

پیش بینی مسیر طوفان های حاره ای با استفاده از مدل حافظه طولانی کوتاه-مدت، اندازه گیری تشابه خطوطسیر و اطلاعات زمینه ای

سحر فرمانی فرد^۱، علی اصغر آل شیخ^۲، محمد شریف^۳، دانیال علیزاده^۴

- ۱- دانشجوی کارشناسی ارشد سیستم اطلاعات مکانی، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی
- ۲- استاد گروه سیستم اطلاعات مکانی، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی
- ۳- استادیار گروه جغرافیا، دانشکده علوم انسانی، دانشگاه هرمزگان
- ۴- دانش آموخته کارشناسی ارشد سیستم اطلاعات مکانی، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی

تاریخ دریافت مقاله: ۱۴۰۰/۰۳/۰۹ تاریخ پذیرش مقاله: ۱۴۰۰/۰۸/۰۵

چکیده

طوفان حاره ای یک پدیده طبیعی و پیچیده است که وقوع آن جان و مال انسان ها را تهدید می کند. بنابراین پیش بینی دقیق مسیر حرکت طوفان برای کاهش خسارات اقتصادی و نجات جان انسان ها لازم است. هنگامی که طوفانی رخ می دهد اطلاعات زمینه ای مختلفی نظیر سرعت و شدت باد، فشار هوا، جهت طوفان، دمای سطح آب و غیره در تغییر مسیر حرکت طوفان اثرگذار است و در نظر گرفتن این اطلاعات در فرآیند پیش بینی مسیر طوفان، می تواند دقت پیش بینی مسیر را بهبود بخشد. پژوهشگران روش های مختلفی را برای پیش بینی مسیر حرکت طوفان ها به کار برده اند تا به بالاترین دقت در پیش بینی دست یابند. امروزه روش های یادگیری عمیق برای این منظور بسیار مورد توجه قرار گرفته است. در این پژوهش با اندازه گیری میزان شباهت خطوطسیر طوفان ها و در نظر گرفتن پارامترهای موقعیتی و اطلاعات زمینه ای نظیر سرعت باد و جهت طوفان، از روش حافظه طولانی کوتاه-مدت برای پیش بینی مسیر و مکان آینده طوفان های واقع در اقیانوس اطلس شمالی استفاده شده است. نتایج به دست آمده بهبود دقت پیش بینی نسبت به عدم در نظر گرفتن اطلاعات زمینه ای را برای بازه های زمانی ۳، ۶، ۹ و ۱۲ ساعت نشان می دهد. فاصله میان مسیر پیش بینی شده با مسیر واقعی در صورت در نظر گرفتن اطلاعات زمینه ای بین ۱٫۹ تا ۴٫۵ کیلومتر کاهش یافته است.

کلید واژه ها: پیش بینی خطسیر، اندازه گیری تشابه، اطلاعات زمینه ای، مدل حافظه طولانی کوتاه-مدت، طوفان های حاره ای.

* نویسنده مکاتبه کننده: بندرعباس، کیلومتر ۹ جاده میناب، دانشگاه هرمزگان، دانشکده علوم انسانی، گروه جغرافیا.

تلفن: ۰۷۶۳۳۷۱۱۰۰۰

۱- مقدمه

طوفان‌ها پدیده‌های طبیعی پیچیده‌ای هستند که با وزش باد شدید در اطراف یک منطقه کم‌فشار ایجاد می‌گردند [۱]. طوفان‌ها خسارات جانی و مالی بسیاری را به مناطق ساحلی وارد می‌کنند و تأثیر بسزایی در توسعه اجتماعی و اقتصادی دارند. به‌عنوان مثال در سال ۲۰۱۷، هشت طوفان در کشور چین به وقوع پیوست و ۵/۸۷۹ میلیون نفر را تحت تأثیر قرار داد و ۵ میلیارد دلار خسارت وارد کرد [۲]. همچنین در سال ۱۹۶۵ طوفان بتسی ۱/۵ میلیارد دلار خسارت مالی به ایالت فلوریدا وارد کرد [۱]. با پیش‌بینی مسیر حرکت یک طوفان دولت‌ها و مردم آمادگی بیشتری جهت مقابله با این پدیده هولناک خواهند داشت و به همین علت پیش‌بینی دقیق مسیر یک طوفان از اهمیت بالایی برخوردار است.

عوامل بسیاری بر روی شکل‌گیری یک طوفان مؤثرند، از جمله این عوامل می‌توان به محیط هوشناسی (شامل فشار هوا، دمای هوا، جهت و سرعت باد، رطوبت، بارندگی و حرکت ابرها) و ترمودینامیک طوفان‌های حاره‌ای اشاره کرد. علاوه بر این، عوامل زیادی نیز بر مسیر آن تأثیر گذارند، مانند نیروی انحراف ژئوستروفیک^۱، فشار منطقه، جبهه هوای سرد حاکم بر منطقه و توپوگرافی [۳]. یک طوفان با توجه به شرایط محیطی می‌تواند به‌سرعت تغییر مسیر داده و برای مناطق پرجمعیت ساحلی خطر بزرگی ایجاد کند [۴]. بنابراین، با توجه به تأثیر طوفان‌ها بر انسان و پیچیدگی پیش‌بینی آن‌ها، توسعه روش‌های نوین پیش‌بینی طوفان‌ها از اهمیت زیادی برخوردار است. از روش‌های قدیمی در پیش‌بینی مسیر طوفان‌ها، مدل‌های پیش‌بینی عددی و مدل‌های پیش‌بینی آماری را می‌توان نام برد [۵]. از طرف دیگر حجم داده‌های طوفان‌ها به علت وجود ایستگاه‌های رصد اقیانوسی،

زمینی و ماهواره‌ای هواشناسی بسیار بالا است و نیازمند روشی است که بتواند داده‌های با حجم زیاد مانند داده‌های طوفان‌ها را پردازش کند. مدل‌های پیش‌بینی عددی از مدل‌های مورد توجه پژوهشگران در گذشته است؛ باین حال دارای پیچیدگی در محاسبات و دقت کم در پیش‌بینی است. همچنین تغییر پذیری طوفان‌ها در مقیاس‌ها، ارتفاعات و زمان‌های مختلف منجر به مشکلاتی در مدل‌سازی می‌گردد [۴].

علاوه بر مسائل ذکر شده در بالا، پژوهشگران همواره به دنبال دستیابی به روشی بودند که بتواند مدت‌زمان پیش‌بینی را افزایش دهند. مدت‌زمانی که دولت و شهروندان قبل از وقوع طوفان برای تخلیه شهرها در اختیار دارند، بسیار حائز اهمیت است و افزایش این مدت‌زمان منجر به پیش‌گیری از فجایع زیان‌بار و کاهش خسارات مالی و جانی می‌گردد. در پژوهش‌های اخیر، مدت‌زمان پیش‌بینی حرکت طوفان بین ۳ ساعت تا ۷۲ ساعت متغیر بوده است [۶ و ۷]. بنابراین برای پیش‌بینی مسیر طوفان‌ها نیازمند روشی هستیم که به‌خوبی قادر به پردازش داده با حجم بالا بوده و با پیچیدگی این نوع داده دچار اختلال یا کاهش دقت در خروجی نشود.

یکی از نقایصی که در پژوهش‌های پیش‌بینی مسیر، به‌ویژه در مورد طوفان‌ها، وجود دارد عدم در نظر گرفتن اطلاعات زمینه‌ای به‌عنوان عامل مؤثر در پیش‌بینی مسیر طوفان‌ها است [۸]. منظور از اطلاعات زمینه‌ای "آن بخش از موقعیت یا داده که بر حرکت تأثیر می‌گذارد یا از حرکت تأثیر می‌پذیرد" [۹] است. در پژوهش‌های اخیر، اطلاعات زمینه‌ای موجود در پایگاه داده طوفان‌ها نظیر سرعت باد، فشار هوا [۱۰]، شدت باد [۷]، جهت طوفان [۲] و دمای سطح آب [۱۱] تأثیر قابل‌توجهی در بهبود دقت پیش‌بینی را نشان می‌دهند. در این پژوهش در هر نقطه مکانی از مسیر طوفان اطلاعات زمینه‌ای همچون، سرعت باد و جهت طوفان مشخص و در دسترس است.

روش‌های مختلفی برای اندازه‌گیری میزان شباهت میان

^۱Geostrophic Deflection Force

بخش ۴ پیاده‌سازی و نتایج بیان می‌گردند. در بخش ۵ به بحث و تفسیر نتایج پرداخته می‌شود. در نهایت در بخش ۶ نتیجه‌گیری و پیشنهادات آتی ارائه می‌گردند.

۲- پیشینه پژوهش

مدل‌های پیش‌بینی خط‌سیر برای کاربردهای مختلفی نظیر حمل‌ونقل (کشتی، هواپیما و خودرو)، زیست‌شناسی (حیوانات) و پدیده‌های طبیعی (طوفان) توسعه داده شده‌اند. این مدل‌ها را می‌توان به دو دسته مدل محور^۵ و داده‌محور^۶ طبقه‌بندی نمود. کیانو و همکاران (۲۰۱۵)، با رویکردی مدل‌محور برای پیش‌بینی مسیر، مدل پیش‌بینی مسیر ترکیبی^۷ (*GMTP*) را ارائه کردند. آن‌ها توزیع احتمال انواع مختلف الگوهای حرکت را محاسبه و مسیرهای ممکن حاصل از مسیر ورودی توسط رگرسیون فرآیند گوسی را تعیین کردند. نتایج این تحقیق نشانگر بهبود دقت در مدل *GMTP* نسبت به رگرسیون فرآیند گوسی و فیلتر کالمن^۸ است [۱۴]. رویکرد مدل‌محور برای هر مسیر نیاز به ساخت یک مدل ریاضی دارد، بنابراین برای محیط‌های پویا چندان مناسب نیستند [۱۵].

با توجه به ماهیت پویای داده‌های طوفان‌ها، رویکردهای داده‌محور در پیش‌بینی مسیر طوفان‌ها کارآمدتر بوده و محققان با رویکردهای داده‌محور دستاوردهای مهمی در زمینه پیش‌بینی مسیر به دست آوردند. کوردمحل و همکاران (۲۰۱۶) برای پیش‌بینی طوفان‌های اقیانوس اطلس یک شبکه عصبی بازگشتی پراکنده^۹ را با رویکردی داده‌محور پیشنهاد کردند. این روش بسیار انعطاف‌پذیر و مناسب داده‌های طوفان است به طوری که در تعداد نرون‌ها و ارتباط آن‌ها و همچنین تعداد اطلاعات زمینه‌ای هیچ محدودیتی وجود ندارد [۱۶]. در پژوهشی دیگر چن و همکاران (۲۰۱۸) به بررسی

دو مسیر بر اساس سری‌های زمانی وجود دارد، مانند فاصله اقلیدسی، فاصله ویرایش^۱، طولانی‌ترین دنباله مشترک^۲ و روش پیچش زمانی پویا^۳ (*DTW*) [۱۲] که هر کدام دارای مزایا و معایب خاص خود هستند [۱۳]. در این پژوهش از روش *DTW*، که از جمله توابع قدرتمند در اندازه‌گیری تشابه خطوط‌سیر با اندازه‌های غیریکسان است، استفاده می‌شود تا میزان شباهت طوفان‌ها محاسبه گردد. سپس طوفانی که بیشترین شباهت را به طوفان هدف دارد استخراج و فاصله میان آن‌ها به‌عنوان ورودی به مدل حافظه طولانی کوتاه-مدت^۴ (*LSTM*)، که از مدل‌های کارآمد یادگیری عمیق در زمینه پیش‌بینی طوفان‌ها است، وارد شود. مدل‌های یادگیری عمیق برای پردازش داده‌های با حجم بالا و پیچیده و زمان‌دار مانند داده‌های طوفان بسیار کارآمد هستند [۲].

هدف پژوهش استفاده از اطلاعات زمینه‌ای در کنار موقعیت مکانی برای پیش‌بینی مسیر طوفان‌های حاره‌ای است. بدین منظور از یک مدل ترکیبی مبتنی بر اندازه‌گیری تشابه خطوط‌سیر و یادگیری عمیق استفاده می‌شود. در این راستا، مشارکت این پژوهش در بکارگیری اطلاعات زمینه‌ای مؤثر در تغییر مسیر طوفان‌های حاره‌ای جهت افزایش دقت پیش‌بینی مدل و افزایش مدت زمان پیش‌بینی برای ۳، ۶، ۹ و ۱۲ ساعت آینده است.

ساختار مقاله در ادامه به این شرح است. در بخش ۲ به مروری بر پژوهش‌های انجام‌شده در زمینه پیش‌بینی مسیر پدیده‌هایی نظیر طوفان‌ها و بیان مدل‌ها و اطلاعات زمینه‌ای مورد استفاده، پرداخته می‌شود. در بخش ۳ روش انجام پژوهش ارائه می‌شود و مفاهیم بنیادی لازم شرح می‌گردد. همچنین شرح آموزش و شیوه ارزیابی مدل نیز در این فصل انجام می‌پذیرد. در

¹Model-driven

²Data-driven

³Gaussian Mixture Trajectory Prediction

⁴Kalman Filter

⁵Sparse Recurrent Neural Network

²Edit Distance

³Longest Common Subsequence

⁴Dynamic Time Warping

⁵Long Short-Term Memory

سازگارند، پژوهشگران بسیاری در تلاش هستند تا از ترکیب یادگیری عمیق با سایر مدل‌ها به نتایج بهتری دست یابند. برای مثال، علیزاده و همکاران (۲۰۲۱)، روش جستجوی شباهت پیچش زمانی پویا و مدل LSTM را برای پیش‌بینی مسیر کشتی‌ها پیشنهاد کرده‌اند. نتایج نشان‌دهنده کارایی موثر روش‌های ترکیبی در مقایسه با روش‌های دیگر است [۱۸].

علاوه بر این، در سال‌های اخیر پژوهشگران با ترکیب مدل‌های یادگیری عمیق به دقت بهتری در مقایسه با استفاده از یک روش دست‌یافته‌اند. ونگ و همکاران (۲۰۱۹)، به مقایسه مقدار خطای میانگین مطلق پنج مدل مبتنی بر آمار و ده مدل مبتنی بر یادگیری عمیق پرداختند و یک مدل نوآورانه، که ترکیبی از مدل‌های یادگیری عمیق است را ارائه کردند. نتایج آنان نشان داد که مقدار خطای میانگین مطلق در مدل‌های مبتنی بر یادگیری عمیق در مقایسه با مدل‌های مبتنی بر آمار برای پیش‌بینی مسیر کمتر است. مدل پیش‌بینی پژوهشگران یک مدل پویا از ترکیب روش پرسپترون چندلایه^۸ و LSTM است که این ترکیب منجر به کاهش خطای پیش‌بینی گردیده است. این پژوهش بر روی پیش‌بینی مسیر حمل‌ونقل عمومی متمرکز است [۱۹]. همان‌طور که در مقدمه به آن اشاره شد، مسیر حرکت طوفان‌های حاره‌ای تحت تأثیر اطلاعات زمینه‌ای مختلفی مانند سرعت و جهت باد، فشار هوا، جهت طوفان و دمای سطح آب تغییر می‌کند. شناخت عوامل مؤثر و سنجش میزان تأثیر آن‌ها بر مسیر حرکت طوفان‌ها در بسیاری از پژوهش‌ها مورد توجه قرار گرفته است. ژنگ و همکاران (۲۰۱۸)، عامل شدت باد را جهت پیش‌بینی دقیق‌تر مسیر در نظر گرفته‌اند [۱۱]. همچنین لیان و همکاران (۲۰۲۰) به این نتیجه رسیدند که در نظر گرفتن اطلاعات زمینه‌ای همچون سرعت باد و فشار مرکزی منجر به بهبود دقت می‌گردد [۱۷]. اطلاعات زمینه‌ای همچون حداقل فشار سطح دریا،

مدل شبکه عصبی بازگشتی^۱ در پیش‌بینی پدیده‌های دارای سری زمانی و پیچیده پرداخته‌اند. در این پژوهش به عملکرد خوب این مدل در پیش‌بینی برای داده‌های محیطی مانند طوفان‌ها اشاره شده است [۱۷]. از دیگر مدل‌های مورد استفاده برای پیش‌بینی مسیر طوفان‌ها، که توسط ژنگ و همکاران (۲۰۱۸)، در پژوهشی مورد بررسی قرار گرفته است، مدل شبکه عصبی ماتریسی^۲ است. این روش با داده‌های نامنظمی همچون داده‌های طوفان‌ها بسیار سازگار است و در مقایسه با روش‌های قبلی مؤثرتر عمل می‌کند [۱۱]. المانی و همکاران (۲۰۱۹)، برای پیش‌بینی طوفان‌های اقیانوس اطلس، ترکیبی از شبکه عصبی بازگشتی و مدل‌های مبتنی بر شبکه^۳ را پیشنهاد کردند. ترکیب این دو روش برای مدل‌سازی روابط پیچیده غیرخطی زمانی کارآمد است [۱].

در برخی از پژوهش‌ها از تصاویر ماهواره‌ای به‌عنوان ورودی برای پیش‌بینی مسیر طوفان‌ها استفاده شده است [۴ و ۶]. روتگرز و همکاران (۲۰۱۹)، یکی دیگر از روش‌های یادگیری عمیق تحت عنوان شبکه‌های مولد تخصصی^۴ را مورد بررسی قرار دادند [۴]. کیم و همکاران (۲۰۱۹) نیز مدلی مبتنی بر رگرسیون با استفاده از روش LSTM پیچشی^۵ را برای تشخیص و ردیابی طوفان‌ها در تصاویر ماهواره‌ای مورد استفاده و ارزیابی قرار دادند. آن‌ها برای پیش‌بینی طوفان‌ها ساختار رمزگذاری^۶ با به کار بردن معماری توالی به توالی^۷ با استفاده از مدل LSTM پیچشی را پیشنهاد کردند [۶].

با توجه به اینکه روش‌های یادگیری عمیق با ماهیت داده‌های زمانی و پیچیده و نامنظم طوفان‌ها بسیار

^۶Recurrent Neural Network

^۷Matrix Neural Network

^۸Grid-based Models

^۱Generative Adversarial Network

^۲Convolutional LSTM

^۳Encoding

^۴Sequence-to-Sequence

^۵Multi-Layer Perception (MLP)

۳-۱- مدل پیش‌بینی جستجوی شباهت خطوط‌سیر با استفاده از حافظه طولانی کوتاه-مدت^۱ (TSSPL)

در این پژوهش، در مرحله اول داده‌ها پیش‌پردازش می‌شوند، به این صورت که طوفان‌هایی با نقاط نمونه و یا اطلاعات زمینه‌ای ناقص از پایگاه داده حذف می‌شوند. سپس پیش‌بینی جستجوی شباهت خطوط‌سیر با استفاده از مدل TSSPL انجام می‌گردد [۱۸]. در این مدل برای یافتن بیشترین شباهت طوفان‌های حاره‌ای از نظر مکان، سرعت باد و جهت طوفان، از تابع DTW استفاده می‌شود. خروجی DTW به‌عنوان ورودی به مدل LSTM وارد شده و درنهایت میزان صحت پیش‌بینی در مقایسه با حالتی که اطلاعات زمینه‌ای در نظر گرفته نشده بررسی می‌گردد.

۳-۱-۱- پیش‌بینی زمانی پویا (DTW)

زمانی که خطوط‌سیر با اندازه و نقاط نمونه متفاوتی وجود داشته باشند، یکی از بهترین انتخاب‌ها برای جستجوی شباهت آن‌ها، استفاده از روش DTW است [۲۱]. در DTW هر نمونه از خط‌سیر با نمونه‌های خطوط‌سیر دیگر مورد مقایسه قرار گرفته و درنهایت داده‌هایی استفاده می‌شود که دارای کمترین فاصله با داده موردنظر باشد. به‌عبارت‌دیگر، DTW بر پایه شیفت منعطف بردار زمان است، بدین معنی که نقاط دو خط‌سیر را به‌گونه‌ای در راستای محور زمان جابه‌جا می‌کند تا مجموع فواصل میان نقاط متناظر کمینه شود (شکل (۱)) [۲۲ و ۲۳]. به همین دلیل زمان جز اصلی بررسی این روش نیست [۱۳ و ۱۸]. از اینرو، از DTW می‌توان برای یافتن شباهت میان مسیرهایی با طول‌های نامساوی، مانند خطوط‌سیر طوفان‌های حاره‌ای، استفاده کرد.


سطح توسعه طوفان، سرعت باد، شدت باد، شعاع حداکثر باد، قطر چشم طوفان و جهت طوفان در پژوهشی دیگر توسط لیان و همکاران (۲۰۲۰) نیز تأثیر مثبتی بر پیش‌بینی مسیر نشان دادند [۲].

از دیگر مسائل مهم، مدت‌زمان پیش‌بینی است، که همان‌گونه که ذکر شد، برای حفظ جان و مال انسان‌ها بسیار حائز اهمیت است. مدت‌زمان پیش‌بینی در مسائل و پدیده‌ها متفاوت است. به‌عنوان مثال در پیش‌بینی مسیر کشتی‌ها، مدت‌زمان ۴۰ دقیقه مدت‌زمان مناسب و قابل قبولی است اما در مورد پدیده طوفان و پیش‌بینی مسیر آن حداقل زمان ممکن ۳ ساعت است چراکه کمتر از آن عملاً برای مدیریت بحران کارایی کافی را ندارد. ونگ و همکاران (۲۰۲۰) یک مدل یادگیری برخط را برای پیش‌بینی طوفان در زمان‌های ۱۲، ۲۴، ۳۶ و ۴۸ ساعته مورد بررسی قرار داده‌اند. نتایج این پژوهش برای هشدار سریع امیدوارکننده است. بااین‌حال در اکثر پژوهش‌ها مدت‌زمان پیش‌بینی ۶ ساعت بوده است [۲۰].

با توجه به موارد فوق، مدل‌های ترکیبی بر پایه یادگیری عمیق در مطالعات مربوط به پیش‌بینی مسیر کارآمدتر عمل کرده‌اند. اما از اطلاعات زمینه‌ای موثر در پیش‌بینی حرکت طوفان‌های حاره‌ای در این مدل‌ها کمتر استفاده شده است. موضوع دیگر مدت‌زمان پیش‌بینی است، که عمده پژوهش‌ها تا ۶ ساعت به پیش‌بینی طوفان‌های حاره‌ای پرداخته‌اند. بنابراین در این پژوهش با بهره‌گیری از اطلاعات زمینه‌ای سرعت باد و جهت طوفان در یک مدل ترکیبی پیش‌بینی، میزان تأثیر این اطلاعات بر صحت نتایج پیش‌بینی تا ۱۲ ساعت قبل از وقوع طوفان سنجیده می‌شود.

۳- روش انجام پژوهش

این بخش به بیان مفاهیم اولیه در این پژوهش و روش انجام پژوهش اختصاص دارد. در مدل مورد استفاده از جستجوی شباهت برای پیش‌بینی مسیر طوفان استفاده می‌گردد.



شکل ۱: سازوکار DTW [۱۸]

بدون در نظر گرفتن اطلاعات زمینه‌ای، شبیه‌ترین مسیر به مسیر هدف به دست می‌آید؛ بنابراین وزن اطلاعات زمینه‌ای (W_v و W_d) صفر خواهند بود. در حالت دوم موقعیت مکانی و اطلاعات زمینه‌ای، وزن برابر دارند. مقدار هر سه وزن W_s ، W_d و W_v برابر با ۰/۳۳ در نظر گرفته شده است. در حالت سوم وزن موقعیت مکانی بیشتر از اطلاعات زمینه‌ای است. وزن موقعیت مکانی (W_s) برابر با ۰/۵ و وزن‌های اطلاعات زمینه‌ای (W_v و W_d) برابر با ۰/۲۵ در نظر گرفته شده‌اند.

۳-۱-۳- حافظه طولانی کوتاه-مدت (LSTM)

مدل LSTM نوع خاصی از شبکه‌های عصبی بازگشتی است. رابطه اصلی در شبکه‌های بازگشتی در رابطه (۲) نشان داده شده است.

$$h_t = fw(h_{t-1}, x_t) \quad \text{رابطه (۲)}$$

در رابطه (۲)، h_t نمایانگر حالت جدید، x_t ورودی جدید و f یک تابع فعال‌سازی با پارامترهای W است. شبکه عصبی بازگشتی حالت قبلی را که با h_{t-1} نشان داده شده را در نظر می‌گیرد. این خصیصه شبکه عصبی بازگشتی را کارآمدتر می‌کند [۱۸]. مدل LSTM با تهیه یک حافظه ذخیره‌سازی و مدیریت سازوکار قادر است ورودی‌ها و حالت‌های قبلی را برای مدت طولانی ذخیره کند [۲۴]. رابطه اصلی در مدل LSTM توسط

۳-۱-۲- اندازه‌گیری شباهت خطوط مسیر مکانی با

در نظر گرفتن اطلاعات زمینه‌ای

در بررسی میزان شباهت میان طوفان‌های حاره‌ای، علاوه بر موقعیت مکانی، اطلاعات زمینه‌ای مؤثر سرعت باد و جهت طوفان نیز در نظر گرفته می‌شوند. میزان شباهت خطوط مسیر از نظر مکانی، سرعت باد و جهت طوفان به صورت جداگانه با استفاده از تابع DTW محاسبه می‌گردد. سپس با استفاده از ترکیب وزن‌دار (رابطه (۱))، شبیه‌ترین خط‌سیر به خط‌سیر مربوط به طوفان هدف از لحاظ معیارهای فوق از درون پایگاه داده استخراج می‌گردد.

رابطه (۱)

$$D_{SM} = W_s \times D_{ns} + W_v \times D_{nv} + W_d \times D_{nd}$$

در رابطه (۱)، D_{SM} بیانگر میزان فاصله بین نقطه هدف و نقاط درون پایگاه داده از لحاظ معیارهای مکانی، سرعت باد و جهت طوفان می‌باشد. هرچه مقدار آن کمتر باشد نشان‌دهنده شباهت بیشتر نقطه درون پایگاه داده با نقطه هدف از نظر معیارهای فوق است. متغیرهای D_{nv} و D_{ns} ، D_{nd} به ترتیب فواصل جهت، مکان و سرعت نرمال شده می‌باشند و همچنین W_s ، W_d و W_v به ترتیب وزن‌های مربوط به این توابع می‌باشند.

در ادامه جستجوی شباهت در سه حالت بررسی می‌شود. حالت اول با در نظر گرفتن موقعیت مکانی و


روابط (۳) و (۴) معرفی شده است.
 رابطه (۳)

$$h_t = f_{act}(c_t) \cdot o_t$$

 رابطه (۴)

$$c_t = f_t \cdot c_{t-1} + i_t \cdot f_{act}(W_x \cdot x_t + W_h \cdot h_{t-1} + b)$$

 در روابط (۳) و (۴)، f_{act} ، i_t ، o_t ، f_t ، W_h و W_x به ترتیب دریچه فراموش‌شده (*Forget gate*)، دریچه خروجی، مقدار دریچه، تابع فعال‌سازی، ورودی مخفی و ماتریس وزن لایه مخفی هستند. در شکل (۲) ساختار مدل LSTM آورده شده است که در آن h_0 ، h_1 ، h_2 ، h_3 و x_0 ، x_1 ، x_2 ، x_3 به ترتیب وضعیت پنهان و ورودی را نشان می‌دهد. در آخرین مرحله از این ساختار، آخرین وضعیت پنهان برای رسیدن به خروجی از تابع سیگموئید عبور می‌کند. ممکن است خروجی یکی از لایه‌های LSTM دارای مقدار بیشتری باشد. وقتی این خروجی به لایه‌های بعدی وارد شود، احتمال افزایش مجدد این مقدار وجود دارد که مدل را از نظر محاسباتی غیرقابل کنترل می‌کند. این مسئله با کمک تابع سیگموئید با جمع یک مقدار واقعی در یک بازه ثابت (بین ۰ تا ۱) حل می‌شود.



شکل ۲: ساختار مدل LSTM [۲۴]


همانگونه که پیش‌تر شرح داده شد، فاصله میان چهار نقطه آخر و نقاط متناظرشان به‌عنوان ورودی به مدل LSTM وارد می‌شود. فاصله مکانی پیش‌بینی‌شده توسط مدل LSTM توسط رابطه (۵) برای پیش‌بینی مکان بعدی در هر بازه زمانی به کار می‌رود.
 رابطه (۵)

$$Lon_{TP_{12}} = \Delta Longitude - Lon_{SP_{12}}$$


$$Lat_{TP_{12}} = \Delta Latitude - Lat_{SP_{12}}$$

 در این مدل، فاصله میان مسیر هدف و شبیه‌ترین مسیر به آن ثابت نیست، بنابراین از روش DTW برای پیدا کردن شبیه‌ترین مسیر استفاده می‌شود. در شکل (۳) نمای کلی از مدل TSSPL برای مسیرهای واگرا و همگرا نشان داده شده است. خطوط آبی فواصل میان دو مسیر که دارای بیشترین میزان تشابه از نقطه نظر معیارهای ذکر شده هستند و خطوط آبی خط‌چین شده فواصل پیش‌بینی‌شده توسط مدل LSTM را نشان

می‌دهند. پس از یافتن شبیه‌ترین مسیر به مسیر هدف در پایگاه داده توسط روش DTW، اختلاف طول و عرض جغرافیایی میان آخرین نقطه از مسیر هدف و شبیه‌ترین نقطه از شبیه‌ترین مسیر به آن محاسبه می‌گردد که با نقطه *now* نشان داده شده است. علاوه بر محاسبه این فواصل، فواصل میان طول و عرض جغرافیایی سه نقطه قبل از آخرین نقطه از مسیر هدف با سه نقطه متناظر آن‌ها در شبیه‌ترین مسیر نیز محاسبه می‌گردد. در نهایت این فواصل در یک ماتریس ۴ در ۲ که در رابطه (۶) آورده شده به LSTM وارد می‌شود. خروجی آن پیش‌بینی یک نقطه بعد از آخرین نقطه از مسیر هدف است. با آموزش مدل می‌توان چهار نقطه از مسیر هدف در مسیر هدف را که با فاصله زمانی ۳ ساعت از یکدیگر قرار دارند پیش‌بینی کرد.



(الف)




(ب)

شکل ۳: مدل TSSPL: الف) زمانی که دو مسیر واگرا هستند و ب) زمانی که دو مسیر همگرا هستند [۱۸]

از آموزش مدل، از نقطه پیش‌بینی شده به همراه سه نقطه قبل از آن برای پیش‌بینی نقطه دوم استفاده می‌شود. به این ترتیب همانطور که در شکل (۴) نشان داده شده است نقاط بعدی از مسیر هدف قابل پیش‌بینی خواهند بود. این فواصل محاسبه شده برای آموزش شبکه و تنظیم ماتریس وزن برای مقایسه میزان خطای بین مقدار پیش‌بینی شده و مقدار مورد انتظار به کار می‌رود (شکل (۴)).

۳-۲- آموزش و اجرا مدل LSTM

برای آموزش شبکه از داده‌های پیش‌پردازش شده استفاده می‌شود. شبیه‌ترین مسیر به هر مسیر از پایگاه داده استخراج شده، سپس فاصله مکانی بین هر جفت مسیر مشابه با یکدیگر محاسبه می‌گردد. با استفاده از فاصله مکانی میان آخرین نقطه از مسیر هدف و شبیه‌ترین نقطه از شبیه‌ترین مسیر به آن و همچنین فواصل مکانی سه نقطه قبل از آخرین نقطه از مسیر هدف و نقاط متناظر آن در شبیه‌ترین مسیر اولین نقطه پیش‌بینی شده از مسیر هدف به دست خواهد آمد. پس



شکل ۴: آماده‌سازی داده‌ها برای ورود به مدل LSTM [۱۸]

ارزیابی مدل به منظور افزایش قابلیت تعمیم^۱ مدل استفاده شده است. در ادامه، ارزیابی عملکرد مدل به کمک مجموعه داده ارزیابی صورت می‌پذیرد. در این پژوهش از دو معیار میانگین کمترین مربعات^۲ (MSE) و ضریب همبستگی (r -square)، به منظور بررسی کمی دقت مدل بهره برده شده است. دو معیار ذکر شده به ترتیب توسط روابط (۷) و (۸) محاسبه شده‌اند.

$$MSE = \frac{1}{n} \sum_{i=0}^n (y_i - \hat{y}_i)^2 \quad \text{رابطه (۷)}$$

$$R^2 = 1 - \frac{\sum_{i=0}^n (y_i - \hat{y}_i)^2}{\sum_{i=0}^n (y_i - \bar{y}_i)^2} \quad \text{رابطه (۸)}$$

در روابط (۷) و (۸)، y_i ، \hat{y}_i و \bar{y}_i به ترتیب نشان‌دهنده مقدار واقعی، مقدار پیش‌بینی شده و میانگین مقادیر واقعی می‌باشند.

۴- پیاده‌سازی و نتایج

در این بخش با استفاده از مدل $TSSPL$ مسیر طوفان برای ۳، ۶، ۹ و ۱۲ ساعت آینده پیش‌بینی می‌گردد. همچنین برای ارزیابی صحت نتایج از فاصله هورسین^۳

فواصل مکانی میان چهار نقطه آخر مسیر هدف با نقاط متناظرشان در شبیه‌ترین مسیر در یک ماتریس ۴ در ۲ جهت پیش‌بینی نقطه پنجم به عنوان ورودی مدل LSTM در رابطه (۶) آورده شده است.

رابطه (۶)

$$\begin{bmatrix} d_1 \\ d_2 \\ d_3 \\ d_4 \end{bmatrix} = \begin{bmatrix} (Lon_{S,1} - Lon_{T,1}) \cdot (Lat_{S,1} - Lat_{T,1}) \\ (Lon_{S,2} - Lon_{T,2}) \cdot (Lat_{S,2} - Lat_{T,2}) \\ (Lon_{S,3} - Lon_{T,3}) \cdot (Lat_{S,3} - Lat_{T,3}) \\ (Lon_{S,4} - Lon_{T,4}) \cdot (Lat_{S,4} - Lat_{T,4}) \end{bmatrix}$$

در رابطه (۶)، d_1 تا d_4 به ترتیب فواصل مکانی چهار نقطه از آخرین نقاط مسیر هدف با نقاط متناظرشان در شبیه‌ترین مسیر است. این فواصل مکانی شامل اختلاف طول جغرافیایی و اختلاف عرض جغرافیایی نقاط متناظر است.

۳-۳- ارزیابی مدل LSTM

جهت ارزیابی مدل LSTM، در ابتدا داده‌ها اصلی به دو قسمت مجموعه داده آموزشی اولیه و مجموعه داده ارزیابی به نسبت‌های هشت به دو تقسیم خواهند شد. در ادامه مجموعه داده آموزشی اولیه مجدداً به دو قسمت به نام‌های مجموعه داده آموزشی و مجموعه داده اعتبارسنجی به نسبت هفت به سه تقسیم شده است [۱۸]. از مجموعه داده‌های اعتبارسنجی جهت

^۱ Generalization Ability

^۲ Mean Square Error


^۳ Haversine

مسیر، ۲۵۱۷۵ داده موقعیت مکانی را شامل می‌شوند که هر موقعیت مکانی از مسیر طوفان شامل داده‌هایی همچون عرض جغرافیایی، طول جغرافیایی، سرعت باد و جهت طوفان است. فاصله زمانی میان نقاط ۳ ساعت بوده و تمامی داده‌ها از پایگاه داده NOAA (<http://www.nhc.noaa.gov>) جمع‌آوری شده است. شکل (۵) منطقه مورد مطالعه و تراکم بالای طوفان‌ها در سال‌های ۱۹۹۴ تا ۲۰۱۹ را نشان می‌دهد.

بین نقاطی از مسیر که توسط مدل پیش‌بینی شده و مقادیر واقعی آن‌ها استفاده می‌گردد.

۴-۱- منطقه مورد مطالعه

مورد مطالعاتی در این پژوهش، خطوط سیر مربوط به ۴۲۶ طوفان اقیانوس اطلس شمالی که در سال‌های ۱۹۹۴ تا ۲۰۱۹ به وقوع پیوسته‌اند، است. منطقه مورد مطالعه در عرض جغرافیایی صفر درجه شمالی تا ۵۰ درجه شمالی و طول جغرافیایی ۹۰ درجه غربی تا صفر درجه غربی قرار گرفته است. در مجموع این ۴۲۶



شکل ۵: منطقه مورد مطالعه به همراه خطوط سیر طوفان‌ها

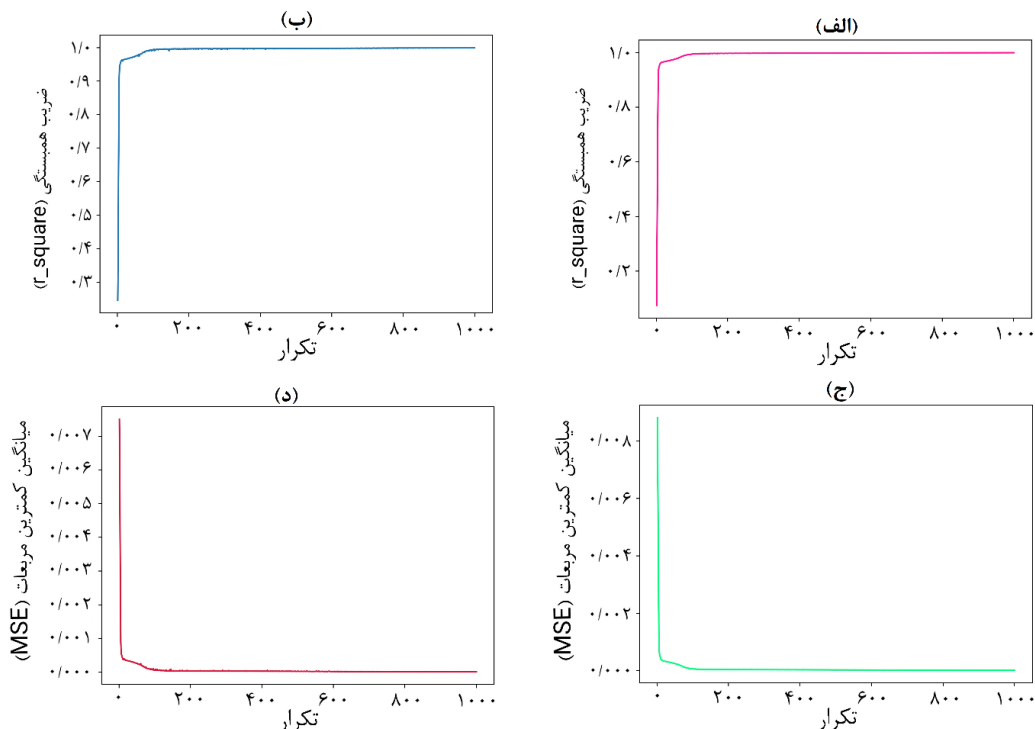
(Epoch)، در شکل (۶) نشان داده شده است. در اشکال، محور قائم نمودارهای ردیف اول و دوم به ترتیب بیانگر معیار ضریب همبستگی و کمترین مربعات هستند. در همین راستا، محور افقی در این نمودارها تعداد تکرار را نشان می‌دهد.

۴-۲- نتایج پیش‌بینی

در جدول (۱) نتایج کمی حاصل از عملکرد مدل آموزش دیده شده بر روی مجموعه داده‌های آموزشی، ارزیابی و اعتبارسنجی آورده شده است. نحوه تغییر مقادیر دو معیار ذکر شده، در طول ۱۰۰۰ تکرار

جدول ۱: ارزیابی عملکرد مدل LSTM

میانگین کمترین مربعات (MSE)	ضریب همبستگی (R^2)	مجموعه داده‌ها
$7.6678e-06$	۰.۹۹۹۳	آموزشی
$7.7696e-06$	۰.۹۹۹۲	ارزیابی
$7.6677e-06$	۰.۹۹۹۱	تست



شکل ۶: ارزیابی کمی مدل LSTM: (الف) مقادیر ضریب همبستگی بر روی مجموعه داده آموزشی؛ (ب) مقادیر ضریب همبستگی بر روی مجموعه داده اعتبارسنجی؛ (ج) مقادیر میانگین کمترین مربعات بر روی مجموعه داده آموزشی؛ (د) مقادیر میانگین کمترین مربعات بر روی مجموعه داده اعتبارسنجی

۳-۴- نقش اطلاعات زمینه‌ای در پیش‌بینی

در فضای کروی فاصله میان دو نقطه با مقدار واقعی و پیش‌بینی شده توسط رابطه (۹) و تحت عنوان رابطه هورسین معرفی می‌شود. در رابطه (۹)، r بیان‌گر شعاع زمین است که مقدار ۶۳۷۱ کیلومتر در نظر گرفته شده است. d_d نشان‌دهنده فاصله هورسین محاسبه شده بین دو نقطه مورد نظر است. $Latitude_1$ و $Latitude_2$ به ترتیب عرض جغرافیایی نقطه اول و دوم و $\Delta Longitude$ و $\Delta Latitude$ به ترتیب اختلاف عرض و طول جغرافیایی دو نقطه هستند. این فاصله اندازه‌گیری شده و مقدار آن برای حالتی که اطلاعات

زمینه‌ای همچون سرعت باد و جهت طوفان در نظر گرفته شده، در مقایسه با عدم در نظر گرفتن اطلاعات زمینه‌ای در مدت‌زمان پیش‌بینی ۳، ۶، ۹ و ۱۲ ساعت در جدول (۲) آورده شده است. در این پژوهش اطلاعات زمینه‌ای را با وزن‌های مختلف توسط رابطه (۴) اعمال کرده، به طوری که یکبار اندازه‌گیری میزان شباهت صرفاً بر اساس معیار مکانی است (قسمت الف) در جدول (۲) و بار دیگر علاوه بر معیار مکانی، معیارهای سرعت باد و جهت طوفان در دو حالت با وزن‌های مختلف در نظر گرفته شد (قسمت ب) و (ج) در جدول (۲) و نتایج در جدول (۲) باهم مقایسه شد.

$$d_d = 2r \times \sin^{-1} \left(\left(\sin^2 \left(\frac{\Delta Latitude}{2} \right) + \cos(Latitude_1) \cdot \cos(Latitude_2) \cdot \sin^2 \left(\frac{\Delta Longitude}{2} \right) \right)^{1/2} \right) \quad \text{رابطه (۹)}$$

جدول ۲: مقایسه صحت پیش‌بینی مکان با استفاده از مدل *TSSPL* (برحسب کیلومتر) برای مدت زمان‌های مختلف برای حالت‌های در نظر گرفتن یا عدم در نظر گرفتن اطلاعات زمینه‌ای با وزن‌های مختلف، الف) عدم در نظر گرفتن اطلاعات زمینه‌ای، ب) در نظر گرفتن اطلاعات زمینه‌ای با وزن‌های برابر (وزن هر کدام از معیارها ۰٫۳۳)، ج) در نظر گرفتن اطلاعات زمینه‌ای با وزن‌های موقعیت مکانی ۰٫۵، سرعت باد ۰٫۲۵ و جهت طوفان ۰٫۲۵.

آزمون	۳ ساعت	۶ ساعت	۹ ساعت	۱۲ ساعت
الف	۲۷,۳۷۱	۶۵,۸۷۰	۱۱۶,۱۲۹	۱۷۶,۷۶۸
ب	۲۲,۴۰۶	۶۱,۸۴۰	۱۲۰,۲۲۸	۱۹۲,۳۴۰
ج	۲۳,۶۲۷	۶۱,۳۱۷	۱۱۲,۸۹۱	۱۷۴,۸۴۱

شده است. همان‌طور که در جدول (۲) نشان داده شده است، صحت پیش‌بینی با افزایش مدت‌زمان پیش‌بینی کاهش می‌یابد؛ که این امر به سبب این است که در این مدل، فواصل مکانی به کمک فواصل مکانی پیش‌بینی شده قبلی حاصل از مدل *LSTM*، به دست می‌آیند. بنابراین خطای فاصله مکانی پیش‌بینی شده در هر زمان بر خطای فاصله مکانی پیش‌بینی شده در زمان بعدی تأثیر می‌گذارد. مدل بکارگرفته‌شده در این پژوهش در مقایسه با پژوهش‌های مشابه، عملکرد بهتری را در صحت نتایج نشان می‌دهد. همچنین نزدیکی مقادیر خطای کمترین مربعات (*MSE*) میان داده‌های آموزشی، اعتبارسنجی و تست که در جدول (۱) آورده شده است، نشانگر این است که مدل *LSTM* به خوبی آموزش داده شده است. خطای کمترین مربعات مربوط به داده‌های تست بسیار به صفر نزدیک است که این خود حاکی از عملکرد مناسب مدل برای پیش‌بینی داده‌های جدید است.

از دیگر اهداف این پژوهش بررسی تأثیر اطلاعات زمینه‌ای بر روی صحت نتایج بود. همان‌طور که در جدول (۲) به آن اشاره شده است، اطلاعات زمینه‌ای با وزن‌های مختلف قادر به بهبود صحت نتایج هستند. با اعمال وزن‌های برابر به اطلاعات مکانی و سرعت باد و جهت طوفان تا مدت زمان ۶ ساعت، صحت نتایج نسبت به عدم در نظر گرفتن اطلاعات زمینه‌ای بهبود می‌یابد. اما در مدت زمان ۹ و ۱۲ ساعت از صحت نتایج کاسته می‌شود. در واقع تأثیر اطلاعات زمینه‌ای در

نتایج نشان می‌دهند که وجود اطلاعات عوامل زمینه‌ای مانند سرعت باد و جهت طوفان منجر به کاهش فاصله میان مسیر طوفان پیش‌بینی شده و مسیر طوفان واقعی در مدت‌زمان ۳ ساعت تا ۳,۷۴۴ کیلومتر در ۶ ساعت تا ۴,۵۵۳ کیلومتر در ۹ ساعت تا ۳,۲۳۸ کیلومتر و در ۱۲ ساعت ۱,۹۲۷ کیلومتر می‌گردد. تأثیر این اطلاعات در فواصل زمانی کمتر از ۶ ساعت بسیار چشم‌گیر است. پژوهش‌های پیشین نشانگر تأثیر بیشتر موقعیت مکانی در مقایسه با اطلاعات زمینه‌ای در فواصل زمانی بالای ۶ ساعت است. بنابراین با در نظر گرفتن وزن ۰٫۵ برای موقعیت مکانی، وزن ۰٫۲۵ برای سرعت باد و وزن ۰٫۲۵ برای جهت طوفان، در فواصل زمانی بالای ۶ ساعت نیز منجر به کاهش فاصله میان مسیر واقعی و مسیر پیش‌بینی شده گردیده است.

۵- بحث

در این پژوهش از مدل *TSSPL* برای پیش‌بینی مسیر طوفان‌ها و بررسی تأثیر اطلاعات زمینه‌ای در این مدل استفاده شد. یکی از مشاهدات مهم این پژوهش، کارآمدی بالای مدل *LSTM* در کار با داده‌های زمانی با حجم بسیار زیاد نظیر داده‌های طوفان‌ها و مناسب برای اعمال اطلاعات زمینه‌ای است. به‌طور مثال، در این پژوهش داده‌ها شامل ۲۵۱۷۵ موقعیت مکانی از مسیر طوفان‌ها است که هر نقطه شامل طول و عرض جغرافیایی و سرعت باد و جهت طوفان است. در نظر گرفتن این اطلاعات منجر به بهبود صحت نتایج و نزدیک‌تر شدن مسیر پیش‌بینی شده به مسیر واقعی

بر روی داده‌های سال‌های ۱۹۹۶ تا ۲۰۱۵ از مجموعه داده‌های $CAM5^1$ و نقشه‌هایی با قدرت تفکیک ۰٫۵ درجه، با در نظر گرفتن اطلاعات زمینه‌ای سرعت باد و بارش، به صورت متغیر ۱۴۰ الی ۱۷۰ کیلومتر بدست آورده و همچنین مقدار $RMSE$ برای ۱۲ ساعت در این پژوهش ۲٫۶۸ در واحد پیکسل حاصل شده است [۶]. نزدیکی صحت مقادیر حاصل شده در پژوهش حاضر و سایر پژوهش‌ها در این حوزه نشانگر این است که مدل پیشنهادی در مقایسه با سایر مدل‌های یادگیری عمیق عملکرد مناسبی از خود نشان می‌دهد. لیان و همکاران (۲۰۲۰)، با استفاده از مدل دیگری از یادگیری عمیق تحت عنوان $AE-GRU$ بر روی داده‌های طوفان‌های حاره‌ای اقیانوس آرام شمالی با در نظر گرفتن اطلاعات زمینه‌ای همچون شدت باد، متوسط سطح آب، فشار هوا، سرعت باد، سرعت طوفان، ارتفاع موج و شعاع ماکزیمم باد برای حداقل مدت زمان پیش‌بینی ۱۲، صحت پیش‌بینی نتایج ۱۳۸٫۶۷ کیلومتر بدست آوردند که نشان‌دهنده بهبود صحت نتایج با افزایش تعداد اطلاعات زمینه‌ای مؤثر است [۲]. علیزاده و همکاران (۲۰۲۱)، با استفاده از مدل $TSSPL$ موقعیت آینده کشتی‌ها را در فواصل ۱۰، ۲۰، ۳۰ و ۴۰ دقیقه پیش‌بینی می‌کردند. مقدار R^2 برای داده‌های آموزش در این پژوهش ۰٫۹۸۵۳ و مقدار MSE $5.9081e-5$ محاسبه شده است، که نشان‌دهنده کارآمدی مدل $TSSPL$ برای پیش‌بینی‌های کوتاه مدت و بلند مدت است [۱۸]. در چنین پژوهشی، قابلیت اطمینان داده‌ها جهت حصول یک پیش‌بینی دقیق بسیار مهم است. این واقعیت که، در دهه‌های گذشته ابزارهای گیرنده اطلاعات هواشناسی دقیق نبوده‌اند، سبب ایجاد محدودیت، تناقض و خطا در نتایج می‌گردد. تولید داده‌های طوفان‌های شبیه‌سازی شده به طوفان واقعی با استفاده از رویکردهای جدید، ما را در بهبود دقت و

فواصل بالا در صورت در نظر گرفتن وزن برابر با موقعیت مکانی کاهش می‌یابد. در صورتی که وزن اطلاعات مکانی را ۰٫۵ و وزن سرعت باد را ۰٫۲۵ و وزن جهت طوفان را ۰٫۲۵ در نظر بگیریم، در تمامی مدت‌زمان‌های ۳، ۶، ۹ و ۱۲ ساعت افزایش صحت نتایج را به دنبال خواهد داشت. بنابراین میزان تأثیر موقعیت مکانی (عرض و طول جغرافیایی) از اطلاعات زمینه‌ای بر صحت نتایج بیشتر است، اما همچنان اطلاعات زمینه‌ای به بهبود صحت نتایج کمک می‌کنند. مدت‌زمان پیش‌بینی در اکثر پژوهش‌های مشابه ۶ ساعت بوده که در این پژوهش با توجه به ساختار داده‌ها، ۳، ۶، ۹ و ۱۲ ساعت در نظر گرفته شد؛ که این مدت‌زمان برای مدیریت بحران قبل از وقوع طوفان مناسب است.

در مقایسه صحت نتایج، گائو و همکاران (۲۰۱۸) با استفاده از مدل $LSTM$ برای پیش‌بینی مسیر طوفان‌های دریای شمال چین مربوط به سال‌های ۱۹۴۹ تا ۲۰۱۲ میلادی، در مدت‌زمان پیش‌بینی ۶ ساعت بدون در نظر گرفتن اطلاعات زمینه‌ای، صحت پیش‌بینی تعدادی طوفان نمونه را بین ۴۵٫۹۸۴ و ۱۲۴٫۳۸۵ کیلومتر بدست آوردند. میانگین این مقدار در پژوهش حاضر با در نظر گرفتن اطلاعات زمینه‌ای برای مدت‌زمان پیش‌بینی ۶ ساعت ۶۱٫۳۱۷ کیلومتر بدست آمده است [۲۵]. ونگ و همکاران (۲۰۲۰)، نتایج صحت پیش‌بینی مسیر طوفان‌ها را با استفاده از مدل $LSTM$ بر روی داده‌های ۲۱۲ طوفان حاره‌ای در اقیانوس اطلس شمالی از سال‌های ۲۰۱۲ تا ۲۰۱۸ میلادی، بدون در نظر گرفتن اطلاعات زمینه‌ای برای مدت زمان پیش‌بینی ۱۲ ساعت، ۲۸۲٫۶۳ کیلومتر بدست آوردند که در مقایسه با مقدار ۱۷۴٫۸۴۱ کیلومتر بدست آمده در پژوهش حاضر، نشان از تأثیر مثبت اطلاعات زمینه‌ای در بهبود صحت نتایج پیش‌بینی دارد [۲۰]. در پژوهشی کیم و همکاران (۲۰۱۹)، صحت نتایج پیش‌بینی مسیر طوفان‌ها در مدت زمان ۱۲ ساعت با استفاده از روش $ConvLSTM$

¹ Community Atmosphere Model

کیفیت یاری خواهد کرد [۲۶ و ۲۷].

۶- نتیجه‌گیری

در این پژوهش به پیش‌بینی مسیر طوفان‌های حاره‌ای با استفاده از روش پیش‌بینی جستجوی شباهت مبتنی بر مسیر با استفاده از مدل TSSPL پرداخته شد. در این مدل ترکیبی، شباهت میان مسیره‌ها نه تنها از بعد موقعیتی، بلکه از بعد زمینه‌ای همچون سرعت باد و جهت طوفان نیز بررسی گردید. نتایج نشان دادند که موقعیت مکانی (عرض و طول جغرافیایی) در مقایسه با اطلاعات زمینه‌ای در پیش‌بینی مسیر اثرگذارتر بودند. با این وجود نتایج موید تأثیر مثبت اطلاعات زمینه‌ای بر پیش‌بینی دقیق‌تر مسیر طوفان‌های حاره‌ای است.

مراجع

- [1] S. Alemany, J. Beltran, A. Perez, and S. Ganzfried, "Predicting Hurricane Trajectories Using a Recurrent Neural Network," *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 33, no. 01, pp. 468-475, 07/17 2019, doi: 10.1609/aaai.v33i01.3301468.
- [2] J. Lian, P. Dong, Y. Zhang, J. Pan, and K. Liu, "A Novel Deep Learning Approach for Tropical Cyclone Track Prediction Based on Auto-Encoder and Gated Recurrent Unit Networks " *Applied Sciences*, vol. 10, p. 3965, 2020, doi: 10.3390/app10113965.
- [3] J. Yu, J. Tang, Y. Dai, and B. Yu, "Analyses in errors and their causes of Chinese typhoon track operational forecasts," *Meteorol Monthly*, vol. 38, pp. 695-700, 2012.
- [4] M. Rüttgers, S. Lee, S. Jeon, and D. You, "Prediction of a typhoon track using a generative adversarial network and satellite images," *Scientific Reports*, vol. 9, no. 1, p. 6057, 2019/04/15 2019, doi: 10.1038/s41598-019-42339-y.
- [5] J. S. Goerss, "Tropical cyclone track forecasts using an ensemble of dynamical models," *Monthly Weather Review*, vol. 128, no. 4, pp. 1187-1193, 2000.
- [6] S. Kim et al., "Deep-Hurricane-Tracker: Tracking and Forecasting Extreme Climate Events," in *2019 IEEE Winter Conference on Applications of Computer Vision (WACV)*, 7-11 Jan. 2019 2019, pp. 1761-1769, doi: 10.1109/WACV.2019.00192.
- [7] J. Lian, P. Dong, Y. Zhang, J. Pan, and K. Liu, "A Novel Data-Driven Tropical Cyclone Track Prediction Model Based on CNN and GRU With Multi-Dimensional Feature Selection," *IEEE Access*, vol. 8, pp. 97114-97128, 2020, doi: 10.1109/ACCESS.2020.2992083.
- [8] D. Alizadeh, A. A. Alesheikh, and M. Sharif, "Prediction of vessels locations and maritime traffic using similarity measurement of trajectory," *Annals of GIS*, pp. 1-12, 2020, doi: 10.1080/19475683.2020.1840434.
- [9] M. Sharif and A. A. Alesheikh, "Context-aware movement analytics: implications, taxonomy, and design framework," *WIREs Data Mining and Knowledge Discovery*, https://doi.org/10.1002/widm.1233 vol. 8, no. 1, p. e1233, 2018/01/01 2018, doi: https://doi.org/10.1002/widm.1233.
- [10] M. M. Kordmahalleh, M. G. Sefidmazgi, A. Homaiifar, and S. Liess, "Hurricane trajectory prediction via a sparse recurrent neural network," in *Proceedings of the 5th*

بررسی پیش‌بینی ۳، ۶، ۹ و ۱۲ ساعته با صحت قابل قبول از نقاط قوت روش TSSPL است؛ هرچند که با افزایش زمان از صحت نتایج کاسته می‌شود. از محدودیت‌های این پژوهش می‌توان به بالا بودن هزینه محاسبات و نیاز به حافظه بالا به علت وجود لایه‌های زیاد اشاره کرد. لذا در آینده می‌توان از سایر مدل‌های یادگیری عمیق در پیش‌بینی مسیر حرکت طوفان‌ها استفاده کرد. همچنین می‌توان با در نظر گرفتن اطلاعات زمینه‌ای دیگری همچون دمای آب و فشار هوا، میزان تأثیر این اطلاعات را بر روی صحت نتایج پیش‌بینی سنجید.

- International Workshop on Climate Informatics, 2015, pp. 2-3.*
- [11] Y. Zhang, R. Chandra, and J. Gao, "Cyclone Track Prediction with Matrix Neural Networks," in *2018 International Joint Conference on Neural Networks (IJCNN)*, 8-13 July 2018 2018, pp. 1-8, doi: 10.1109/IJCNN.2018.8489077.
- [12] M. Sharif, A. A. Alesheikh, and B. Tashayo, "CaFIRST: A context-aware hybrid fuzzy inference system for the similarity measure of multivariate trajectories," *Journal of Intelligent & Fuzzy Systems*, vol. 36, pp. 5383-5395, 2019, doi: 10.3233/JIFS-181252.
- [13] M. Sharif and A. A. Alesheikh, "A Review on the Process of Point Objects' Movement and Their Trajectory Similarity Measurement Approaches," (in eng), *Geospatial Engineering Journal, Research* vol. 7, no. 1, pp. 41-54, 2016. [Online]. Available: <http://gej.issge.ir/article-1-151-fa.html>.
- [14] S.-J. Qiao, K. Jin, N. Han, C.-J. Tang, and G. Gesangduoji, "Trajectory prediction algorithm based on Gaussian mixture model," *Journal of software*, vol. 26, no. 5, pp. 1048-1063, 2015.
- [15] H. Tang, Y. Yin, and H. Shen, "A model for vessel trajectory prediction based on long short-term memory neural network," *Journal of Marine Engineering & Technology*, pp. 1-10, 2019.
- [16] M. M. Kordmahalleh, M. G. Sefidmazgi, and A. Homaifar, "A Sparse Recurrent Neural Network for Trajectory Prediction of Atlantic Hurricanes," presented at the *Proceedings of the Genetic and Evolutionary Computation Conference 2016, Denver, Colorado, USA, 2016*. [Online]. Available: <https://doi.org/10.1145/2908812.2908834>.
- [17] Y. Chen, Q. Cheng, Y. Cheng, H. Yang, and H. Yu, "Applications of Recurrent Neural Networks in Environmental Factor Forecasting: A Review," *Neural Computation*, vol. 30, no. 11, pp. 2855-2881, 2018, doi: 10.1162/neco_a_01134 %M 30216144.
- [18] D. Alizadeh, A. A. Alesheikh, and M. Sharif, "Vessel trajectory prediction using historical automatic identification system data," *The Journal of Navigation*, vol. 74, no. 1, pp. 156-174, 2021.
- [19] Y. Wang, D. Zhang, Y. Liu, and K. L. Tan, "Trajectory Forecasting With Neural Networks: An Empirical Evaluation and A New Hybrid Model," *IEEE Transactions on Intelligent Transportation Systems*, vol. 21, no. 10, pp. 4400-4409, 2020, doi: 10.1109/TITS.2019.2943055.
- [20] D. Wang, B. Liu, P.-N. Tan, and L. Luo, "OMuLeT: Online Multi-Lead Time Location Prediction for Hurricane Trajectory Forecasting," *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 34, no. 01, pp. 963-970, 04/03 2020, doi: 10.1609/aaai.v34i01.5444.
- [21] M. Sharif and A. A. Alesheikh, "Similarity Measurement of Trajectories Based on Contextual Data in Constrained Euclidean Space," (in eng), *Journal of Geomatics Science and Technology, Research* vol. 5, no. 4, pp. 113-125, 2016. [Online]. Available: <http://jgst.issge.ir/article-1-400-fa.html>.
- [22] M. Sharif and A. A. Alesheikh, "Context-awareness in similarity measures and pattern discoveries of trajectories: a context-based dynamic time warping method," *GIScience & Remote Sensing*, vol. 54, no. 3, pp. 426-452, 2017.
- [23] M. Shaeri and R. Abbaspour, "Comparison of distance functions for similarity measurement in spatial trajectories," *Journal of Geomatics Science and Technology*, vol. 4, no. 3, pp. 201-212, 2015.
- [24] A. Karatzoglou, A. Jablonski, and M. Beigl, "A Seq2Seq learning approach for modeling semantic trajectories and predicting the next location," in *Proceedings of the 26th ACM SIGSPATIAL*

International Conference on Advances in Geographic Information Systems, 2018, pp. 528-531.

[25] S. Gao et al., "A nowcasting model for the prediction of typhoon tracks based on a long short term memory neural network," *Acta Oceanologica Sinica*, vol. 37, no. 5, pp. 8-12, 2018/05/01 2018, doi: 10.1007/s13131-018-1219-z.

[26] M. James and L. Mason, "Synthetic tropical cyclone database," *Journal of waterway, port, coastal, and ocean engineering*, vol. 131, no. 4, pp. 181-192, 2005.

[27] M. James and L. Mason, "Generation of a synthetic tropical cyclone database," in *Coasts & Ports 1999: Challenges and Directions for the New Century; Proceedings of the 14th Australasian Coastal and Ocean Engineering Conference and the 7th Australasian Port and Harbour Conference, 1999: National Committee on Coastal and Ocean Engineering, Institution of ...*, p. 381.



Trajectory Prediction of Tropical Storms Using Long Short-Term Memory Model, Similarity Measurement of Trajectories and Contextual Information

Sahar Farmanifard¹, Ali Asghar Alesheikh², Mohammad Sharif^{3*}, Danial Alizadeh⁴

1- M.Sc. Student, Department of Geospatial Information Systems, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology

2- Professor, Department of Geospatial Information Systems, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology

3- Assistant Professor, Department of Geography, Faculty of Humanities, University of Hormozgan

4- M.Sc., Department of Geospatial Information Systems, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology

Abstract

Tropical Cyclones are natural and complex phenomena that threaten the life and property of human society. The accuracy of predicting their trajectories is critical to reducing the economic loss and saving human lives. When a storm occurs, context information such as wind speed and intensity, air pressure, storm direction, water surface temperature, etc. are effective in changing the direction of the storm trajectory. Accordingly, considering this information can improve the forecasting accuracy. Researchers have used various methods to predict the direction of the hurricane movements in order to achieve the highest accuracy in forecasting. Nowadays, deep learning methods have shown a potential capability in processing the complex data efficiently and accurately. In this paper, we used the Long Short-Term Memory method to predict the future path and location of the tropical cyclones in the North Atlantic Ocean by measuring the similarity of the tropical cyclone trajectories and taking into account the positional parameters and context information such as wind speed and storm direction. The obtained results show an improvement in the accuracy of the prediction compared to the lack of context information for the 3, 6, 9, and 12 hour time periods. If the context information is taken into account, the distance between the predicted trajectory path and the actual trajectory path has been reduced from 1.9 to 4.5 km.

Key words: Trajectory Prediction, Similarity Analysis, Contextual Information, Long Short-Term Memory,