نشریه علمی مهندسی فناوری اطلاعات مکانی

سال یازدهم، شماره دوم، تابستان ۱۴۰۲
Vol.11, No.2, Summer 2023
۱۶-۱
مقاله پژوهشی
DOR: 20.1001.1.20089635.1402.11.2.1.4

[Downloaded from jgit.kntu.ac.ir on 2026-11-15]
[DOR: 20.1001.1.20089635.1402.11.2.1.4]
[DOI: 10.61186/jgit.11.2.1]

پیش‌بینی مسیر طوفان‌های حاره‌ای با استفاده از مدل حافظه طولانی کوتاه-مدت، اندازه‌گیری تشابه خطوطسیر و اطلاعات زمینه‌ای

سحر فرمانی‌فرد [۱]، علی‌اصغر آل‌شیخ [۲]، محمد شریف [۳*]، دانیال علیزاده [۴]

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

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

چکیده

طوفان حاره‌ای یک پدیده طبیعی و پیچیده است که وقوع آن جان و مال انسان‌ها را تهدید می‌کند. بنابراین پیش‌بینی دقیق مسیر حرکت طوفان برای کاهش خسارات اقتصادی و نجات جان انسان‌ها لازم است. هنگامی‌که طوفانی رخ می‌دهد اطلاعات زمینه‌ای 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 پیش‌بینی مسیر طوفان، می‌تواند دقت پیش‌بینی مسیر را بهبود بخشد. پژوهشگران روش‌های مختلفی را برای پیش‌بینی مسیر حرکت طوفان‌ها به‌کاربرده‌اند تا به بالاترین دقت در پیش‌بینی دست یابند. امروزه روش‌های یادگیری عمیق برای این منظور بسیار موردتوجه قرارگرفته است. در این پژوهش با اندازه‌گیری میزان شباهت خطوط‌سیر طوفان‌ها و در نظر گرفتن پارامترهای موقعیتی و اطلاعات زمینه‌ای نظیر سرعت باد و جهت طوفان، از روش حافظه طولانی کوتاه-مدت برای پیش‌بینی مسیر و مکان آینده طوفان‌های واقع در اقیانوس اطلس شمالی استفاده شده است. نتایج به‌دست‌آمده بهبود دقت پیش‌بینی نسبت به عدم در نظر گرفتن اطلاعات زمینه‌ای را برای بازه‌های زمانی ۳، ۶، ۹ و ۱۲ ساعت نشان می‌دهد. فاصله میان مسیر پیش‌بینی‌شده با مسیر واقعی در صورت در نظر گرفتن اطلاعات زمینه‌ای بین ۱/۹ تا ۴/۵ کیلومتر کاهش یافته است.

کلید واژه‌ها : پیش‌بینی خط‌سیر، اندازه‌گیری تشابه، اطلاعات زمینه‌ای، مدل حافظه طولانی کوتاه-مدت، طوفان‌های حاره‌ای.

* نویسنده مکاتبه کننده: بندرعباس، کیلومتر ۹ جاده میناب، دانشگاه هرمزگان، دانشکده علوم انسانی، گروه جغرافیا.
تلفن: ۰۷۶۳۳۷۱۱۰۰۰

Email: m.sharif@hormozgan.ac.ir

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. به‌عنوان‌مثال 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، ازجمله این عوامل می‌توان به محیط هواشناسی (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[1]، 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 موردتوجه پژوهشگران در گذشته است؛ بااین‌حال 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 ذکرشده 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

[1] *Geostrophic Deflection Force*

[Downloaded from jgit.kntu.ac.ir on 2026-11-15]
[DOR: 20.1001.1.20089635.1402.11.2.1.4]
[DOI: 10.61186/jgit.11.2.1]

دو مسیر بر اساس سری‌های زمانی وجود دارد، مانند فاصله اقلیدسی، فاصله ویرایش[1]، طولانی‌ترین دنباله مشترک[2] و روش پیچش زمانی پویا[3] (*DTW*) [۱۲] که هرکدام دارای مزایا و معایب خاص خود هستند [۱۳]. در این پژوهش از روش *DTW*، که ازجمله 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[4] (*LSTM*) ، که از مدل‌های کارآمد یادگیری عمیق درزمینه 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 مورداستفاده، 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 بخش ۴ پیاده‌سازی و نتایج بیان می‌گردند. در بخش ۵ به بحث و تفسیر نتایج پرداخته می‌شود. درنهایت 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 مدل‌محور[5] و داده‌محور[6] طبقه‌بندی نمود. کیائو و همکاران (۲۰۱۵)، با رویکردی مدل‌محور برای پیش‌بینی مسیر، مدل پیش‌بینی مسیر ترکیبی[7] (*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[8] 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.کوردمحله و همکاران (۲۰۱۶) برای پیش‌بینی طوفان‌های اقیانوس اطلس یک شبکه عصبی بازگشتی پراکنده[9] را با رویکردی داده محور پیشنهاد کردند. این روش بسیار انعطاف‌پذیر و مناسب داده‌های طوفان است به‌طوری‌که 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

[1] *Model-driven*
[2] *Data-driven*
[3] *Gaussian Mixture Trajectory Prediction*
[4] *Kalman Filter*
[5] *Sparse Recurrent Neural Network*

[2] *Edit Distance*
[3] *Longest Common Subsequence*
[4] *Dynamic Time Warping*
[5] *Long Short-Term Memory*

[Downloaded from jgit.kntu.ac.ir on 2026-11-15]
[DOR: 20.1001.1.20089635.1402.11.2.1.4]
[DOI: 10.61186/jgit.11.2.1]

مدل شبکه عصبی بازگشتی[1] 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 مورداستفاده برای پیش‌بینی مسیر طوفان‌ها، که توسط ژنگ و همکاران (۲۰۱۸)، در پژوهشی مورد بررسی قرار گرفته است، مدل شبکه عصبی ماتریسی[2] 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[3] 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 مولّد تخاصمی[4] را مورد بررسی قرار دادند [۴]. کیم و همکاران (۲۰۱۹) نیز مدلی مبتنی بر رگرسیون با استفاده از روش *LSTM* پیچشی[5] را برای تشخیص و ردیابی طوفان‌ها در تصاویر ماهواره‌ای مورد استفاده و ارزیابی قرار دادند. آن‌ها برای پیش‌بینی طوفان‌ها ساختار رمزگذاری[6] با به کار بردن معماری توالی به توالی[7] 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 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[8] 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 [۷]. اطلاعات زمینه‌ای همچون حداقل فشار سطح دریا،

[1] *Generative Adversarial Network*
[2] *Convolutional LSTM*
[3] *Encoding*
[4] *Sequence-to-Sequence*
[5] *Multi-Layer Perception (MLP)*
[6] *Recurrent Neural Network*
[7] *Matrix Neural Network*
[8] *Grid-based Models*

[Downloaded from jgit.kntu.ac.ir on 2026-11-15]
[DOR: 20.1001.1.20089635.1402.11.2.1.4]
[DOI: 10.61186/jgit.11.2.1]

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. به‌عنوان‌مثال 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.

۳-۱- مدل پیش‌بینی جستجوی شباهت خطوط‌سیر با استفاده از حافظه طولانی کوتاه-مدت[1] (*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 میان 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- پیچش 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 قرارگرفته 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.

---

[1] *Trajectory-based Similarity Search Prediction using LSTM*

[Downloaded from jgit.kntu.ac.ir on 2026-11-15]
[DOR: 20.1001.1.20089635.1402.11.2.1.4]
[DOI: 10.61186/jgit.11.2.1]

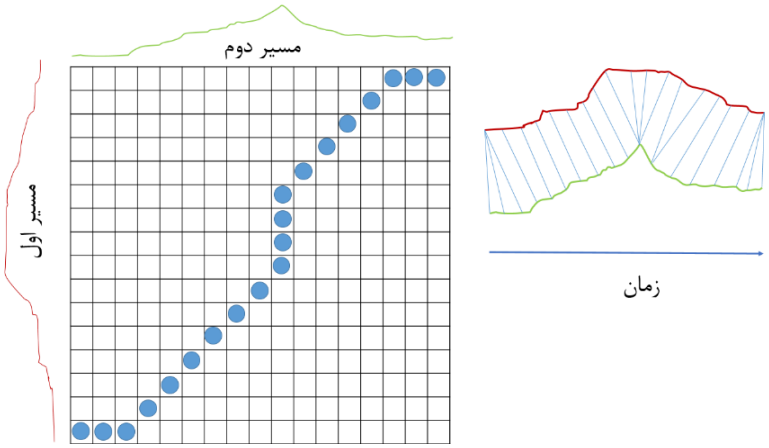

شکل۱: سازوکار *DTW* [۱۸]

۳-۱-۲- اندازه گیری شباهت خطوط‌سیر 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 خطوط‌سیر 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_{nd}، D_{ns} و D_{nv} به ترتیب فواصل جهت، مکان و سرعت نرمال‌شده می‌باشند و همچنین W_d، W_s 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 بدون در نظر گرفتن اطلاعات زمینه‌ای، شبیه‌ترین مسیر به مسیر هدف به‌دست می‌آید؛ بنابراین وزن اطلاعات زمینه‌ای (W_d و W_v) صفر خواهند بود. در حالت دوم موقعیت مکانی و اطلاعات زمینه‌ای، وزن برابر دارند. مقدار هر سه وزن W_d، W_s 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_d و W_v) 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.

رابطه(۲)

$$h_t = fw\left(h_{t-1}, x_t\right)$$

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

[Downloaded from jgit.kntu.ac.ir on 2026-11-15]
[DOR: 20.1001.1.20089635.1402.11.2.1.4]
[DOI: 10.61186/jgit.11.2.1]

روابط(۳) و (۴) معرفی شده است.

رابطه(۳)
$$h_t = f_{act}(c_t).o_t$$

رابطه(۴)
$$c_t = f_t.c_{t-1} + i_t.f_{act}(W_x.x_t + W_h.h_{t-1} + b)$$

در روابط (۳) و (۴)، $o_t.f_t$، i_t، f_{act}، W_x و W_h 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 h_4 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 غیرقابل‌کنترل می‌کند. این مسئله با کمک تابع سیگموئید با جمع یک مقدار واقعی در یک بازه ثابت (بین ۰ تا ۱) حل می‌شود.

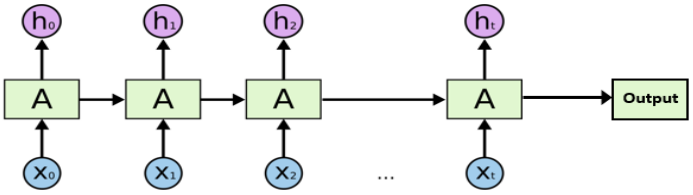

شکل۲: ساختار مدل *LSTM* [۲۴]

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)
$$Lon_{TP_{t2}} = \Delta Longitude - Lon_{SP_{t2}}$$
$$Lat_{TP_{t2}} = \Delta Latitude - Lat_{SP_{t2}}$$

در این مدل، فاصله میان مسیر هدف و شبیه‌ترین مسیر به آن ثابت نیست، بنابراین از روش *DTW* برای پیداکردن 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 پس از آخرین نقطه در مسیر هدف را که با فاصله زمانی ۳ ساعت از یکدیگر قرار دارند پیش‌بینی کرد.

[Downloaded from jgit.kntu.ac.ir on 2026-11-15]
[DOR: 20.1001.1.20089635.1402.11.2.1.4]
[DOI: 10.61186/jgit.11.2.1]

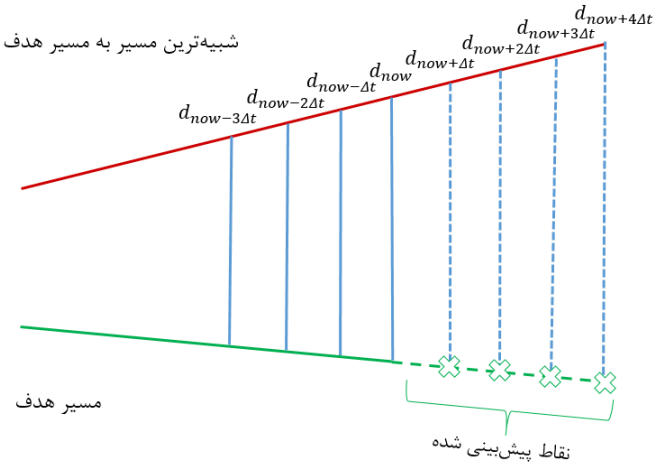

(الف)

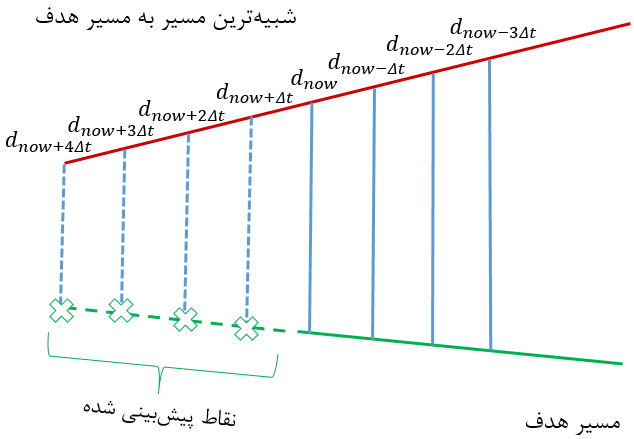

(ب)

شکل۳: مدل *TSSPL*: الف) زمانی که دو مسیر واگرا هستند و ب) زمانی که دو مسیر همگرا هستند [۱۸]

۳-۲- آموزش و اجرا مدل *LSTM*

برای آموزش شبکه از داده‌های پیش‌پردازش‌شده 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 پیش‌بینی‌شده از مسیر هدف به‌دست خواهد آمد. پس از آموزش مدل، از نقطه پیش‌بینی‌شده 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 محاسبه‌شده برای آموزش شبکه و تنظیم ماتریس وزن برای مقایسه میزان خطای بین مقدار پیش‌بینی‌شده و مقدار مورد انتظار به کار می‌رود (شکل (۴)).

[Downloaded from jgit.kntu.ac.ir on 2026-11-15]
[DOR: 20.1001.1.20089635.1402.11.2.1.4]
[DOI: 10.61186/jgit.11.2.1]

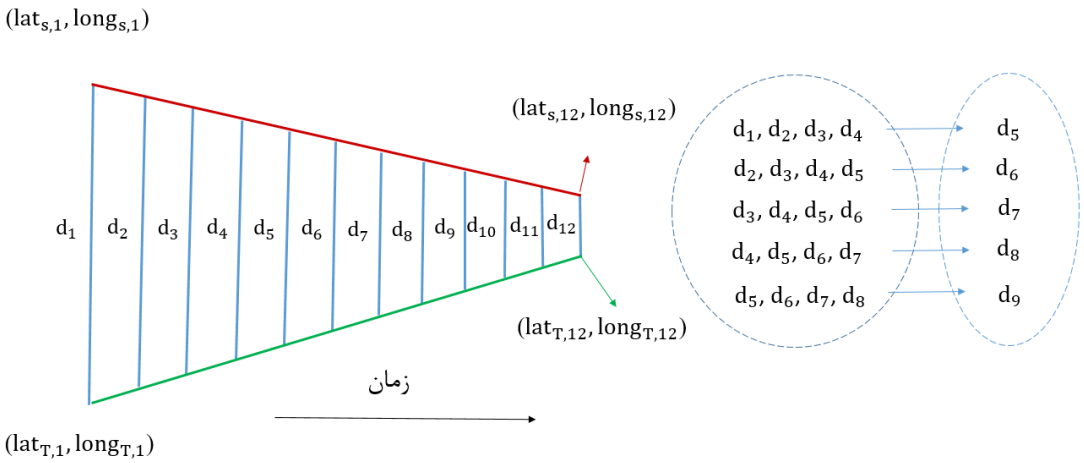

شکل۴: آماده‌سازی داده‌ها برای ورود به مدل *LSTM* [۱۸]

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)

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

در رابطه(۶)، $\boldsymbol{d_1}$ تا $\boldsymbol{d_4}$ 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 ارزیابی مدل به‌منظور 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 و ضریب همبستگی (*r-square*)، به‌منظور بررسی کمّی دقت مدل بهره برده شده است. دو معیار ذکرشده به ترتیب توسط روابط(۷) و (۸) محاسبه شده‌اند.

رابطه(۷)

$$MSE = \frac{1}{n}\sum_{i=0}^{n}\left(y_i - y_i\right)^2$$

رابطه(۸)

$$R^2 = 1 - \frac{\sum_{i=0}^{n}\left(y_i - y_i\right)^2}{\sum_{i=0}^{n}\left(y_i - \overline{y_i}\right)^2}$$

در روابط(۷) و (۸)، y_i، $\hat{y}_i$ و $\overline{y_i}$ به ترتیب نشان‌دهنده مقدار واقعی، مقدار پیش‌بینی‌شده 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]

---

[۱] *Generalization Ability*

[۲] *Mean Square Error*

[۳] *Haversine*

[Downloaded from jgit.kntu.ac.ir on 2026-11-15]
[DOR: 20.1001.1.20089635.1402.11.2.1.4]
[DOI: 10.61186/jgit.11.2.1]

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، خطوط‌سیر مربوط به ۴۲۶ طوفان اقیانوس اطلس شمالی که در سال‌های ۱۹۹۴ تا ۲۰۱۹ به وقوع پیوسته‌اند، است. منطقه موردمطالعه در عرض جغرافیایی صفر درجه شمالی تا ۵۰ درجه شمالی و طول جغرافیایی ۹۰ درجه غربی تا صفر درجه غربی قرار گرفته است. درمجموع این ۴۲۶ 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 موردمطالعه و تراکم بالای طوفان‌ها در سال‌های ۱۹۹۴ تا ۲۰۱۹ را نشان می‌دهد.

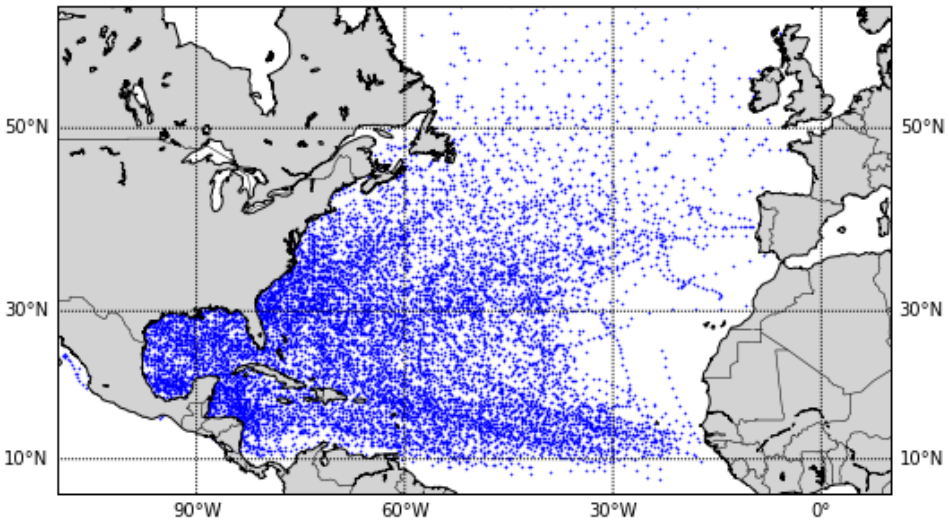

شکل۵: منطقه موردمطالعه به همراه خطوط‌سیر طوفان‌ها

۴-۲- نتایج پیش‌بینی

در جدول (۱) نتایج کمّی حاصل از عملکرد مدل آموزش‌دیده شده بر روی مجموعه داده‌های آموزشی، ارزیابی و اعتبارسنجی آورده شده است. نحوه تغییر مقادیر دو معیار ذکرشده، در طول ۱۰۰۰ تکرار (*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.

جدول۱ : ارزیابی عملکرد مدل *LSTM*

مجموعه داده‌ها	ضریب همبستگی (R^2)	میانگین کمترین مربعات (*MSE*)
آموزشی	۰٫۹۹۹۳	۷٫۶۶۷۸e-۰۶
ارزیابی	۰٫۹۹۹۲	۷٫۷۶۹۶e-۰۶
تست	۰٫۹۹۹۱	۷٫۶۶۷۷e-۰۶

[Downloaded from jgit.kntu.ac.ir on 2026-11-15]
[DOR: 20.1001.1.20089635.1402.11.2.1.4]
[DOI: 10.61186/jgit.11.2.1]

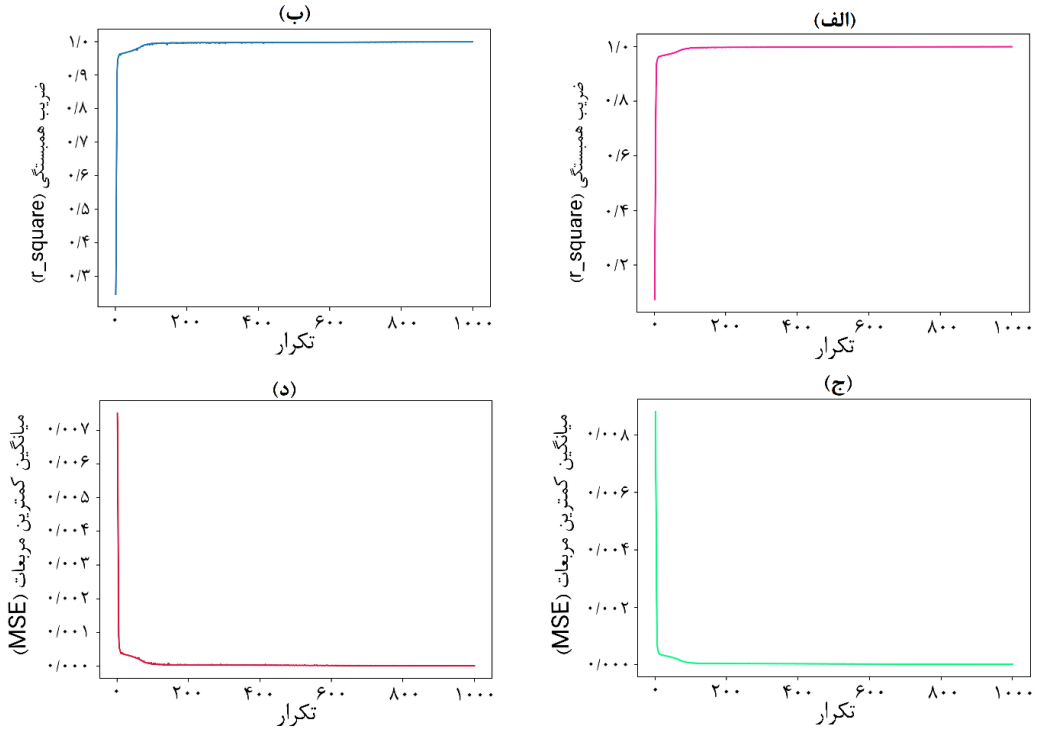

شکل ۶: ارزیابی کمی مدل *LSTM*: (الف) مقادیر ضریب همبستگی بر روی مجموعه داده آموزشی؛ (ب) مقادیر ضریب همبستگی بر روی مجموعه داده اعتبارسنجی؛ (ج) مقادیر میانگین کمترین مربعات بر روی مجموعه داده آموزشی؛ (د) مقادیر میانگین کمترین مربعات بر روی مجموعه داده اعتبارسنجی

۴-۳- نقش اطلاعات زمینه‌ای در پیش‌بینی

در فضای کروی فاصله میان دو نقطه با مقدار واقعی و پیش‌بینی‌شده 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 هاورسین محاسبه شده بین دو نقطه مورد نظر است. $Latitude_1$ و $Latitude_2$ به ترتیب عرض جغرافیایی نقطه اول و دوم و $\Delta Latitude$ و $\Delta Longitude$ 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، به‌طوری‌که یکبار اندازه‌گیری میزان شباهت صرفا 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 نظرگرفته شد (قسمت (ب) و (ج) در جدول(۲)) و نتایج در جدول(۲) باهم مقایسه شد.

$$d_d = 2r \times \sin^{-1}\left(\left(\sin^2\left(\frac{\Delta Latitude}{2}\right) + \cos\left(Latitude_1\right).\cos\left(latitude_2\right).\sin^2\left(\frac{\Delta Longitude}{2}\right)\right)^{1/2}\right) \quad \text{رابطه(۹)}$$

[Downloaded from jgit.kntu.ac.ir on 2026-11-15]
[DOR: 20.1001.1.20089635.1402.11.2.1.4]
[DOI: 10.61186/jgit.11.2.1]

جدول۲: 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 هرکدام 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

نتایج نشان می‌دهند که وجود اطلاعات عوامل زمینه‌ای مانند سرعت باد و جهت طوفان منجر به کاهش فاصله میان مسیر طوفان پیش‌بینی‌شده 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 پیش‌بینی‌شده 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 پیش‌بینی‌شده به مسیر واقعی 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 پیش‌بینی‌شده قبلی حاصل از مدل *LSTM*، به‌دست می‌آیند. بنابراین خطای فاصله مکانی پیش‌بینی‌شده در هر زمان بر خطای فاصله مکانی پیش‌بینی‌شده 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 نظرگرفتن اطلاعات زمینه‌ای بهبود می‌یابد. اما در مدت زمان ۹ و ۱۲ ساعت از صحت نتایج کاسته می‌شود. درواقع تأثیر اطلاعات زمینه‌ای در

[Downloaded from jgit.kntu.ac.ir on 2026-11-15]
[DOR: 20.1001.1.20089635.1402.11.2.1.4]
[DOI: 10.61186/jgit.11.2.1]

فواصل بالا در صورت در نظر گرفتن وزن برابر با موقعیت مکانی کاهش می‌یابد. درصورتی‌که 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* بر روی داده‌های سال‌های ۱۹۹۶ تا ۲۰۱۵ از مجموعه داده‌های *CAM5*[۱] 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* ۵/۹۰۸۱*e*-۵ 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 شبیه‌سازی‌شده به طوفان واقعی با استفاده از رویکردهای جدید، ما را در بهبود دقت و

[۱] *Community Atmosphere Model*

[Downloaded from jgit.kntu.ac.ir on 2026-11-15]
[DOR: 20.1001.1.20089635.1402.11.2.1.4]
[DOI: 10.61186/jgit.11.2.1]

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 مسیرها 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.

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.

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. Homaifar, and S. Liess, "Hurricane trajectory prediction via a sparse recurrent neural network," in Proceedings of the 5th

[Downloaded from jgit.kntu.ac.ir on 2026-11-15]
[DOR: 20.1001.1.20089635.1402.11.2.1.4]
[DOI: 10.61186/jgit.11.2.1]

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

[Downloaded from jgit.kntu.ac.ir on 2026-11-15]
[DOR: 20.1001.1.20089635.1402.11.2.1.4]
[DOI: 10.61186/jgit.11.2.1]

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.

[Downloaded from jgit.kntu.ac.ir on 2026-11-15]
[DOR: 20.1001.1.20089635.1402.11.2.1.4]
[DOI: 10.61186/jgit.11.2.1]

K. N. TOOSI UNIVERSITY OF TECHNOLOGY
FACULTY OF GEODESY AND GEOMATICS ENGINEERING

Journal of Geospatial Information Technology
Vol.11, No.2, Summer 2023

Research Paper

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

Sahar Farmanifard [1], Ali Asghar Alesheikh [2], Mohammad Sharif [3*], Danial Alizadeh[4]

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,*

Correspondence Address *: Department of Geography, Faculty of Humanities, University of Hormozgan, Minab Road, Bandar Abbas, Iran.*
Tel *: +987633711000.*
Email*: m.sharif@hormozgan.ac.ir*

[Downloaded from jgit.kntu.ac.ir on 2026-11-15]
[DOR: 20.1001.1.20089635.1402.11.2.1.4]
[DOI: 10.61186/jgit.11.2.1]