارکس دارند شناسایی شده‌اند.

در مرحله دوم، هدف پیش‌بینی نیز به‌عنوان پیش‌بینی روند برای روزهای آینده با نگاه پویا به گذشته پس از تجزیه و تحلیل روش‌های موجود تعیین شده است.

در مرحله سوم، فرآیند دقیق نحوه ساخت CNN-LSTM برای پیش‌بینی بازار فارکس توضیح داده شده است. تنظیم Hyperparameter برای مدل نیز معرفی شده است.

فصل ۴ نتایج و آزمایش‌ها

۱-۴ مقدمه

در فصل قبل روشی برای پیش‌پردازش داده‌های مالی ارائه شد و سپس روش‌های مختلف هدف‌گذاری بررسی گردید. سرانجام یک مدل یادگیری عمیق طراحی و در ادامه ابرپارامترهای آن تنظیم خواهد شد. در این فصل بعد از تنظیم ابرپارامترها ابتدا روش پیشنهادی برای پیش‌پردازش در مقایسه با سایر روش‌های موجود ارزیابی می‌شود سپس به ارزیابی روش هدف‌گذاری و مدل پیشنهادی در مقایسه با سایر مدل‌های موجود در یادگیری ماشین پرداخته می‌شود.


۲-۴ تنظیمات ابرپارامترها

برای هر شبکه عصبی، تعدادی از ابر پارامترها وجود دارد که باید قبل از آموزش رسمی تنظیم شوند [۲۴]. در یادگیری ماشینی، یک ابر پارامتر با یک پارامتر معمولی متفاوت است. یک پارامتر معمولی در طی مراحل آموزش تنظیم می‌شود، به عنوان مثال، وزن یا بایاس در شبکه عصبی یک پارامتر معمولی می‌باشند. اما ابر پارامترها باید قبل از آموزش تنظیم شوند و بسته به داده‌های آموزش، الگوریتم‌ها و حتی نرم‌افزار و سخت افزار مورد استفاده، مقادیر مختلفی در تنظیمات مختلف دارند. ابر پارامترهای خوب می‌توانند به عملکرد بهتر الگوریتم کمک کنند [۲۴، ۲۰].

به طور کلی، ابر پارامترهایی که باید در یک شبکه عصبی CNN-LSTM تنظیم شوند، شامل تعداد لایه‌های پنهان، تعداد نرون‌ها در هر لایه پنهان، تابع فعالسازی برای هر لایه، تعداد دوره‌های آموزش، اندازه دسته‌بندی داده‌ها، نرخ یادگیری، بهینه‌ساز، و تابع خطا می‌باشد. در این تحقیق، همانطور که در بخش‌های پیشین توضیح داده شد، تابع فعالسازی استاندارد به طور پیش فرض $\tanh$ می‌باشد. و همچنین تابع بهینه‌ساز Adam، که یکی از بهترین بهینه‌سازها می‌باشد استفاده شده است و تابع خطا باید $\text{Categor_Crossentropy}$ می‌باشد زیرا این یک مساله طبقه‌بندی سه کلاسه می‌باشد. و در نتیجه،

برای دوره‌های آموزش، روشی به نام "توقف زودهنگام"^۱، با هدف جلوگیری از مساله بیش‌برازش مناسب بجای تعداد معینی از دورها استفاده شده است [۱۳، ۱۶، ۲۴].

بیشتر فرآیند آموزش شبکه عصبی با یک مساله بیش‌برازش روبرو است. به این معنی که، در طول فرایند، دقت مجموعه آموزش همیشه در حال افزایش است، اما دقت در مجموعه آزمون در حال کاهش می‌باشد [۱۶].



شکل ۱-۴ برای جلوگیری از حالت بیش‌برازش، در نقطه قرمز متوقف می‌شویم

مانند شکل در مسائل بیش‌برازش، دقت در ابتدا افزایش می‌یابد ولی در برخی از زمان‌ها شروع به کاهش می‌کند. این به این دلیل است که مدل ANN آموزش دیده بیش از حد با داده‌های آموزش سازگار می‌باشد و بنابراین توانایی سازگاری با داده‌های جدید را از دست داده است. به همین دلیل، یک مجموعه اعتبارسنجی اغلب برای کمک به انتخاب یک مدل قابل تعمیم در طول مراحل آموزش استفاده می‌شود [۱۳، ۲۴]. باتوجه به شکل مشاهده می‌کنیم، هنگامی که دقت مجموعه اعتبارسنجی در طی مراحل آموزش به حداکثر نقطه افزایش می‌یابد، مدل با بیشترین دقت روی مجموعه اعتبارسنجی به‌عنوان مدل آموزش دیده نهایی ذخیره می‌شود.

در این تحقیق، حداکثر دوره آموزش ۱۰۰۰ مورد تنظیم شده است تا اطمینان حاصل شود که آموزش می‌تواند به نقطه عطف برسد. همچنین تحمل دوره ۱۰۰ تعیین شده است، این بدان معناست که اگر

^۱ Early Stopping

دقت در مجموعه اعتبارسنجی بهبود نیابد و شروع به کاهش کند، روند آموزش برای صرفه جویی در وقت متوقف می‌شود. در نتیجه، مدل آموزش دیده با بالاترین دقت به عنوان نتیجه آموزش ذخیره می‌شود [۱۳، ۱۶].

معمولاً روش‌های مورد استفاده برای تنظیم ابرپارامترها به دو نوع انتخاب دستی و انتخاب خودکار طبقه بندی می‌شوند. در این تحقیق، برای اطمینان از بهترین تنظیمات ابرپارامترها، زمان زیادی برای تنظیم دستی و خودکار پارامترها صرف شده است.

برای روش دستی در ابتدا برای LSTM مقادیر اولیه برای ابرپارامترها بر اساس تجربیات تعیین می‌شوند: ۱۰۰ نورون در یک لایه مخفی LSTM تنظیم می‌شوند، اندازه مینی بچ ۵۱۲ است و از نرخ یادگیری پیش فرض ۰.۰۱ استفاده می‌شود. سپس ابر پارامترها یک به یک تنظیم می‌شوند: مقادیر مختلف یک ابر پارامتر آزمایش می‌شوند به این صورت که ابر پارامترهای دیگر ثابت می‌مانند.

• تعداد لایه های پنهان

جدول ۱-۴ نتیجه حاصل از آزمایش تنظیم لایه ها

Cross-validation			
تعداد لایه ها	۱ لایه	۲ لایه	۳ لایه
دقت با استفاده از	۷۹.۵۲	۸۱.۵۳	۷۶.۷۱
	۸۰.۲۴	۸۰.۶۵	۷۹.۸۴
	۷۹.۸۴	۷۹.۴۴	۷۵.۴۰
	۸۴.۶۸	۸۲.۲۶	۷۸.۶۳
	۸۱.۰۵	۸۳.۴۷	۷۸.۲۳

۷۸.۹۵	۸۲.۱۹	۸۱.۳۸	Cross-validation در حالت ۱۰-fold
۷۴.۰۹	۸۱.۳۸	۸۰.۹۷	
۷۵.۷۱	۸۲.۱۹	۸۳.۴۰	
۸۲.۱۹	۸۲.۱۹	۸۰.۵۷	
۸۰.۱۶	۸۱.۷۸	۸۴.۲۱	
۷۷.۹۹	۸۱.۷۰	۸۱.۵۹	میانگین

همانطور که مشاهده می‌شود در جدول فوق فرآیند تعیین تعداد لایه‌ها با کمک Cross-Validation به صورت بهینه تعیین شده است. هر سطر از جدول دقت اعتبارسنجی بر روی ویژگی مربوطه را نشان می‌دهد. در جدول ۴-۱ مشاهده می‌شود، تعداد دو لایه با متوسط دقت ۸۱.۷۰٪ بهترین عملکرد را نسبت به سایر تعداد لایه‌ها دارد.

• تعداد سلولهای عصبی (نرون)

جدول ۴-۲ نتایج تنظیم پارامتر تعداد نرون

Cross-validation						
تعداد نرون‌ها در لایه پنهان	۱۰	۵۰	۶۴	۱۲۸	۲۰۰	۲۵۰
دقت با استفاده از	۶۴.۹۴	۸۱.۶۷	۸۳.۲۷	۸۳.۲۷	۸۲.۸۷	۸۲.۰۷
	۶۵.۰۶	۸۲.۳۳	۸۱.۵۳	۷۹.۹۲	۸۳.۵۳	۸۱.۹۳
	۶۳.۰۵	۷۸.۷۱	۷۷.۱۱	۷۵.۹۰	۷۵.۹۰	۷۸.۷۱
	۷۴.۶۰	۸۳.۴۷	۸۴.۲۷	۸۳.۸۷	۸۲.۶۶	۸۲.۲۶
	۶۷.۳۴	۷۷.۴۲	۸۱.۴۵	۸۱.۴۵	۸۲.۶۶	۷۹.۴۴

۸۰.۲۴	۸۰.۲۴	۸۲.۲۶	۸۰.۶۵	۷۹.۰۳	۶۶.۵۳	Cross-validation در حالت ۱۰-fold
۷۷.۸۲	۷۹.۰۳	۷۸.۶۳	۷۸.۶۳	۷۶.۲۱	۶۵.۳۲	
۸۴.۶۸	۸۳.۴۷	۸۴.۲۷	۸۴.۶۸	۸۱.۴۵	۶۴.۵۲	
۸۱.۸۵	۸۰.۲۴	۸۱.۰۵	۸۲.۶۶	۸۱.۴۵	۶۸.۱۵	
۸۲.۶۶	۸۱.۴۵	۸۱.۸۵	۸۴.۲۷	۸۱.۰۵	۷۴.۱۹	
۸۱.۲۵	۸۱.۱۳	۸۱.۲۵	۸۱.۸۵	۸۰.۳۶	۶۷.۳۷	میانگین

برای تنظیم تعداد نرون‌ها در لایه LSTM با استفاده از تکنیک اعتبارسنجی ده برابر نتایج جدول فوق قابل رویت می‌باشد. در جدول ۴-۲ نتایج حاصل از تنظیم تعداد نرون به ازای هر لایه را مشاهده می‌کنیم. همانطور که مشخص است ستون‌ها بیانگر تعداد نرون‌ها می‌باشند و هر سطر دقت را به ازای اعتبارسنجی نشان می‌دهد. سطر آخر نیز نشان دهنده میانگین دقت به‌ازای هر ویژگی است. همانطور که پیش‌بینی می‌شد بعد از کاهش ویژگی، پیچیدگی دادگان متوسط شد و تعداد ۶۴ نرون در هر لایه نیز بیانگر همین موضوع است.

• اندازه دسته

جدول ۳-۴ نتایج تعیین اندازه دسته

Cross-validation					
۵۱۲	۲۵۶	۱۲۸	۶۴	۳۲	اندازه دسته
۸۲.۸۷	۸۳.۲۷	۸۳.۲۷	۸۲.۴۷	۸۲.۰۷	
۸۰.۷۲	۸۲.۷۳	۸۱.۵۳	۷۸.۷۱	۷۸.۳۱	
۷۶.۷۱	۷۸.۳۱	۷۷.۱۱	۷۷.۵۱	۷۶.۳۱	
۸۲.۶۶	۸۳.۴۷	۸۴.۲۷	۸۱.۸۵	۷۹.۴۴	

۸۲.۲۴	۷۹.۸۴	۸۱.۴۵	۸۱.۸۵	۷۹.۸۴	دقت با استفاده از Cross-validation در حالت ۱۰-fold
۸۱.۰۵	۸۱.۸۵	۸۰.۶۵	۸۰.۶۵	۸۱.۰۵	
۸۰.۲۴	۷۷.۸۲	۷۸.۶۳	۸۰.۲۴	۷۷.۰۲	
۸۵.۰۸	۸۵.۴۸	۸۴.۶۸	۸۱.۸۵	۷۹.۰۳	
۸۱.۴۵	۷۹.۸۴	۸۲.۶۶	۷۹.۰۳	۸۰.۶۵	
۸۱.۸۵	۸۲.۲۶	۸۴.۲۷	۸۱.۸۵	۸۱.۸۵	
۸۱.۲۹	۸۱.۴۹	۸۱.۸۵	۸۰.۶۰	۷۹.۵۶	میانگین

برای تعیین اندازه دسته جهت تغذیه شبکه، مانند قبل از اعتبارسنجی ۱۰ برابر استفاده کردیم. هر ویژگی از جدول بالا نشان دهنده تعداد دسته می‌باشد. و هر سطر دقت مربوط به اعتبارسنجی را نشان می‌دهد. سطر آخر نیز بیانگر میانگین دقت‌های تست در اعتبارسنجی می‌باشد.

• نرخ یادگیری

جدول ۴-۴ نتایج تعیین نرخ یادگیری

Cross-validation		
۰.۰۰۱	۰.۰۱	
۸۳.۲۷	۸۱.۶۷	دقت
۸۱.۵۳	۸۱.۵۳	
۷۷.۱۱	۷۷.۵۱	
۸۴.۲۷	۸۳.۸۷	
۸۱.۴۵	۸۰.۶۵	
۸۰.۶۵	۸۲.۲۶	
۷۸.۶۳	۷۸.۲۳	

۸۴.۶۸	۸۳.۰۶	
۸۲.۶۶	۸۱.۴۵	
۸۴.۲۷	۸۱.۴۵	
۸۱.۸۵	۸۱.۱۷	میانگین

نرخ یادگیری با عملکرد بالاتر در دقت مقدار ۰.۰۰۱ است چرا که با توجه به نوع داده‌ها و عملکرد نرخ یادگیری، حرکت به سمت نقطه مینیمم با کمک قدم‌های نسبتاً کوچک (۰.۰۰۱) نسبت به نرخ یادگیری بزرگتر (۰.۰۱) دقت بالاتری را نشان می‌دهد.

سپس برای مدل CNN هم ابرپارامترها را تنظیم می‌کنیم به‌این صورت که با استفاده از کراس-تیونر^۱ به‌صورت خودکار انجام می‌شود و در پایان بهترین ابر پارامترها با بالاترین متوسط دقت در اعتبارسنجی متغیر، انتخاب می‌شوند.

جدول ۴-۵ ابرپارامترهای تنظیم شده برای لایه‌های مدل CNN-LSTM


لایه	نام لایه	اندازه کرنل	تعداد سلول (فیلتر)	نرخ	قدم
۱	Conv1D	۳	۸	-	۱
۲	Dropout	-	-	۰.۵	-
۳	Conv1D	۳	۱۶	-	۱
۴	Dropout	-	-	۰.۳	-
۵	Dense	-	۱۰۰	-	-
۶	LSTM	-	۶۴	-	-
۷	LSTM	-	۶۴	-	-
۸	Dense	-	۱۰۰	-	-

و سایر ویژگی‌های تکمیلی مدل به قرار زیر می‌باشد.

^۱ Keras-Tuner

جدول ۴-۶ ابرپارامترهای تنظیم شده برای مدل CNN-LSTM

Parameters	Value
Convolution layer activation function	tanh
Convolution layer padding	Same
LSTM layer activation function	tanh
Time_step	20
Batch_size	128
Learning rate	0.001
Optimizer	Adam
Loss function	mean_absolute_error
Epochs	1000



شکل ۴-۲ شمای کلی مدل ترکیبی

در شکل بالا یک شمای کلی تک لایه از مدل پیشنهادی نمایش داده شده است. در مدل پیشنهادی از

لایه‌های انتخاب ویژگی به صورت اتوماتیک مثل لایه‌ی max-pooling استفاده نشده است. علت این موضوع حذف برخی از ویژگی‌های مهم در دادگان سری‌زمانی مالی می‌باشد. ما در آزمایش مدل با استفاده از این لایه شاهد کاهش درصد دقت بودیم.

۳-۴ مجموعه دادگان

برای ارزیابی عملکرد روش پیشنهادی در پیش‌پردازش، نیاز است انواع روش‌های رایج برای پیش‌پردازش دادگان خام مالی را بررسی و پیاده‌سازی نمود. سپس به کمک یک مدل یادگیری ماشین مانند SVM ارزیابی کرد کدام روش پیش‌پردازش می‌تواند بر روی دقت مدل در شرایط یکسان تاثیر بیشتری بگذارد. ویژگی‌های مشترک تمام دادگان‌ها در تعداد نمونه که از سال ۲۰۱۰ تا ۲۰۲۱ می‌باشد همچنین جفت ارز انتخابی GBP/USD می‌باشد.

مشخصات مجموعه دادگان به شرح زیر می‌باشند:

۱. اولین دادگان شامل ۵ ویژگی اصلی داده‌های مالی می‌باشد.
۲. دومین دادگان شامل ۱۷۷ ویژگی می‌باشد در نتیجه استخراج تمام شاخص‌های موجود در تحلیل تکنیکال ساخته می‌شود. بدین معنی که تمام شاخص‌های معرفی شده توسط Williams مورد استفاده قرار می‌گیرد. برای پیاده‌سازی از کتابخانه ta-lib در پایتون استفاده شده است.
۳. سومین دادگان شامل تمام شاخص‌ها و اندیکاتورهای معرفی شده در این تحقیق بدون کاهش تعداد ویژگی براساس نمودار همبستگی می‌باشد. تعداد ویژگی‌های این دادگان برابر با ۷۵ ویژگی است.
۴. چهارم دادگان همان دادگان مورد دو است که بعد از محاسبه همبستگی، ویژگی‌های با نمره پایین از دادگان حذف شدند و تعداد آنها به ۳۹ مورد رسیده است.
۵. و در آخر پنجم، دادگان مربوط به این تحقیق که شامل ۵۹ ویژگی می‌باشد.

جدول ۴-۵ ویژگی‌های دادگان پس از پیش‌پردازش‌های مختلف

تعداد سطر	تعداد ویژگی	قالب زمانی	جفت ارز	شماره دادگان
۲۹۱,۴۰۵	۵	5 min	GBP/USD	یک
۲۹۱,۴۰۵	177	5 min	GBP/USD	دو
۲۹۱,۴۰۵	۷۵	5 min	GBP/USD	سه
۲۹۱,۴۰۵	۳۹	5 min	GBP/USD	چهار
۲۹۱,۴۰۵	۵۲	5 min	GBP/USD	پنج

۴-۴ ارزیابی عملکرد روش پیشنهادی

برای ارزیابی عملکرد روش پیشنهادی در پیش‌پردازش دادگان، ما نیاز به پیاده‌سازی چند الگوریتم مختلف یادگیری ماشین هستیم تا بتوانیم به کمک آنها انواع پیش‌پردازش‌های انجام شده بر روی دادگان را مقایسه کنیم. لذا از سه الگوریتم SVM، K-NN و LSTM استفاده می‌کنیم.

جدول ۴-۶ مشخصات الگوریتم‌های مورد استفاده


الگوریتم	تنظیمات
SVM	از هسته تابع ^۱ RBF استفاده شده و پارامتر تنظیم ^۲ $C=0.65$ می‌باشد
K نزدیک‌ترین همسایه ^۳	پارامتر N برابر با ۲۰ می‌باشد.
LSTM	تعداد لایه‌ها = ۲. تابع بهینه سازی Adam، نرخ یادگیری = ۰.۰۲ و $\text{betas} = (0.9, 0.999)$

^۱ Kernel Function

^۲ Regularization Parameter

^۳ K-Nearest-Neighbor


نتایج حاصل از مقایسه در زیر نشان داده شده است:



شکل ۳-۴ مقایسه روش‌های پیش‌پردازش با روش پیشنهادی

همانطور که در نمودار بالا مشاهده می‌شود در تمام الگوریتم‌های مورد استفاده، پیش‌پردازش پیشنهاد شده با اختلاف قابل توجه از سایر روش‌ها دارای دقت بالاتری می‌باشد.

لازم بذکر است از موارد پیش‌پردازش تعیین هدف می‌باشد. همانطور که در بخش‌های قبل توضیح داده شد از روش افق ثابت برای این امر استفاده می‌شود. اما با تغییر افق ثابت به افق متغیر (شرح در فصل سوم) نتایج بهبود بیشتری می‌یابند.



شکل ۴-۴ مقایسه افق ثابت و افق متغیر

در نهایت با بررسی آزمایشات انجام شده تایید می‌شود که پیش‌پردازش‌های پیشنهادی می‌تواند تاثیر مطلوب‌تری نسبت به سایر روش‌ها بر روی دقت مدل بگذارد.

در ادامه باتوجه به نتایج بدست آمده از مقایسه پیش‌پردازش‌ها و همچنین مدل CNN-LSTM تنظیم شده در بخش قبل، برای مقایسه مدل پیشنهادی با سایر مدل‌های یادگیری ماشین ابتدا باید انواع مدل‌ها را پیاده‌سازی کنیم و سپس عملکرد هر کدام با ورود دادگان پیش‌پردازش شده‌ی کاملاً یکسان بررسی می‌شود و براساس میزان دقت مدل برتر را تعیین می‌کنیم.

جدول ۴-۷ نام و مشخصات مدل‌های بررسی شده

نام مدل	مشخصات
رگرسیون لجستیک ^۱	از پارامتر "L2" برای خطا استفاده شده است.
جنگل تصادفی ^۲	حداکثر پارامتر تکرار N برابر با ده می‌باشد.
K نزدیک‌ترین همسایه	پارامتر N برابر با ۲۰ می‌باشد.
ماشین بردار پشتیبان ^۳	از هسته تابع RBF استفاده شده و پارامتر تنظیم $C=0.65$ می‌باشد.
LSTM	تعداد لایه‌ها = ۲. تابع بهینه سازی Adam، نرخ یادگیری = ۰.۰۲ و $\text{betas} = (0.9, 0.999)$
CNN-LSTM	توضیحات در بخش ۲-۵-۳ آمده است.

باتوجه به جدول داریم:

رگرسیون لجستیک یک رویکرد مدلسازی ریاضی است که می‌تواند برای توصیف رابطه چندین متغیر با یک متغیر وابسته استفاده شود [۶۶]. درک تئوری LOGREG ساده و آسان است، اما در صورت وجود نویز در داده‌ها از قدرت و دقت کافی برخوردار نیست [۶۷].

مدل طبقه‌بندی جنگل تصادفی یک طبقه‌بند یکپارچه می‌باشد که چندین درخت تصمیم را با استفاده از زیر مجموعه‌های نمونه آموزش و متغیرهای تصادفی انتخاب شده تولید می‌کند [۶۹]. الگوریتم جنگل

^۱ Logistic Regression

^۲ Random Forest

^۳ Support Vector Machine (SVM)


تصادفی پیشنهادی، توسط بریمن در سال ۲۰۰۱، به عنوان یک روش طبقه‌بندی عمومی و رگرسیون، بسیار موفقیت آمیز بود [۶۵]. RF یکی از قدرتمندترین روش‌های انسمبل^۱ با عملکرد بالا در هنگام برخورد با داده‌های با ابعاد بالا است [۶۹].

روش K نزدیک‌ترین همسایه یک روش طبقه‌بندی غیر پارامتری می‌باشد، که در بسیاری از موارد در عین سادگی بسیار موثر است [۷۳]. این الگوریتم می‌تواند بسیاری از شرایط بازار از جمله معکوس کردن متوسط قیمت و جهت روند را تشخیص دهد [۷۳].

(SVM) یک الگوریتم ویژه یادگیری ماشین می‌باشد که با کنترل ظرفیت عملکرد تصمیم‌گیری، استفاده از توابع هسته و کاهش خطا عمل می‌کند [۷۱]. این الگوریتم دارای بسیاری از ویژگی‌های پیشرفته با قابلیت تعمیم خوب و توانایی محاسبات سریع است [۷۱]. ماشین بردار پشتیبان یک تابع متشکل از اصل به حداقل رساندن ریسک ساختاری را اتخاذ می‌کند، که یک روش امیدوار کننده برای پیش‌بینی سری‌زمانی مالی می‌باشد [۷۲]. انگیزه اساسی برای استفاده از SVM این است که این روش می‌تواند با دقت داده‌های سری‌زمانی را پیش‌بینی کند که فرآیند سیستم معمولاً غیر خطی، غیر ثابت و تعریف شده باشد [۷۲].

ارزیابی الگوریتم‌های بالا برای قالب زمانی پنج دقیقه و با اعمال پیش‌پردازش‌های شرح داده شده نتایج زیر را در بر دارد:

^۱ Ensemble



شکل ۴-۵ عملکرد انواع مدل‌ها در قالب زمانی پنج دقیقه‌ای

همان‌طور که در شکل مشخص است دقت مدل پیشنهادی نسبت به سایر مدل‌ها در قالب زمانی کوتاه‌مدت پنج دقیقه مطلوب‌تر می‌باشد. اما در ادامه برای اطمینان، قالب‌های زمانی متنوعی را برای بررسی عملکرد مدل‌ها مورد ارزیابی قرار داده‌ایم که مشخصات این داده‌گان‌ها در زیر آمده است.

جدول ۴-۸ قالب زمانی پانزده

نام کلاس (برچسب)	تعداد
کلاس یک (صعودی)	۸۱۲۱۵
کلاس دو (نزولی)	۶۷۱۲۵
کلاس صفر (خنثی)	۳۶۸۷۵۸
اندازه نهایی هر کلاس	۶۷۱۲۵


جدول ۴-۹ قالب زمانی چهار ساعت

نام کلاس (برچسب)	تعداد
کلاس یک (صعودی)	۷۰۵۲
کلاس دو (نزولی)	۴۹۹۵
کلاس صفر (خنثی)	۲۱۱۲۵
اندازه نهایی هر کلاس	۴۹۹۵

جدول ۴-۱۰ قالب زمانی یک

نام کلاس (برچسب)	تعداد
کلاس یک (صعودی)	۲۰۵۲
کلاس دو (نزولی)	۱۷۳۴
کلاس صفر (خنثی)	۱۷۵۲
اندازه نهایی هر کلاس	۱۷۳۴

از جداول بالا جدول شماره ۷ و ۵ دادگان بلند مدت و قالب زمانی پنج دقیقه و همچنین جدول شش دادگان کوتاه مدت می‌باشند. نتایج حاصل از اعمال مدل‌ها بر روی این دادگان بخوبی می‌تواند عملکرد آن‌ها را در کوتاه مدت و بلند مدت نشان دهد.



شکل ۴-۶ مقایسه میزان دقت مدل‌های مختلف برای انواع قالب زمانی

ارزیابی انجام شده نشان می‌دهد که مدل ترکیبی پیشنهاد شده در بازه زمانی کوتاه مدت عملکرد بهتری نسبت به سایر مدل‌ها دارد و برای قالب‌های زمانی بلند مدت LSTM و SVM عملکرد بهتری نسبت به سایرین داشته‌اند.

۴-۵ نتیجه‌گیری

در این فصل خروجی‌های حاصل از اجرای روش پیشنهادی برای فاز پیش‌پردازش را در مراحل مختلف آن نشان دادیم سپس با اضافه کردن روشی جدید در هدف‌گذاری، بررسی و مقایسه را ادامه دادیم و نتایج را منتشر کردیم و در نهایت مراحل مختلف برای ساخت یک مدل ترکیبی هوش مصنوعی را نشان دادیم. همچنین در ادامه به مقایسه دقت حاصل شده از روش پیشنهادی ارائه شده با برخی از کارهای مرتبط

قبل پرداخته شد و مشاهده گردید که روش پیشنهادی از دقت بسیار خوبی نسبت به سایر روش‌ها برخوردار است.

فصل ۵ جمع‌بندی و پیشهادات

۱-۵ جمع‌بندی و نتیجه‌گیری

پیش‌بینی بازارهای مالی همچنان یک موضوع تحقیقاتی محبوب است زیرا سود کلان و منافع اقتصادی زیادی در آن وجود دارد. از نظر آکادمیک، پیش‌بینی این بازارها نیز توجه زیادی را به خود جلب کرده است، چراکه یکی از انواع مسائل پیچیده‌ی سری‌زمانی می‌باشد [۲۰]. مطالعات گسترده‌ای برای پیش‌بینی بازارهای مالی مانند بازار فارکس انجام شده است. از جمله‌ی این مطالعات بررسی متدهای آماری و روش‌های یادگیری ماشین می‌باشد [۲۰].

در این پایان‌نامه، ابتدا یک بررسی جامع در مورد انواع بازارهای مالی انجام شد سپس پیش‌بینی بازار فارکس به‌عنوان بازار پیشنهادی مورد تحقیق قرار گرفت. داده‌ها با روش تجزیه و تحلیل فنی مورد بررسی قرار گرفته و همچنین پیشنهاد شده است که استخراج سیگنال از داده‌های خام برای پیش‌بینی روند بازار مفید خواهد بود. به‌همین دلیل، این تحقیق تمام داده‌های مربوط به تجزیه و تحلیل فنی و همچنین دریافت سیگنال از شاخص‌های این حوزه را جمع‌آوری کرده و با بررسی ویژگی‌های استخراج شده، داده‌ها را مورد تجزیه و تحلیل قرار داده است. با استفاده از انتخاب ویژگی، ۵۳ ویژگی شناسایی شده است که تأثیر زیادی در معاملات فارکس برای تبادل جفت ارز GBP/USD دارند. این شاخص‌ها باید به‌عنوان ورودی‌های الگوریتم مورد نظر استفاده شوند.

در ادامه اهداف پیش‌بینی برای بازار تبادل ارز نیز مورد مطالعه قرار گرفته است. مزایای اهداف مختلف پیش‌بینی، خواسته‌های واقعی معامله‌گران این بازارها و استفاده عملی از پیش‌بینی‌های هوشمند برای تجارت بازارهای مالی به‌طور مفصل بحث شده است. پیش‌بینی روند قیمت بازار برای روزهای آینده (به‌عنوان مثال، ده روز بعدی) پیشنهاد و اثبات می‌شود که یک هدف پیش‌بینی مناسب می‌باشد، همچنین به معامله‌گران این بازارها پیشنهادات قابل اعتماد و واقع‌بینانه‌ای را هنگام توضیح استراتژی‌های تجاری خود ارائه داده‌ایم.

به‌منظور غلبه بر مشکلات موجود در بخش هدف‌گذاری، روشی برای مقابله با حالت افق ثابت ارائه شده

است علت استفاده از این روش متغییر و پویا بودن بازار می‌باشد. از آنجا که یک جریان پویا را با کمک یک فرمول ثابت نمی‌توان بخوبی فرموله کرد، برای پوشش تمام سناریوها، لازم به پویاسازی فرمول هدف‌گذاری می‌باشد که با کمک روش پیشنهادی و مقایسه با روش قبل به این مهم دست یافته‌ایم.

با استفاده از روش جدید پیش‌پردازش، یک مدل پیش‌بینی مبتنی بر شبکه عصبی CNN-LSTM برای پیش‌بینی روند قیمت بازار با موفقیت توسعه یافته است. با استفاده از اطلاعات حاصل از تجزیه و تحلیل فنی، میانگین دقت پیش‌بینی با بهبود همراه بوده است و عملکرد مدل جدید در مقایسه با سایر مدل‌های پیشنهاد شده و همچنین مدل‌های سنتی و کلاسیک در یادگیری ماشین نتایج بهتری را نشان می‌دهد. این بهبود عملکرد با اضافه کردن پیش‌پردازش پیشنهادی بازهم بهبود خواهد یافت.

۲-۵ پیشنهادات برای ادامه فعالیت

- پیشنهادات زیر را جهت ادامه فعالیت توصیه می‌کنیم:
- بررسی و استفاده از تجزیه و تحلیل بنیادی و استخراج ویژگی از آن و همچنین ترکیب دو روش تجزیه و تحلیل به‌منظور بهبود دقت.
 - بررسی روش‌های هدف‌گذاری پیچیده‌تر به‌منظور افزایش حجم داده‌های ورودی به مدل‌های یادگیری ماشین.
 - بررسی آماری داده‌های خام اولیه بازارهای مالی جهت ساخت و معرفی شاخص جدید.
 - بررسی شاخص‌های غیررسمی و استفاده از آنها برای استخراج ویژگی.
 - ترکیب قالب‌های زمانی و استفاده از قالب زمانی بالاتر برای معامله در قالب زمانی پایین‌تر.

١. Admiral markets. (2019) "Forex predictions: how to predict the Forex market" [admiralmarkets.com](https://admiralmarkets.com/education/articles/forex-basics/forex-predictions-how-topredict-the-forex-market). Admiral Markets UK Ltd. Retrieved from <https://admiralmarkets.com/education/articles/forex-basics/forex-predictions-how-topredict-the-forex-market> On 25 February 2019.
٢. Habibullah, M. (2017). A study on currencies – gold - crude and trade balance. *International Journal of Management and Applied Science*, 3(7), pp. 2394-7926.
٣. Raynor de, Forex daily volume with 39 different currencies 2001-2019: *Best, Feb 16, 2021*.
٤. Eleftherios Soulas, Apr (2013), Dennis Shasha, Online machine learning algorithms for currency exchange prediction. - Published.
٥. Borivoje D. Krušković & Tina Maričić, 2015. "Monetary Targeting," *Journal of Central Banking Theory and Practice*, Central bank of Montenegro, vol. 4(3), pages 137-146.
٦. Alejandro Pérez, (2021) "ARTIFICIAL INTELLIGENCE 4 simple ways to label financial data for Machine Learning".
٧. Marcos López de Prado - Nov (2018), *Advances in Financial Machine Learning*.
٨. Liua, Yi Le Wang, aLing Huang, Xueyong Zhangb, 2015-Outward FDI and Stock Price Crash Risk--- Evidence from China Haiyue.
٩. ZS Shaikh, (2021), *Analysis and Evaluation of Technical Indicators for Prediction of Stock Market* GS Thanekar.
١٠. H HUANG - Solid State Technology, (2021), A review of recent applications of AI for games.
١١. J An, R Rau - *The European Journal of Finance*, (2021), Finance, technology, and disruption.
١٢. Mohammed AbuHamad, Masnizah Mohd and Juhana Salim, (٢٠١٣-٠٥-١٣), *EVENT-DRIVEN BUSINESS INTELLIGENCE APPROACH FOR REAL-TIME INTEGRATION OF TECHNICAL AND FUNDAMENTAL ANALYSIS IN FOREX MARKET*.
١٣. Ching-Ru Ko1, Hsien-Tsung Chang March 11, (2021) *LSTM-based sentiment analysis for stock price forecast*.
١٤. Shuai Shao, Robert Stoumbos & X. Frank Zhang, the power of firm fundamental information in explaining stock returns,.
١٥. Don Guy, :2019-Forex Trading Money Management System.
١٦. Wen Long, Zhichen Lu , Lingxiao Cui 22 November (2018), *Deep learning-based feature engineering for stock price movement prediction*.
١٧. MehreenRehmanGul MuhammadKhanSahibzada AliMahmud (2014), *Foreign Currency Exchange Rates Prediction Using CGP and Recurrent Neural Network*.
١٨. KK Nataraja ,J. Gokulachandran-*International Journal of Process Management and Benchmarking* (2021) *Application of artificial neural network techniques in computer-aided process planning-a review*.

- .۱۹ Lean Yu, Kin Keung Lai, Shouyang Wang and Kaijian He (2005), Oil Price Forecasting with an EMD-Based Multiscale Neural Network Learning Paradigm.
- .۲۰ Louis B. Mendelsohn– September 19, (2018), Supercharged Trading with Artificial Intelligence: The Secret to Success in Today's Financial Markets Paperback.
- .۲۱ OB Sezer, MU Gudelek, AM Ozbayoglu - Applied Soft Computing, (2020), Elsevier, Financial time series forecasting with deep learning: A systematic literature review.
- .۲۲ players and evolution Michael King, Carol Osler and Dagfinn Rime (2011), Working Paper from Norges Bank Foreign exchange market structure.
- .۲۳ Jingtao Yao, Chew Lim Tan (2000), A case study on using neural networks to perform technical forecasting of forex.
- .۲۴ ur Sami I (2017) Predicting future gold rates using machine learning approach. Int J Adv Comput Sci Appl 8(12):92–99.
- .۲۵ ElSaid, A., Jamiy, F.E., Higgins, J., Wild, B. and Desell, T. (2018). Optimizing long short-term memory recurrent neural networks using ant colony optimization to predict turbine engine vibration. Applied Soft Computing, 73, pp.969-991.
- .۲۶ Mark Taylor and Helen Allen ‘Journal of International Money and Finance, (1992), The use of technical analysis in the foreign exchange market.
- .۲۷ Luciana Abednego and Cecilia Esti Nugraheni (2018), FOREX DATA ANALYSIS USING WEKA.
- .۲۸ Ntakaris, Martin Magris, Juho Kanninen, Moncef Gabbouj, Alexandros Iosifidis - (2019), Benchmark dataset for mid-price forecasting of limit orderbook data with machine learning methods Adamantios.
- .۲۹ The Foreign Exchange Matrix by Barbara Rockefeller and Vicki Schmelzer.
- .۳۰ A. Abraham; M.U. Chowdhury, (2001) International Conference- An intelligent forex monitoring system. IEEE.
- .۳۱ Ming Hao Eng, Yang Li, Qing-Guo Wang, Tong Heng Lee, IEEE (2008), Forecast Forex with ANN Using Fundamental Data.
- .۳۲ Mohamed Masry, (۲۰۱۷), the Impact of Technical Analysis on Stock Returns in an Emerging Capital Markets (ECM_i’s) Country: Theoretical and Empirical Study.
- .۳۳ S. M. M. Yazdi, Ziba Habibi Lashkari ‘Published (2013), Technical analysis of Forex by MACD Indicator.
- .۳۴ V.V.Kondratenko, Yu. A Kuperin ‘(۲۰۰۳), Using Recurrent Neural Networks To Forecasting of Forex.
- .۳۵ Lean Yu T Shouyang Wang T Kin Keung Lai (2007), Foreign-Exchange-Rate Forecasting With Artificial Neural Networks.
- .۳۶ Aiham Ghazali, Stéphanie Ragot, Cyril Breque, Youcef Guechi¹, Amélie Boureau-Voultoury Franck Petitpas and Denis Oriot (2008) Randomized controlled trial of multidisciplinary team stress and performance in immersive simulation for management of infant in shock: study protocol Daniel.
- .۳۷ Menkhoff, Lukas; Taylor, Mark P. (2006)-The Obstinate Passion of Foreign Exchange Professionals: Technical Analysis.
- .۳۸ Miguel Fuentes and Pablo Pincheira, Juan Manuel Julio and Hernán Rincón, Santiago García-Verdú and Miguel Zerecero, Marco Vega and Erick Lahura and

- Ramon Moreno (2019) The effects of intraday foreign exchange market operations in Latin America: results for Chile, Colombia, Mexico and Peru.
- .۳۹ Svitlana Galeshchuk, Sumitra Mukherjee, March (2017), Intelligent Systems in Accounting Finance & Management Deep networks for predicting direction of change in foreign exchange rates.
- .۴۰ J. Mańdziuk, Piotr Rajkiewicz Computer Science (2016), IEEE-Neuro-evolutionary system for FOREX trading.
- .۴۱ Chatfield, C. (2016). The Analysis of Time Series: An Introduction, Sixth Edition. CRC Press, London.
- .۴۲ Nijole Maknickiene, Algirdas Antano Maknickas, May (2012), APPLICATION OF NEURAL NETWORK FOR FORECASTING OF EXCHANGE RATES AND FOREX TRADING.
- .۴۳ Lee, Bong-Soo, Ingram, Beth Fisher, (1991), Simulation estimation of time-series models.
- .۴۴ Kazem, Ebrahim Sharifi, (2013), Support vector regression with chaos-based firefly algorithm for stock market price forecasting.
- .۴۵ Tay, D. (2017). Time series analysis of discourse: A case study of metaphor in psychotherapy sessions. Discourse Studies, 19(6), pp.694-710.
- .۴۶ Johnston, F. R., Boyland, J. E., Meadows, M., & Shale, E. (1999). Some properties of a simple moving average when applied to forecasting a time series. Journal of the Operational Research Society, 50(12), 1267-1271.
- .۴۷ Venkateswarlu, G., & Sarma, A. D. (2017, February). Performance of Holt-Winter and exponential smoothing methods for forecasting ionospheric TEC using IRNSS data. In 2017 Second International Conference on Electrical, Computer and Communication Technologies (ICECCT) (pp. 1-5). IEEE.
- .۴۸ Philip, A. A., Taofiki, A. A., & Bidemi, A. A. (2011). An artificial neural network model for forecasting foreign exchange rate. World of Computer Science and Information Technology Journal, 1(3), 110-118.
- .۴۹ De Matos, G. (1994). Neural networks for forecasting foreign exchange rates.
- .۵۰ Mahmood, A. and A. Srivastava. *A novel segmentation technique for Urdu type-written text*. in (2018) *Recent Advances on Engineering, Technology and Computational Sciences (RAETCS)* IEEE.
- .۵۱ Nugrahani, T. A., Adi, K., & Suseno, J. E. (2018). Information System Prediction With Weighted Moving Average (WMA) Method And Optimization Distribution Using Vehicles Routing Problem (VRP) Model for Batik Product. In E3S Web of Conferences (Vol. 73, p. 13004). EDP Sciences.
- .۵۲ Chandra, S. R., & Al-Deek, H. (2009). Predictions of freeway traffic speeds and volumes using vector autoregressive models. Journal of Intelligent Transportation Systems, 13(2), 53-72.
- .۵۳ Yu, L., Wang, S., & Lai, K. K. (2005). A novel nonlinear ensemble forecasting model incorporating GLAR and ANN for foreign exchange rates. Computers & Operations Research, 32(10), 2523-2541.
- .۵۴ Chen, S. H., Hwang, S. H., & Wang, Y. R. (1998). An RNN-based prosodic information synthesizer for Mandarin text-to-speech. IEEE transactions on speech and audio processing, 6(3), 226-239.

- .۵۵ Altavilla, C., & De Grauwe, P. (2010). Forecasting and combining competing models of exchange rate determination. *Applied Economics*, 42(27), 3455-3480.
- .۵۶ Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654-669.
- .۵۷ Admiral Markets. (2019) "Forex predictions: how to predict the Forex Market" [admiralmarkets.com](https://admiralmarkets.com/education/articles/forex-basics/forex-predictions-how-to-predict-the-forex-market). Admiral Markets UK Ltd. Retrieved from <https://admiralmarkets.com/education/articles/forex-basics/forex-predictions-how-to-predict-the-forex-market> On 25 February 2019.
- .۵۸ Admiral Markets. (2019) "Forex vs. Stocks: Should You Trade Forex Or Stocks?" [admiralmarkets.com](https://admiralmarkets.com/education/articles/forex-basics/forex-vs-stocks-should-you-trade-forex-or-stocks). Admiral Markets UK Ltd. Retrieved from <https://admiralmarkets.com/education/articles/forex-basics/forex-vs-stocks-should-you-trade-forex-or-stocks>.
- .۵۹ Admiral markets. (2019) "Introduction to Forex technical analysis" [admiralmarkets.com](https://admiralmarkets.com/education/articles/forex-analysis/introduction-to-forextechnical-analysis). Admiral Markets UK Ltd. Retrieved from <https://admiralmarkets.com/education/articles/forex-analysis/introduction-to-forextechnical-analysis>.
- .۶۰ Leung, M. T., Chen, A. S., & Daouk, H. (2000). Forecasting exchange rates using general regression neural networks. *Computers & Operations Research*, 27(11-12), 1093-1110.
- .۶۱ Guyon, I., & Elisseeff, A. (2003). An introduction to variable and feature selection. *Journal of machine learning research*, 3(Mar), 1157-1182.
- .۶۲ Floares, A. G., Calin, G. A., & Manolache, F. B. (2016, June). Bigger Data Is Better for Molecular Diagnosis Tests Based on Decision Trees. In *International Conference on Data Mining and Big Data* (pp. 288-295). Springer, Cham.
- .۶۳ Aungiers, J. (2016). LSTM Neural Network for Time Series Prediction. Retrieved from <http://www.jakob-aungiers.com/articles/a/LSTM-Neural-Network-for-Time-SeriesPrediction>.
- .۶۴ Kondratenko, V. V., & Kuperin, Y. A. (2003). Using recurrent neural networks to forecasting of forex. *arXiv preprint cond-mat/0304469*.
- .۶۵ Luo, X.; Li, D.; Yang, Y.; Zhang, S. Spatiotemporal Traffic Flow Prediction with Knn and Lstm. *J. Adv. Transp.* 2019, 2, 1–10.
- .۶۶ Candès, E.J.; Sur, P. (2020), The Phase Transition for the Existence of the Maximum Likelihood Estimate in High-Dimensional Logistic Regression. *Ann. Stat.* 48, 27–42.
- .۶۷ De Menezes, F.S.; Liska, G.R.; Cirillo, M.A.; Vivanco, M.J.F. (2020), Data Classification with Binary Response through the Boosting Algorithm and Logistic Regression. *Expert Syst. Appl.* 2017, 69, 62–73.
- .۶۸ Grabczewski, K., & Jankowski, N. (2005, November). Feature selection with decision tree criterion. In *Fifth International Conference on Hybrid Intelligent Systems (HIS'05)* (pp. 6-12). IEEE.
- .۶۹ Nadi, A.; Moradi, H. (2019), Increasing the Views and Reducing the Depth in Random Forest. *Expert Syst. Appl.* 138, 112801–112813.
- .۷۰ Pujari, M. V., Sayyed, A. H., Shahani, H., Rupani, D., & Student, B. E. (2018). Forex Trading System. *International Journal of Engineering Science*, 17116.

- .۷۱ Liu, Y.; Zhou, Y.; Chen, Y.; Wang, D.; Wang, Y.; Zhu, Y. (2020), Comparison of Support Vector Machine and Copula-Based Nonlinear Quantile Regression for Estimating the Daily Diffuse Solar Radiation: A Case Study in China. *Renew. Energy* 146, 1101–1112.
- .۷۲ Zendeboudi, A.; Baseer, M.; Saidur, R. (2020), Application of Support Vector Machine Models for Forecasting Solar and Wind Energy Resources: A Review. *J. Clean. Prod.* 2018, 199, 272–285.
- .۷۳ Yu, H.; Ji, N.; Ren, Y.; Yang, C. (2020), A Special Event-Based K-Nearest Neighbor Model for Short-Term Traffic State Prediction. *IEEE Access* 2019, 7, 81717–81729.

فهرست واژگان

عناوین فارسی	عناوین انگلیسی
شبکه‌های عصبی مصنوعی	Artificial Neural Networks
شاخص جهت گیری متوسط	Average Directional Index
محدوده واقعی متوسط	Average True Range
تبادل	Balance
عادی سازی دسته‌ای	Batch Normalization
باندهای بولینگر	Bollinger Bands
برچسب زدن روند مداوم	continuous trend labeling
تحول	Convolution
لایه تحول	Convolution Layer
شبکه‌های عصبی کانولوشنی	Convolutional Neural Network
بر اساس همبستگی	Correlation-based
روند نزولی	DawnTrend
روش مبتنی بر تصمیم درخت	Decision-Tree-based method
از بین رفتن صفر شدن	Dropout
توقف زودهنگام	Early Stopping
فرضیه کارآمد	Efficient Market Hypothesis
گروه	Ensemble
دوران	Epoch
انفجار و محو شدن گرادیان	Exploding and Vanishing Gradient
شیب انفجاری	Exploding gradient
انتخاب ویژگی	Feature Selection
افق زمان ثابت	Fixed-time horizon
گیت را فراموش کنید	Forget Gate

fractile	شکونده
Fully Connected	کاملاً متصل است
Fundamental Analysis	آنالیز بنیادی
Gate Recurrent	دروازه بازگشتی
General Regression Neural Network	شبکه عصبی رگرسیون عمومی
Generalised Linear Auto-Regression	رگرسیون خطی خودکار
Grand Brtania Pound Unted State Dollar	پوند انگلستان به دلار امریکا
Hidden Layer	لایه پنهان
Hidden Markov	مارکوف مخفی
Hierarchical or innovative	سلسله مراتبی یا ابتکاری
Higher Order Neural Network	شبکه عصبی هون
Human Neural Networks	شبکه عصبی طبیعی
Hyper Parameters	ابریامترها
Indicators	شاخص‌ها
Input Gate	دروازه ورودی
Input Layer	لایه ورودی
Interest Rate Parity	نظریه برابری نرخ بهره
International Indebtedness	نظریه بدهی بین المللی
Kernel Function	تابع هسته
Label	برچسب
Local Perception	ادراک محلی
Logistic Regression	رگرسیون لجستیک
Long Short-Term Memory	حافظه کوتاه و بلند مدت
Mean Squared Error	میانگین مربع خطا
MetaTrader	نام یک نرم افزار
Momentum Indicators	شاخص های شتاب

Moving Average Convergence/Divergence	میانگین متحرک/واگرایی
Moving-Avrage	میانگین متحرک
Node	گره
Noise	اختلال
Output Gate	دروازه خروجی
overbuy	خرید بیش از حد
Overfitting	برازش بیش از حد
oversell	فروش بیش از حد
Parabolic Stop and Reverse Indicator	شاخص توقف و معکوس
pip	کوچکترین واحد رشد در یک جفت ارز
pipet	برخی ارزها از پنج رقم بعد از اعشار استفاده می کنند
Pooling	آبگیری
Pooling Layer	لایه تجمع
Predictive Stochastic Complexity	پیچیدگی تصادفی
Purchasing Power Parity	نظریه برابری قدرت خرید
Random Forest	جنگل تصادفی
Random Walk Hypothesis	پیاده روی تصادفی
Recurrent	بازگشتی
Regularization Parameter	پارامتر منظم سازی
Relative Strength Index	شاخص قدرت نسبی
Seasonal ARIMA	آریمای فصلی
Seasonality	فصلی
Sequential Feature Selection	انتخاب ویژگی متوالی
Serial Partitioning	تقسیم بندی سری
Sideway	بازار یک طرفه یا خشی

Simple Avrage	میانگین ساده
Smoothing Simple Exponential	هموارسازی نمایی
Stochastic Oscillator	نوسان ساز تصادفی
Support Vector Machine (SVM)	(SVM) پشتیبانی از دستگاه بردار
Target	هدف
Threshold	حد آستانه
TimeFrame	قالب زمانی
UpTrend	روند صعودی
vanishing gradient	شیب ناپدید شدن
Vector Autoregression (VAR)	رگرسیون اتوماتیک برداری
Volatility Indicators	شاخص های فرار
Weight Sharing	تقسیم وزن
Weighted Moving Average	میانگین متحرک وزن دار
Artificial Neural Networks	شبکه های عصبی مصنوعی

Abstract

Modeling and forecasting the prices of various types of stocks in financial markets with very high sales and a very large impact on the economic growth of countries and organizations, are the challenging goals of researchers, investment companies and reputable banks. With the growth of artificial intelligence and especially deep learning, the performance of the feature learning task was performed through networks designed to do so. In this dissertation, a model of neural networks using CNN and LSTM architectures and inspired by multi-filter neural network (MFNN) is presented, which differs from other models. Different methods are predicted for Feature extraction and production, a new method, specifically for feature extraction in nominal financial series samples and forecasting market price trends. In this method, from different types of indicators, the strategies produced have been produced, which has been used in the production of features. In the following, by introducing a new method in targeting financial data and comparing it with other methods, we will complete the pre-processing steps on the financial time series data. Also, in the continuation of the proposed model, a combination of both CNN and LSTM neural network architectures is used, in order to obtain information about different spaces and the market. We apply our method to predict the most important and largest financial market in the world, the foreign exchange market. The results showed that the proposed model performed better than traditional machine learning models, statistical models and single construction (convolution, RNN and LSTM). (Networks are visible in terms of accuracy, usefulness and stability).

Keywords (5 to 7 Keywords): Deep Learning, Series, Financial Markets, CNN, LSTM, Financial Market Prediction System, Series Analysis



Shahrood University of
Technology

Faculty of Computer Engineering
M.Sc. Thesis in Artificial Intelligence s Engineering

Financial market prediction using deep learning

By: Ali Mohammad Siyahkarzadeh

Supervisors:
Dr. Morteza zahedi

Advisors:
Dr. Mohsen Rezvani

September 2021