

پیش بینی سری های زمانی مالی با رویکرد یادگیری عمیق: مروری بر روش ها، چالش ها و روندهای نوین

غزل حیدری^{۱*}، عباس نجفی مدیسه^۲

۱- دانشجوی کارشناسی پیوسته مهندسی حرفه ای کامپیوتر، دانشگاه ملی مهارت مرکز دختران شهرکرد،

gh.h8d3r@gmail.com

۲- دانشجوی کارشناسی ناپیوسته مهندسی برق قدرت کامپیوتر، دانشگاه ملی مهارت مرکز پسران شهرکرد،

abasnajafi9953@gmail.com

چکیده

پیش بینی قیمت دارایی های مالی همواره یکی از چالش برانگیزترین مسائل در حوزه مالی و اقتصاد بوده است. ماهیت غیرخطی، ناپیوسته و پویای بازارهای مالی، روش های آماری سنتی را با محدودیت های جدی مواجه کرده و زمینه را برای ظهور رویکردهای نوین مبتنی بر یادگیری عمیق فراهم آورده است. این مقاله به مرور نظام مند روش های پیش بینی سری های زمانی مالی بر پایه یادگیری عمیق می پردازد. چهار پارادایم اصلی شامل شبکه های عصبی پیچشی، شبکه های عصبی بازگشتی و مشتقات آنها مانند حافظه طولانی مدت کوتاه مدت، شبکه های عصبی گراف و مدل های مبتنی بر سازوکار توجه از جمله ترانسفورم ها، به طور مفصل بررسی می شوند. همچنین، مفاهیم کلیدی در آموزش این مدل ها از جمله توابع خطا و سنج های ارزیابی با نگاهی ویژه به کاربردهای مالی تحلیل می شوند. یافته ها نشان می دهد که مدل های ترکیبی و معماری های مبتنی بر توجه، به ویژه در مواجهه با نوسانات شدید بازار و افق های پیش بینی بلندمدت، عملکرد پایدارتری نسبت به رویکردهای سنتی دارند. در پایان، چالش های موجود از جمله نرمال سازی داده ها، نشت اطلاعات، تفسیرپذیری و پیچیدگی محاسباتی مورد بحث قرار گرفته و مسیرهای پژوهشی آینده ترسیم می شود.

کلمات کلیدی: پیش بینی سری های زمانی مالی، یادگیری عمیق، شبکه های عصبی بازگشتی، ترانسفورم، شبکه های عصبی گراف، بازار سهام

۱. مقدمه

پیش بینی بازارهای مالی از دیرباز یکی از جذاب ترین و در عین حال دشوارترین حوزه های پژوهشی در علوم مالی، اقتصاد و مهندسی کامپیوتر بوده است. سرمایه گذاران، تحلیل گران مالی، مدیران صندوق های سرمایه گذاری و سیاست گذاران اقتصادی همواره به دنبال ابزارهایی بوده اند که بتوانند با دقتی قابل قبول، مسیر آینده قیمت دارایی های مالی را پیش بینی کنند. این پیش بینی ها نه تنها در تصمیم گیری های سرمایه گذاری نقشی حیاتی ایفا می کنند، بلکه در مدیریت ریسک، بهینه سازی سبد دارایی و حتی تدوین سیاست های کلان اقتصادی نیز کاربردهای گسترده ای دارند. با این حال، ماهیت ذاتاً پیچیده، غیرخطی و پویای بازارهای مالی، پیش بینی دقیق قیمت ها را به یک چالش جدی تبدیل کرده است.

روش‌های سنتی پیش‌بینی سری‌های زمانی مالی عمدتاً بر پایه مدل‌های آماری و اقتصادسنجی مانند خودرگرسیون یکپارچه میانگین متحرک، خودرگرسیون برداری و مدل‌های خانواده خودرگرسیون شرطی ناهمسانی واریانس استوار بودند. این مدل‌ها با وجود سادگی و تفسیرپذیری بالا، فرضیات محدودکننده‌ای مانند خطی بودن روابط، ایستایی داده‌ها و نرمال بودن توزیع خطاها را پیش‌فرض می‌گیرند که در عمل و در مواجهه با داده‌های واقعی بازارهای مالی به ندرت برقرار هستند. بازارهای مالی تحت تأثیر عوامل بیشمار از جمله رویدادهای سیاسی، اقتصادی، اجتماعی، رفتار جمعی سرمایه‌گذاران و حتی پدیده‌های روانشناختی قرار دارند که همگی تعاملاتی غیرخطی و پیچیده با یکدیگر دارند. این محدودیت‌ها باعث شده است که روش‌های سنتی نتوانند پاسخگوی نیازهای روزافزون به پیش‌بینی‌های دقیق و قابل اعتماد باشند.

با ظهور روش‌های یادگیری ماشین در دهه‌های اخیر، افق‌های جدیدی در حوزه پیش‌بینی مالی گشوده شد. الگوریتم‌هایی مانند ماشین بردار پشتیبان، جنگل تصادفی و شبکه‌های عصبی مصنوعی ساده توانستند با کنار گذاشتن فرضیات محدودکننده روش‌های آماری، عملکرد بهتری در شناسایی الگوهای غیرخطی داده‌ها از خود نشان دهند. با این حال، این روش‌ها نیز با چالش‌هایی نظیر وابستگی شدید به مهندسی ویژگی، مشکل بیش‌برازش و محدودیت در مدل‌سازی وابستگی‌های زمانی طولانی‌مدت مواجه بودند. به‌ویژه در حوزه سری‌های زمانی، جایی که ترتیب و توالی داده‌ها از اهمیت بالایی برخوردار است، روش‌های سنتی یادگیری ماشین به دلیل ناتوانی در حفظ حافظه از مشاهدات گذشته، عملکرد چندانی مطلوبی نداشتند.

نقطه عطف در این حوزه با معرفی و گسترش روش‌های یادگیری عمیق رقم خورد. شبکه‌های عصبی عمیق با ساختار چندلایه خود، توانایی بالایی در استخراج خودکار ویژگی‌های معنادار از داده‌های خام دارند و نیاز به مهندسی ویژگی دستی را به حداقل می‌رسانند. در میان معماری‌های مختلف یادگیری عمیق، شبکه‌های عصبی بازگشتی و به‌ویژه نوع پیشرفته آن یعنی حافظه طولانی‌مدت کوتاه‌مدت، به دلیل طراحی خاص خود برای پردازش داده‌های ترتیبی، به سرعت به ابزاری محبوب برای پیش‌بینی سری‌های زمانی مالی تبدیل شدند. این شبکه‌ها با حفظ یک حافظه داخلی و استفاده از سازوکارهای دروازه‌ای، قادر به یادگیری وابستگی‌های طولانی‌مدت در داده‌ها هستند و مشکل محو شدن گرادبان در شبکه‌های بازگشتی ساده را برطرف می‌کنند.

با گذشت زمان و پیشرفت‌های مستمر در حوزه یادگیری عمیق، معماری‌های متنوع‌تری برای پیش‌بینی سری‌های زمانی مالی معرفی شدند. شبکه‌های عصبی پیچشی یک‌بعدی که پیشتر در پردازش تصویر موفقیت چشمگیری کسب کرده بودند، به‌عنوان ابزاری کارآمد برای استخراج الگوهای محلی و ویژگی‌های دوره‌ای در سری‌های زمانی مورد استفاده قرار گرفتند. در سال‌های اخیر، معماری ترانسفورم که ابتدا برای پردازش زبان طبیعی معرفی شد، انقلابی در حوزه سری‌های زمانی ایجاد کرده است و مدل‌های مبتنی بر آن مانند Informer، Autoformer، FEDformer و PatchTST با ارائه مکانیزم‌های توجه کارآمد، امکان پردازش دنباله‌های بلندمدت را با دقت بالا فراهم کرده‌اند. همچنین، شبکه‌های عصبی گراف با مدل‌سازی روابط بین متغیرهای مختلف در سری‌های زمانی چندمتغیره، رویکرد جدیدی را برای پیش‌بینی مالی ارائه داده‌اند که در آن تعاملات بین دارایی‌های مختلف به‌صورت گراف مدل‌سازی می‌شود.

علاوه بر معماری مدل‌ها، دو مؤلفه کلیدی دیگر در موفقیت روش‌های یادگیری عمیق برای پیش‌بینی مالی نقش اساسی دارند: توابع خطا و سنج‌های ارزیابی. انتخاب تابع خطای مناسب که بتواند مدل را در جهت اهداف سرمایه‌گذاری هدایت کند، از اهمیت ویژه‌ای برخوردار است. در حالی که بسیاری از پژوهش‌ها از توابع خطای متقارن مانند میانگین مربعات خطا استفاده می‌کنند، این توابع نمی‌توانند عدم تقارن در اهمیت خطاهای بیش‌برآوردی و کم‌برآوردی در بازارهای مالی را مدل‌سازی کنند. از این رو، پژوهش‌های اخیر به سمت استفاده از توابع خطای نامتقارن مانند تابع خطای پین‌بال (Pinball)

(Loss) و تابع خطای LINEX حرکت کرده‌اند که عملکرد مدل را بر اساس معیارهای عملی سرمایه‌گذاری مانند نسبت شارپ ارزیابی می‌کنند. همچنین، سنج‌های ارزیابی سنتی مانند RMSE و MAE هرچند برای مقایسه مدل‌ها مفید هستند، اما نمی‌توانند سودآوری واقعی یک استراتژی مبتنی بر پیش‌بینی را اندازه‌گیری کنند.

۱-۱. تحلیل شکاف پژوهشی

گرچه مرورهای متعددی در حوزه پیش‌بینی مالی با رویکرد یادگیری عمیق انجام شده است، اما بررسی دقیق آن‌ها نشان می‌دهد که شکاف‌های قابل توجهی همچنان باقی مانده است. مرور جامع Zhang و همکاران (۲۰۲۴) [۲] عمدتاً بر مدل‌های نقطه‌ای متمرکز بوده و به پیش‌بینی بازه‌ای و توابع خطای نامتقارن نپرداخته است. مرور Sezer و همکاران (۲۰۲۰) [۱۸] نیز با وجود جامعیت، به مدل‌های مبتنی بر ترانسفورم و GNN که در سال‌های اخیر ظهور کرده‌اند، اشاره‌ای نداشته است. همچنین، مرورهای موجود عمدتاً بر روش‌های بین‌المللی متمرکز بوده و کمتر به کاربرد این روش‌ها در بازارهای نوظهور مانند بورس تهران پرداخته‌اند. علاوه بر این، هیچ‌یک از مرورهای پیشین، تحلیل مقایسه‌ای از هزینه محاسباتی مدل‌های مختلف را ارائه نداده‌اند که این موضوع برای کاربردهای عملی از اهمیت بالایی برخوردار است. از سوی دیگر، بررسی توابع خطا در مرورهای قبلی عمدتاً به توابع متقارن محدود شده و توابع نامتقارن و مبتنی بر سود به‌ندرت مورد بحث قرار گرفته‌اند. این مقاله تلاش دارد تا با رویکردی نقادانه، این شکاف‌ها را پر کرده و نقشه راهی جامع برای پژوهشگران این حوزه ترسیم نماید.

۲. روش‌شناسی مرور و تحلیل شکاف


این پژوهش یک مرور روایی با رویکرد تحلیلی-انتقادی است که بر اساس جستجو در پایگاه‌های داده Scopus، Web of Science، IEEE Xplore، ScienceDirect و Google Scholar با کلیدواژه‌های مرتبط با یادگیری عمیق و پیش‌بینی مالی انجام شده است. بازه زمانی جستجو ۲۰۱۵ تا ۲۰۲۵ در نظر گرفته شد و از میان ۸۴۲ مقاله اولیه، پس از غربالگری اولیه، ۶۸ مقاله کلیدی به‌عنوان منابع اصلی این مرور انتخاب شدند. در بخش‌های بعدی، ابتدا چالش‌های ذاتی پیش‌بینی بازارهای مالی بررسی شده و سپس معماری‌های مختلف یادگیری عمیق، توابع خطا و سنج‌های ارزیابی مورد تحلیل قرار می‌گیرند.

۲-۱- چالش‌های ذاتی پیش‌بینی بازارهای مالی

درک ماهیت داده‌های مالی و چالش‌های ذاتی پیش‌بینی آن‌ها، گام نخست در انتخاب و طراحی مدل‌های مناسب است. سری‌های زمانی مالی دارای ویژگی‌های منحصربه‌فردی هستند که آن‌ها را از سایر انواع داده‌های سری‌زمانی متمایز می‌کند. داده‌های سری‌زمانی مالی، دنباله‌ای از مشاهدات هستند که در فواصل زمانی منظم از یک دارایی مالی مانند سهام، ارز، کالا یا شاخص برداشت می‌شوند. قیمت پایانی، قیمت آغازین، بالاترین قیمت، پایین‌ترین قیمت و حجم معاملات از جمله متداول‌ترین مشاهدات در این حوزه هستند.

نخستین و شاید مهم‌ترین ویژگی سری‌های زمانی مالی، غیرخطی بودن آن‌هاست. برخلاف بسیاری از پدیده‌های طبیعی که روابط خطی ساده‌ای بین متغیرهای خود دارند، بازارهای مالی تحت تأثیر شبکه‌ای پیچیده از عوامل اقتصادی، سیاسی،

روانشناختی و اجتماعی قرار دارند که به صورت غیرخطی با یکدیگر تعامل دارند. ویژگی دوم، ناپیوسته بودن سری‌های زمانی مالی است که تغییر توزیع آماری داده‌ها در طول زمان را نشان می‌دهد. ویژگی سوم، وجود نوسانات خوشه‌ای است که در آن دوره‌های نوسان شدید معمولاً با یکدیگر دنبال می‌شوند. ویژگی چهارم، وجود حافظه بلندمدت در داده‌های مالی است که مدل‌هایی را که قادر به حفظ و استفاده از اطلاعات گذشته‌دور هستند، برای پیش‌بینی مالی ضروری می‌سازد. ویژگی پنجم، نسبت سیگنال به نویز بسیار پایین در داده‌های مالی است که تشخیص الگوهای معنادار را از میان نوسانات تصادفی بسیار




دشوار می‌سازد. این چالش‌ها در شکل ۱ به صورت خلاصه نمایش داده شده‌اند.
(تصویر ۱- چالش‌های اصلی در پیش‌بینی بازارهای مالی)

۳. معماری‌های یادگیری عمیق در پیش‌بینی مالی

۱-۳- شبکه‌های عصبی پیچشی

شبکه‌های عصبی پیچشی که پیشتر در حوزه بینایی ماشین و پردازش تصویر موفقیت‌های چشمگیری کسب کرده بودند، به تدریج جای خود را در حوزه سری‌های زمانی و پیش‌بینی مالی باز کردند. این شبکه‌ها با بهره‌گیری از عملگر پیچش، قادر به استخراج خودکار ویژگی‌های محلی و الگوهای دوره‌ای از داده‌های ورودی هستند. در سری‌های زمانی مالی، شبکه‌های پیچشی یک‌بعدی می‌توانند روابط کوتاه‌مدت بین نقاط داده مجاور را شناسایی کنند و این ویژگی آن‌ها را برای تشخیص الگوهای تکنیکال در داده‌های قیمتی مناسب می‌سازد.

ساختار پایه یک شبکه پیچشی یک‌بعدی شامل لایه‌های پیچش، لایه‌های تجمیع و لایه‌های کاملاً متصل است. لایه پیچش با اعمال فیلترهایی با اندازه مشخص بر روی پنجره‌های داده، نقشه‌های ویژگی تولید می‌کند. شکل ۲، معماری کامل یک شبکه عصبی پیچشی یک‌بعدی را برای پیش‌بینی سری‌های زمانی مالی نمایش می‌دهد.




(تصویر ۲- معماری شبکه عصبی پیچشی یک بعدی (1D CNN))

همان‌طور که در شکل ۲ مشاهده می‌شود، داده ورودی ابتدا به وسیله یک پنجره کشویی با اندازه مشخص به بخش‌هایی تقسیم می‌شود. سپس لایه پیچش با اعمال فیلترهایی بر روی این پنجره‌ها، نقشه‌های ویژگی را تولید می‌کند. در ادامه، لایه تجمیع بیشینه ابعاد را کاهش داده و در نهایت لایه کاملاً متصل، پیش‌بینی نهایی را انجام می‌دهد. شبکه‌های پیچشی زمانی مانند ModernTCN با بهره‌گیری از پیچش‌های علی، گشادشده و بلوک‌های باقیمانده، نسخه بهبودیافته‌ای هستند که عملکردی قابل رقابت با مدل‌های ترانسفورم در پیش‌بینی سری‌های زمانی دارند. با این حال، این شبکه‌ها در مدل‌سازی وابستگی‌های طولانی‌مدت که در سری‌های زمانی مالی بسیار حائز اهمیت است، با محدودیت مواجه هستند و به‌تنهایی به‌ندرت برای پیش‌بینی مالی استفاده می‌شوند.

۲-۳- شبکه‌های عصبی بازگشتی و حافظه طولانی‌مدت کوتاه‌مدت

شبکه‌های عصبی بازگشتی، نخستین معماری‌های یادگیری عمیق بودند که به‌طور خاص برای پردازش داده‌های ترتیبی طراحی شدند. این شبکه‌ها با حفظ یک حالت پنهان که از گام‌های زمانی قبلی به گام فعلی منتقل می‌شود، قادر به مدل‌سازی وابستگی‌های زمانی در داده‌ها هستند. با وجود این مزیت، شبکه‌های بازگشتی ساده با مشکل محو شدن یا انفجار گرادیان مواجه هستند. حافظه طولانی‌مدت کوتاه‌مدت با معرفی سازوکارهای دروازه‌ای، این مشکل را برطرف کرده و به معماری غالب در پیش‌بینی سری‌های زمانی مالی تبدیل شده است.

یک سلول LSTM شامل چهار مؤلفه اصلی است: دروازه ورودی، دروازه فراموشی، دروازه خروجی و سلول حافظه. دروازه فراموشی تعیین می‌کند که چه مقدار از اطلاعات قبلی سلول حافظه باید حفظ شود و چه مقدار باید دور ریخته شود. دروازه ورودی تصمیم می‌گیرد که چه اطلاعات جدیدی باید به سلول حافظه اضافه شود و دروازه خروجی مشخص می‌کند که چه بخشی از محتوای سلول حافظه باید به‌عنوان خروجی در گام زمانی فعلی استفاده شود. شکل ۳، ساختار داخلی یک سلول LSTM را به‌طور دقیق نمایش می‌دهد.




(تصویر ۳- معماری سلول حافظه طولانی مدت کوتاه مدت (LSTM))

همان‌طور که در شکل 3 مشاهده می‌شود، جریان داده در سلول LSTM از چپ به راست حرکت می‌کند. ورودی‌های سلول شامل x_t (ورودی فعلی)، h_{t-1} (حالت پنهان از زمان قبلی) و c_{t-1} (حالت حافظه از زمان قبلی) هستند. این سه ورودی از طریق سه دروازه اصلی پردازش می‌شوند و در نهایت h_t (حالت پنهان جدید) و c_t (حالت حافظه جدید) را تولید می‌کنند. واحد بازگشتی دروازه‌دار (GRU) نیز نسخه ساده‌تری از LSTM است که با ترکیب دروازه ورودی و فراموشی، تعداد پارامترهای کمتری دارد و آموزش آن سریع‌تر است. مطالعات نشان داده‌اند که مدل‌های مبتنی بر LSTM و GRU در پیش‌بینی بازارهای مالی عملکرد بسیار خوبی دارند، هرچند که ماهیت ترتیبی این شبکه‌ها باعث می‌شود آموزش آن‌ها به‌سختی موازی‌سازی شود [۲۳، ۲۴، ۲۵].

۳-۳- شبکه‌های عصبی گراف

رویکرد نوین دیگری که در سال‌های اخیر مورد توجه پژوهشگران حوزه پیش‌بینی مالی قرار گرفته، استفاده از شبکه‌های عصبی گراف است. در بازارهای مالی، دارایی‌های مختلف به‌صورت مجزا عمل نمی‌کنند، بلکه شبکه‌ای از روابط پیچیده بین آن‌ها وجود دارد. حرکت قیمت یک سهم می‌تواند بر سهام همگروه، رقبا و حتی کل بازار تأثیر بگذارد. شبکه‌های عصبی گراف با مدل‌سازی این روابط به‌صورت یک گراف که در آن گره‌ها نشان‌دهنده دارایی‌ها و یال‌ها نشان‌دهنده روابط بین آن‌ها هستند، امکان بهره‌گیری از این تعاملات را برای پیش‌بینی دقیق‌تر فراهم می‌کنند [۱۲].

در یک شبکه عصبی گراف، هر گره دارای یک بردار ویژگی است که می‌تواند شامل تاریخچه قیمت، شاخص‌های تکنیکال و سایر اطلاعات مرتبط با آن دارایی باشد. شکل 4، معماری کامل یک شبکه عصبی گراف را برای سری‌های زمانی چندمتغیره مالی نمایش می‌دهد.




(تصویر ۴- معماری شبکه عصبی گراف (GNN))

همان‌طور که در شکل ۴ مشاهده می‌شود، ورودی مدل یک گراف با ۶ گره است که هر گره نماینده یک دارای مالی است. لایه پیچش گرافی (GCN) اطلاعات بین گره‌های مجاور را انتشار می‌دهد. سپس لایه LSTM وابستگی‌های زمانی را مدل‌سازی می‌کند. در نهایت، لایه جمع‌آوری اطلاعات همه گره‌ها را جمع‌بندی کرده و لایه کاملاً متصل، پیش‌بینی قیمت هر دارای را تولید می‌کند. با این حال، مهم‌ترین چالش در کاربرد این مدل‌ها، تعیین ساختار گراف و روابط بین گره‌هاست که برخی روابط مالی ظریف و پویا هستند و در طول زمان تغییر می‌کنند.

۴-۳- مدل‌های مبتنی بر ترانسفورم

معماری ترانسفورم که در سال ۲۰۱۷ معرفی شد، انقلابی در حوزه پردازش زبان طبیعی ایجاد کرد و به تدریج جای خود را در سایر حوزه‌ها از جمله پیش‌بینی سری‌های زمانی نیز باز کرد. برخلاف شبکه‌های بازگشتی که دنباله‌های ورودی را به صورت گام‌به‌گام و ترتیبی پردازش می‌کنند، ترانسفورم با استفاده از سازوکار توجه به خود، امکان پردازش موازی کل دنباله ورودی را فراهم می‌کند. شکل ۵، معماری کامل مدل ترانسفورم را برای پیش‌بینی سری‌های زمانی مالی نشان می‌دهد.




(تصویر 5- معماری مدل ترانسفورم)

همان طور که در شکل ۳ مشاهده می شود، معماری ترانسفورم از پایین به بالا جریان داده را نشان می دهد. داده های ورودی ابتدا از لایه جاسازی و رمزگذار موقعیت عبور می کنند. سپس از چندین لایه رمزگذار که هر کدام شامل توجه به خود چندسر، اتصالات باقیمانده و شبکه پیشخور هستند، عبور می کنند. در نهایت، لایه خطی خروجی نهایی را تولید می کند. مدل های متعددی مبتنی بر ترانسفورم مانند [۶]Informer، [۷]Autoformer، [۸]FEDformer و [۹] PatchTST برای پیش بینی سری های زمانی مالی ارائه شده اند که هر کدام با مکانیزم های نوآورانه، چالش های محاسباتی و دقت را بهبود بخشیده اند. با وجود موفقیت های چشمگیر، مصرف بالای حافظه و پردازش برای دنباله های بلند، نیاز به حجم بسیار زیاد داده و تمایل به بیش برآزش از چالش های اصلی این مدل ها هستند.

۵-۳- مدل های ترکیبی و نوین

یکی از رویکردهای موفق در پیش بینی مالی، استفاده از مدل های ترکیبی است که نقاط قوت معماری های مختلف را با یکدیگر تلفیق می کنند. ترکیب شبکه های پیش خشی و بازگشتی، رایج ترین نوع مدل های ترکیبی در این حوزه است. در این معماری، لایه های پیش خشی ابتدا ویژگی های محلی و الگوهای دوره ای را از داده های ورودی استخراج می کنند و سپس خروجی

این لایه‌ها به یک شبکه بازگشتی مانند LSTM یا GRU داده می‌شود تا وابستگی‌های زمانی طولانی مدت مدل‌سازی شوند. رویکرد دیگر، استفاده از روش‌های تجزیه سیگنال مانند تجزیه مود تجربی یا تبدیل موجک پیش از ورود داده‌ها به شبکه عصبی است که سری زمانی اصلی را به چندین مؤلفه با مقیاس‌های زمانی مختلف تجزیه می‌کند. همچنین، مدل‌های ترکیبی مبتنی بر ترانسفورم و ترکیب شبکه‌های گراف با ترانسفورم در سال‌های اخیر مورد توجه قرار گرفته‌اند. شکل ۶، سه رویکرد اصلی ترکیبی را نمایش می‌دهد.



(تصویر ۶- رویکردهای ترکیبی در پیش‌بینی مالی)

جدول ۱، خلاصه مقایسه‌ای معماری‌های یادگیری عمیق را برای پیش‌بینی مالی ارائه می‌دهد که شامل مزایا، معایب و

کاربرد مناسب هر معماری است.

معماری	مزایا	معایب	کاربرد مناسب
CNN	استخراج ویژگی‌های محلی، سرعت بالا، موازی‌سازی آسان	محدودیت در مدل‌سازی وابستگی‌های بلندمدت	شناسایی الگوهای تکنیکال کوتاه‌مدت
RNN/LSTM	مدل‌سازی وابستگی‌های زمانی، حفظ حافظه بلندمدت	آموزش ترتیبی، زمان بر، مشکل محو شدن گرادینان	دنباله‌های با وابستگی زمانی قوی
GRU	مشابه LSTM با پارامترهای کمتر و سرعت بیشتر	ظرفیت کمتر نسبت به LSTM	داده‌های محدود و نیاز به سرعت بالا
GNN	مدل‌سازی روابط بین متغیرها، شناسایی تعاملات	نیاز به تعریف ساختار گراف، پیچیدگی بالا	سری‌های زمانی چندمتغیره با روابط مشخص
Transformer	مدل‌سازی وابستگی‌های بلندمدت، موازی‌سازی عالی	نیاز به داده زیاد، مصرف حافظه بالا	دنباله‌های بلند با روابط پیچیده

کاربردهای عمومی پیش‌بینی مالی	پیچیدگی و زمان آموزش بیشتر	بهره‌گیری همزمان از مزایای هر دو معماری	ترکیبی CNN-LSTM
-------------------------------	----------------------------	---	-----------------

جدول ۱- خلاصه مقایسه‌ای معماری‌های یادگیری عمیق برای پیش‌بینی مالی

۳-۶- مقایسه هزینه محاسباتی معماری‌های یادگیری عمیق

یکی از چالش‌های عملی در کاربرد مدل‌های یادگیری عمیق برای پیش‌بینی مالی، هزینه محاسباتی بالای آن‌هاست.

جدول ۲، مقایسه‌ای از تعداد پارامترها، زمان آموزش و حافظه مصرفی مدل‌های مختلف را بر اساس مطالعات مرور شده ارائه می‌دهد.

سخت‌افزار پیشنهادی	(GB) حافظه مصرفی	زمان آموزش (نسبی)	تعداد پارامتر (میلیون)	معماری
ساده CPU/GPU	۲-۴	۱X	۵-۲۰	ساده CNN
میان‌رده GPU	۴-۸	۳X	۱-۵	LSTM
میان‌رده GPU	۳-۶	۵/۲X	۸-۴۰	GRU
پیشرفته GPU	۸-۱۶	۵-۱۰X	۵-۲۰	Transformer
پیشرفته GPU	۶-۱۲	۴-۸X	۲-۱۰	GNN
پیشرفته GPU	۶-۱۰	۴-۶X	۳-۱۲	ترکیبی CNN-LSTM
حرفه‌ای GPU (۲۴GB+)	۱۲-۲۴	۸-۱۵X	۱۰-۳۰	Transformer+GNN

جدول ۲- مقایسه هزینه محاسباتی معماری‌های یادگیری عمیق

همان‌طور که در جدول ۲ مشاهده می‌شود، مدل‌های مبتنی بر ترانسفورم و ترکیبی آن‌ها با گراف، بالاترین هزینه محاسباتی را دارند و نیازمند سخت‌افزارهای پیشرفته هستند. در مقابل، مدل‌های CNN و GRU با هزینه محاسباتی پایین‌تر، گزینه‌های مناسبی برای کاربردهای با منابع محدود محسوب می‌شوند.

۴. توابع خطا و سنج‌های ارزیابی

۴-۱- توابع خطا

انتخاب تابع خطای مناسب، یکی از مهم‌ترین تصمیم‌ها در طراحی مدل‌های یادگیری عمیق برای پیش‌بینی مالی است. تابع خطا، معیاری است که میزان اختلاف بین خروجی مدل و مقادیر واقعی را اندازه‌گیری می‌کند و فرآیند بهینه‌سازی مدل بر اساس کمینه‌سازی این تابع انجام می‌شود. متداول‌ترین تابع خطا در پیش‌بینی سری‌های زمانی، میانگین مربعات خطا (MSE) است که میانگین مربع اختلاف بین مقادیر پیش‌بینی شده و واقعی را محاسبه می‌کند. میانگین قدرمطلق خطا (MAE) نیز تابع خطای دیگری است که به جای مجذور کردن خطاها، قدرمطلق آن‌ها را محاسبه می‌کند و نسبت به نقاط پرت مقاوم‌تر است.

با وجود کاربرد گسترده این توابع خطای متقارن، آن‌ها در حوزه مالی با یک محدودیت اساسی مواجه هستند: هزینه خطای بیش‌برآوردی و کم‌برآوردی یکسان نیست. به همین دلیل، پژوهشگران به سمت استفاده از توابع خطای نامتقارن روی آورده‌اند. از جمله مهم‌ترین این توابع می‌توان به موارد زیر اشاره کرد:

۱- تابع خطای پینبال (Pinball Loss): این تابع در مسائل رگرسیون چندکی کاربرد گسترده‌ای دارد و به صورت زیر تعریف می‌شود.

$$L_{\tau}(y, \hat{y}) = \begin{cases} \tau(y - \hat{y}) & y \geq \hat{y} \\ (\tau - 1)(y - \hat{y}) & y < \hat{y} \end{cases}$$

که در آن، τ نشان‌دهنده چندک مورد نظر است. در حوزه مالی، این تابع خطا به سرمایه‌گذاران امکان می‌دهد تا پیش‌بینی‌های خود را بر اساس ریسک‌پذیری خود تنظیم کنند.

۲- تابع خطای LINEX: این تابع خطا به صورت زیر تعریف می‌شود:

$$L_{LINEX}(y, \hat{y}) = e^{a(y-\hat{y})} - a(y - \hat{y}) - 1$$

که در آن، a پارامتر کنترل‌کننده عدم تقارن است. این تابع خطا به‌ویژه برای مسائلی که هزینه خطای بیش‌برآوردی و کم‌برآوردی به شدت متفاوت است (مانند بازارهای مالی) مناسب می‌باشد. مطالعات نشان داده است که استفاده از تابع خطای LINEX در پیش‌بینی شاخص کل بورس تهران، بهبود قابل توجهی در نسبت شارپ را نسبت به توابع خطای متقارن به همراه داشته است [1].

۳- توابع خطای مبتنی بر سود: گام فراتر از توابع خطای نامتقارن، استفاده از توابع خطای مبتنی بر سود است که مستقیماً عملکرد سرمایه‌گذاری را بهینه‌سازی می‌کنند. در این رویکرد، تابع خطا بر اساس معیارهای مالی مانند بازده سرمایه‌گذاری یا نسبت شارپ تعریف می‌شود.


۲-۴- سنج‌های ارزیابی

پس از آموزش مدل، ارزیابی عملکرد آن با استفاده از سنج‌های مختلف انجام می‌شود. این سنج‌ها را می‌توان به سه دسته کلی تقسیم کرد: سنج‌های خطا، سنج‌های طبقه‌بندی و سنج‌های مبتنی بر سود که در شکل ۷ به صورت خلاصه نمایش داده شده‌اند.



(تصویر ۷- سنج‌های ارزیابی در پیش‌بینی سری‌های زمانی مالی)

سنج‌های خطا مانند RMSE، MAE و MAPE میزان انحراف پیش‌بینی‌ها از مقادیر واقعی را اندازه‌گیری می‌کنند. سنج‌های طبقه‌بندی مانند Accuracy، Precision، Recall و F1-Score برای مسائلی که هدف پیش‌بینی جهت حرکت قیمت است، به کار می‌روند. سنج‌های مبتنی بر سود، جدیدترین و کاربردی‌ترین دسته از سنج‌های ارزیابی در حوزه مالی هستند. این سنج‌ها با شبیه‌سازی استراتژی معاملاتی مبتنی بر پیش‌بینی‌های مدل، عملکرد واقعی آن را اندازه‌گیری می‌کنند. بازده سرمایه‌گذاری، نسبت شارپ و حداکثر افت سرمایه از جمله مهم‌ترین این سنج‌ها هستند. شکل ۴، عملکرد سه مدل LSTM، Transformer و ARIMA را در پیش‌بینی قیمت سهام مقایسه می‌کند.



(تصویر ۴- مقایسه نتایج پیش‌بینی مدل‌های مختلف)

نتایج شکل ۴ به وضوح نشان می‌دهد که مدل Transformer با کمترین میزان خطا ($RMSE=2987.45$) و بهترین عملکرد را در بین مدل‌های مورد بررسی دارد. مدل LSTM با $RMSE=6502.31$ و $MAE=2198.33$ بهترین عملکرد را نشان می‌دهد. این نتایج نشان می‌دهد که معماری‌های مبتنی بر توجه، به‌ویژه در مواجهه با داده‌های مالی با نوسانات بالا، عملکرد پایدارتری نسبت به روش‌های سنتی دارند.

۵. چالش‌ها و مسیرهای پژوهشی آینده

با وجود رشد چشمگیر پژوهش‌های مرتبط با یادگیری عمیق در حوزه مالی بین‌المللی، مطالعات داخلی در این زمینه عمدتاً بر روش‌های سنتی و مدل‌های آماری متمرکز بوده‌اند. با این حال، در سال‌های اخیر پژوهش‌های ارزشمندی در زمینه کاربرد شبکه‌های عصبی عمیق در بورس تهران انجام شده است که نشان‌دهنده پتانسیل بالای این روش‌ها در بازار سرمایه ایران است.

مطالعه گلنبر و همکاران (۲۰۲۵) با استفاده از معماری SLSAE و داده‌های ۱۰ سهم برتر بورس تهران در بازه ۱۳۹۱ تا ۱۴۰۲ نشان داد که مدل‌های یادگیری عمیق با ساختار نظارت‌شده پشته‌ای می‌توانند دقت پیش‌بینی قیمت پایانی را به‌طور قابل توجهی بهبود بخشند. این مطالعه نشان داد که مدل SLSAE با $RMSE$ کمتر از ۰.۲/۰ و R^2 بالای ۹۷/۰ در اکثر سهام، عملکردی به مراتب بهتر از مدل‌های سنتی ARIMA و ANN دارد [۴]. همچنین، مطالعه اصولیان و همکاران (۱۴۰۴) که به بررسی مدل‌های هیبریدی CNN-LSTM در بورس تهران پرداخت، نشان داد که برخلاف تصور رایج، شبکه‌های پیچشی به‌تنهایی در برخی مقیاس‌های زمانی (به‌ویژه هفتگی و ماهانه) عملکرد بهتری از مدل‌های هیبریدی دارند و این یافته چالش‌های جدیدی را در طراحی معماری‌های مناسب برای بازارهای نوظهور مطرح می‌کند. [۵]

با این حال، تحلیل این پژوهش‌ها نشان می‌دهد که کاربرد یادگیری عمیق در بورس تهران همچنان با چالش‌های متعددی روبرو است. از جمله مهم‌ترین این چالش‌ها می‌توان به محدودیت دسترسی به داده‌های باکیفیت و طولانی‌مدت، نبود زیرساخت‌های محاسباتی مناسب و نبود یک معیار استاندارد برای ارزیابی عملکرد مدل‌ها در بازار ایران اشاره کرد. همچنین، بررسی پژوهش‌های داخلی نشان می‌دهد که توجه به مدل‌های ترکیبی و توابع خطای نامتقارن در مطالعات ایرانی بسیار محدود بوده و این حوزه همچنان نیازمند پژوهش‌های گسترده‌تری است.

۶. چالش‌ها و مسیرهای پژوهشی آینده

با وجود پیشرفت‌های چشمگیر در کاربرد یادگیری عمیق برای پیش‌بینی مالی، چالش‌های متعددی همچنان باقی مانده است که نیازمند پژوهش‌های بیشتر است. در این بخش، مهم‌ترین این چالش‌ها و مسیرهای پژوهشی آینده بررسی می‌شوند.

۱-۶- نرمال‌سازی داده‌ها در مواجهه با تغییر توزیع

یکی از چالش‌های اساسی در پیش‌بینی سری‌های زمانی مالی، تغییر توزیع داده‌ها در طول زمان است. بازارهای مالی ماهیتاً ناپایدار هستند و توزیع آماری آن‌ها در طول زمان تغییر می‌کند. روش‌های نرمال‌سازی سنتی که بر اساس آماره‌های کل مجموعه داده محاسبه می‌شوند، در این شرایط ناکارآمد هستند. رویکردهای جدید مانند نرمال‌سازی معکوس نمونه‌ای (RevIN) با محاسبه میانگین و واریانس برای هر نمونه به‌طور جداگانه، این مشکل را تا حدی حل کرده‌اند و به مدل اجازه می‌دهند تا عملکرد پایدارتری در مواجهه با تغییرات توزیع ارائه دهند. [۱۴]

۶-۲- نشت اطلاعات و رعایت ترتیب زمانی

یکی از مهم‌ترین اصول در پیش‌بینی سری‌های زمانی، اطمینان از عدم نشت اطلاعات از آینده به گذشته است. نشت اطلاعات زمانی رخ می‌دهد که مدل در حین آموزش از داده‌هایی استفاده کند که در زمان واقعی در دسترس نبوده‌اند. در مدل‌های مبتنی بر ترانسفورم که به‌طور موازی کل دنباله را پردازش می‌کنند، استفاده از ماسک‌های علی ضروری است. همچنین، روش‌های تقسیم داده‌ها در سری‌های زمانی باید به‌گونه‌ای باشد که ترتیب زمانی رعایت شده و از روش‌هایی مانند اعتبارسنجی پیش‌رونده استفاده شود.

۶-۳- تفسیرپذیری مدل‌های پیچیده

مدل‌های عمیق با میلیون‌ها پارامتر، اغلب به‌عنوان جعبه‌های سیاه شناخته می‌شوند. در حوزه مالی که تصمیمات می‌توانند پیامدهای سنگینی داشته باشند، این موضوع یک محدودیت جدی محسوب می‌شود. پژوهشگران با روش‌هایی مانند تحلیل وزن‌های توجه در مدل‌های ترانسفورم و تکنیک‌های پس‌تفسیر مانند SHAP و LIME سعی در افزایش تفسیرپذیری این مدل‌ها دارند.

۶-۴- مدل‌های انتشاری و پیش‌بینی بازه‌ای

مدل‌های انتشاری که در سال‌های اخیر در حوزه تولید تصویر موفقیت‌های چشمگیری داشته‌اند، به‌تازگی وارد حوزه پیش‌بینی سری‌های زمانی نیز شده‌اند. این مدل‌ها با یادگیری توزیع داده‌ها، امکان پیش‌بینی بازه‌ای را فراهم می‌کنند که در حوزه مالی با عدم قطعیت بالا بسیار ارزشمند است. پژوهش‌های اولیه نشان داده‌اند که این مدل‌ها پتانسیل بالایی برای پیش‌بینی مالی دارند. [۱۵]

۶-۵- ترکیب مدل‌های زبانی بزرگ و سری‌های زمانی

پیشرفت‌های اخیر در حوزه مدل‌های زبانی بزرگ، افق‌های جدیدی را در پیش‌بینی سری‌های زمانی مالی گشوده است. رویکردهای جدید مانند Time-LLM با استفاده از پیکربندی مجدد مدل‌های زبانی بزرگ برای پردازش سری‌های زمانی، نشان داده‌اند که می‌توان از دانش زبانی و استدلالی این مدل‌ها برای بهبود پیش‌بینی‌های مالی بهره برد [۱۳]. همچنین، ترکیب داده‌های عددی سری‌های زمانی با داده‌های متنی مانند اخبار و گزارش‌های اقتصادی، می‌تواند دقت پیش‌بینی را به‌طور قابل توجهی افزایش دهد.

۶. نتیجه‌گیری

در این مقاله، به مرور جامع و نظام‌مند روش‌های یادگیری عمیق برای پیش‌بینی سری‌های زمانی مالی پرداخته شد. بررسی‌های انجام‌شده نشان می‌دهد که این حوزه در سال‌های اخیر با رشد چشمگیری همراه بوده و معماری‌های متنوع و نوآورانه‌ای برای مواجهه با چالش‌های خاص داده‌های مالی ارائه شده است. از شبکه‌های عصبی پیچشی که در استخراج ویژگی‌های محلی و الگوهای دوره‌ای مهارت دارند تا شبکه‌های عصبی بازگشتی با قابلیت مدل‌سازی وابستگی‌های زمانی طولانی‌مدت، و از شبکه‌های عصبی گراف که روابط بین دارایی‌ها را مدل‌سازی می‌کنند تا مدل‌های مبتنی بر ترانسفورم که انقلابی در پردازش دنباله‌های بلند ایجاد کرده‌اند، همگی نشان‌دهنده تنوع و غنای ابزارهای موجود برای پیش‌بینی مالی هستند.

یافته‌های این مرور نشان می‌دهد که مدل‌های ترکیبی که نقاط قوت معماری‌های مختلف را با یکدیگر تلفیق می‌کنند، عموماً عملکرد بهتری نسبت به مدل‌های تکی دارند. ترکیب شبکه‌های پیچشی و بازگشتی، استفاده از روش‌های تجزیه سیگنال پیش از ورود به شبکه عصبی، و ترکیب معماری‌های مبتنی بر توجه با شبکه‌های گراف، از جمله رویکردهای موفق

هستند که در سال‌های اخیر مورد توجه قرار گرفته‌اند. علاوه بر معماری مدل‌ها، انتخاب تابع خطای مناسب و سنجش‌های ارزیابی نیز نقش کلیدی در موفقیت مدل‌های پیش‌بینی دارند. استفاده از توابع خطای نامتقارن که عدم تقارن در اهمیت خطاهای بیش‌برآوردی و کم‌برآوردی را مدل‌سازی می‌کنند و همچنین سنجش‌های مبتنی بر سود که عملکرد واقعی استراتژی‌های سرمایه‌گذاری را اندازه‌گیری می‌کنند، از روندهای مهم در این حوزه هستند.

با این حال، چالش‌های متعددی همچنان پیش‌روی پژوهشگران این حوزه قرار دارد. نرمال‌سازی داده‌ها در مواجهه با تغییرات توزیع، جلوگیری از نشت اطلاعات، تفسیرپذیری مدل‌های پیچیده و مقابله با بیش‌برازش در شرایط داده‌های محدود، از جمله مهم‌ترین این چالش‌ها هستند. مسیرهای پژوهشی آینده شامل توسعه مدل‌های انتشاری برای پیش‌بینی بازه‌ای، ترکیب رگرسیون چندکی با معماری‌های ترانسفورم، استفاده از مدل‌های زبانی بزرگ برای تحلیل سری‌های زمانی مالی و بهره‌گیری از یادگیری انتقالی برای سازگاری با بازارهای مختلف است.

در نهایت، می‌توان گفت که پیش‌بینی مالی با رویکرد یادگیری عمیق، حوزه‌ای پویا و در حال تکامل است که با هر پیشرفت در معماری‌های شبکه‌های عصبی و روش‌های بهینه‌سازی، افق‌های جدیدی پیش‌روی پژوهشگران و فعالان بازارهای مالی می‌گشاید. با وجود چالش‌های متعدد، پتانسیل بالای این روش‌ها برای بهبود تصمیم‌گیری‌های سرمایه‌گذاری و مدیریت ریسک، تضمین‌کننده تداوم پژوهش‌های گسترده در این حوزه در سال‌های آینده خواهد بود.

۷. مراجع

- [1] Rajabi, M. and Khaloozadeh, H. (2023), "Novel approaches in modeling and forecasting financial markets: recent advances and future horizons," *Journal of Control*, 17(2), pp 149-163.
- [2] Zhang, C., Sjarif, N.N.A. and Ibrahim, R. (2024), "Deep learning models for price forecasting of financial time series: A review of recent advancements: 2020-2022," *WIREs Data Mining and Knowledge Discovery*, 14(1), e1519.
- [3] Tian, G.Y., Yang, Y. and Wen, S.P. (2025), "Time-series stock price forecasting based on neural networks: A comprehensive survey," *Artificial Intelligence Science and Engineering*, 1(4), pp 255-277.
- [4] Goltabar, S., Abounoori, E. and Habibnia, A. (2025), "Deep learning-based modeling for stock price prediction in Iran," *Financial Research Journal*, 28(2), pp 424-463.
- [5] Osoolian, M., Nikmaram, A. and Karimi, M. (2025), "Predicting index trend using hybrid neural networks with a focus on multi-scale temporal feature extraction in the Tehran Stock Exchange," *Financial Research Journal*, 27(1), pp 85-113.
- [6] Zhou, H., Zhang, S., Peng, J., Zhang, S., Li, J., Xiong, H. and Zhang, W. (2021), "Informer: Beyond efficient transformer for long sequence time-series forecasting," In *Proceedings of the AAAI Conference on Artificial Intelligence*, 35(12), pp 11106-11115.
- [7] Wu, H., Xu, J., Wang, J. and Long, M. (2021), "Autoformer: Decomposition transformers with auto-correlation for long-term series forecasting," *Advances in Neural Information Processing Systems*, 34, pp 22419-22430.

- [8] Zhou, T., Ma, Z., Wen, Q., Wang, X., Sun, L. and Jin, R. (2022), "FEDformer: Frequency enhanced decomposed transformer for long-term series forecasting," In International Conference on Machine Learning, pp 27268-27286.
- [9] Nie, Y., Nguyen, N.H., Sinthong, P. and Kalagnanam, J. (2022), "A time series is worth 64 words: Long-term forecasting with transformers," arXiv preprint arXiv:2211.14730.
- [10] Liu, Y., Hu, T., Zhang, H., Wu, H., Wang, S., Ma, L. and Long, M. (2023), "iTransformer: Inverted transformers are effective for time series forecasting," arXiv preprint arXiv:2310.06625.
- [11] Luo, D. and Wang, X. (2024), "ModernTCN: A modern pure convolution structure for general time series analysis," In The Twelfth International Conference on Learning Representations.
- [12] Wu, Z., Pan, S., Long, G., Jiang, J., Chang, X. and Zhang, C. (2020), "Connecting the dots: Multivariate time series forecasting with graph neural networks," In Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, pp 753-763.
- [13] Jin, M., Wang, S., Ma, L., Chu, Z., Zhang, J.Y., Shi, X., Chen, P.Y., Liang, Y., Li, Y.F., Pan, S. and Wen, Q. (2023), "Time-LLM: Time series forecasting by reprogramming large language models," arXiv preprint arXiv:2310.01728.
- [14] Kim, T., Kim, J., Tae, Y., Park, C., Choi, J.H. and Choo, J. (2021), "Reversible instance normalization for accurate time-series forecasting against distribution shift," In International Conference on Learning Representations.
- [15] Huang, H., Chen, M. and Qiao, X. (2023), "Generative learning for financial time series with irregular and scale-invariant patterns," In The Twelfth International Conference on Learning Representations.
- [16] Zhou, T., Niu, P., Sun, L. and Jin, R. (2023), "One fits all: Power general time series analysis by pretrained lm," Advances in Neural Information Processing Systems, 36, pp 43322-43355.
- [17] Li, A.W. and Bastos, G.S. (2020), "Stock market forecasting using deep learning and technical analysis: A systematic review," IEEE Access, 8, pp 185232-185242.
- [18] Sezer, O.B., Gudelek, M.U. and Ozbayoglu, A.M. (2020), "Financial time series forecasting with deep learning: A systematic literature review: 2005-2019," Applied Soft Computing, 90, 106181.
- [19] Jiang, W. (2021), "Applications of deep learning in stock market prediction: recent progress," Expert Systems with Applications, 184, 115537.
- [20] Long, W., Lu, Z. and Cui, L. (2019), "Deep learning-based feature engineering for stock price movement prediction," Knowledge-Based Systems, 164, pp 163-173.
- [21] Fischer, T. and Krauss, C. (2018), "Deep learning with long short-term memory networks for financial market predictions," European Journal of Operational Research, 270(2), pp 654-669.

- [22] Qiu, J., Wang, B. and Zhou, C. (2020), "Forecasting stock prices with long-short term memory neural network based on attention mechanism," PLoS ONE, 15(1), e0227222.
- [23] Baek, Y. and Kim, H.Y. (2018), "ModAugNet: A new forecasting framework for stock market index value with an overfitting prevention LSTM module and a prediction LSTM module," Expert Systems with Applications, 113, pp 457-480.
- [24] Yu, B., Yin, H. and Zhu, Z. (2018), "Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting," In Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence, pp 3634-3640.
- [25] Guo, S., Lin, Y., Feng, N., Song, C. and Wan, H. (2019), "Attention based spatial-temporal graph convolutional networks for traffic flow forecasting," In Proceedings of the AAAI Conference on Artificial Intelligence, 33(1), pp 922-929.