

الگوریتمی برای فشردن سازی خطوط سیر مکانی با حفظ ماهیت معنایی

سمیه عاقل شاه‌نشین^۱، سیمین سادات میروهابی^۱، رحیم علی‌عباسپور^{۲*}

- ۱- دانشجوی کارشناسی ارشد سیستم‌های اطلاعات مکانی - دانشکده مهندسی نقشه برداری و اطلاعات مکانی - پردیس دانشکده‌های فنی - دانشگاه تهران
۲- استادیار دانشکده مهندسی نقشه برداری و اطلاعات مکانی - پردیس دانشکده‌های فنی - دانشگاه تهران

تاریخ دریافت مقاله: ۹۴/۰۹/۱۲ تاریخ پذیرش مقاله: ۹۴/۱۲/۱۰

چکیده

یک راه معمول برای ذخیره اطلاعات مکانی-زمانی اشیاء در حال حرکت، نمایش مسیر حرکت شیء متحرک به شکل خط سیر سه‌بعدی (موقعیت جغرافیایی نقاط به همراه زمان) است. در سال‌های اخیر تحقیقات گسترده‌ای در حوزه خط سیر انجام شده است. با این حال، در این مطالعات، ایده خط سیر معنایی یک مفهوم نسبتاً جدید است که با هدف انجام آنالیزهای معنایی مؤثر روی داده‌ها انجام می‌شود. در خط سیر معنایی که یک نمایش ثانویه از خط سیر مکانی است، حرکت شیء به شکل دنباله‌ای از توقف‌ها و حرکت‌ها توصیف می‌شود. تولید خط سیر معنایی از داده‌های خام جمع‌آوری شده، یک فرآیند با چندین گام پردازش است که با توجه به حجم عظیم داده‌ها، یکی از پیش‌پردازش‌های موردنیاز کاهش تعداد نقاط خط سیر با حفظ دقت موردنیاز با استفاده از تکنیک‌های فشردن سازی است. با وجود این، اغلب تکنیک‌های کاهش داده خط سیر که بر اساس ساده‌سازی خطی هستند، قادر به حفظ مناطق توقف و حرکت نیستند. در این مقاله روشی برای فشردن سازی داده‌های خط سیر بر اساس سرعت نقاط ارائه شده است که از ترکیب دو تابع فاصله در درونیایی و محاسبه خطای نقاط استفاده کرده است. تابع فاصله اول بر اساس سرعت نقاط است که برای محاسبه خطای تقریب خط سیر استفاده شده و تابع فاصله دوم تابعی بر اساس توسعه الگوریتم شناخته شده داگلاس-پوکر است که از فرض ثابت بودن شتاب در محاسبه خطا در تقریب استفاده کرده است. الگوریتم ارائه شده روی داده‌های واقعی خط سیر پیاده‌سازی شده و نتایج به دست آمده حاکی از بهبود عملکرد در حفظ مناطق توقف در مقایسه با الگوریتم‌های فشردن سازی دیگر است.

کلیدواژه‌ها: خط سیر معنایی، فشردن سازی، مدل توقف-حرکت، E_1 - E_2

۱- مقدمه

شیء متحرک برای انجام فعالیت‌های مهم و یا در مکان‌های مهم توقف می‌کند و یا سرعت خود را کاهش می‌دهد. به این ترتیب مناطق توقف معمولاً به صورت تراکم نقاط در مناطق توقف (به دلیل توقف شیء متحرک و یا کاهش سرعت) و یا نبود سیگنال GPS (به دلیل ورود شیء متحرک به فضای بسته) در خط سیر ظاهر می‌شود. از این رو می‌توان نتیجه گرفت، در حالی که در مباحث مربوط به خطوط سیر هندسی، مسیر حرکت شیء متحرک مبنای تحلیل داده‌های خط سیر است، در خطوط سیر معنایی، علاوه بر مسیر حرکت شیء متحرک، شناسایی و تحلیل مکان‌های توقف در خط سیر نیز از اهمیت ویژه‌ای برخوردار است.

شکل ۱ مثالی از خط سیر هندسی و خط سیر معنایی متناظر با آن را برای گردش یک روزه یک گردشگر نشان می‌دهد. در شکل ۱ (بالا)، خطوط سیر به شکل نقاط ساده بدون اطلاعات معنایی نشان داده شده‌اند. در شکل ۱ (پایین)، اطلاعات معنایی با خطوط سیر ترکیب شده‌اند. همانگونه که مشاهده می‌شود، در خط سیر معنایی، مکان‌های مهم از نظر کاربرد با اطلاعات معنایی غنی‌سازی شده‌اند. در این مثال، مکان‌های مهم شامل اماکن تفریحی و گردشگری و محل اقامت هستند.

نگهداری و ذخیره اطلاعات خط سیر در پایگاه داده اشیاء متحرک به سرعت می‌تواند به حجم عظیمی از داده‌ها تبدیل شود. از این رو ارائه راهکارهای مناسب برای مدیریت مؤثر این حجم عظیم از داده‌ها ضروری به نظر می‌رسد. از یک سو غنی‌سازی معنایی داده‌های خط سیر مکانی یک راه مؤثر در کاهش این حجم عظیم داده‌هاست. از سوی دیگر در پردازش داده‌ها که با هدف آماده‌سازی داده‌های خط سیر برای غنی‌سازی معنایی انجام می‌شود، استفاده از تکنیک‌های فشردن سازی برای حذف داده‌های اضافی می‌تواند مورد استفاده قرار گیرد. با این حال سؤال اساسی این است که می‌توان با حفظ دقت

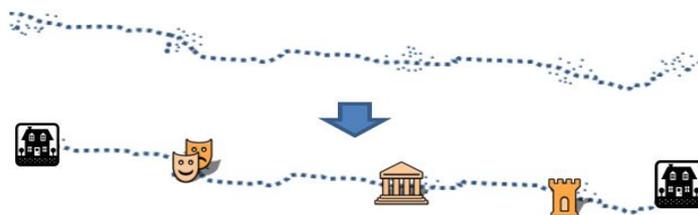
امروزه تعیین موقعیت توسط دستگاه‌های سیار مجهز به GPS افزایش چشمگیری داشته است. به این ترتیب حجم عظیمی از اطلاعات مکانی به‌طور مداوم و روزانه تولید می‌شود. تعیین موقعیت اشیاء متحرک در خدمات مکان‌مبنا کاربردهای گسترده‌ای از قبیل مدیریت و برنامه‌ریزی شهری، مدیریت حمل و نقل و ترافیک، گردشگری، الگوکاوای مسیر مهاجرت حیوانات و غیره دارد. با این حال، اغلب این خدمات روی موقعیت فعلی کاربران تمرکز می‌کنند و اطلاعاتی که می‌تواند از تاریخچه حرکت کاربران به دست آید را کمتر مورد توجه قرار می‌دهند. با این حال، غیر از اطلاعات خامی که مستقیماً از دستگاه‌های تعیین موقعیت به دست می‌آید، خدمات و کاربردهای نسل‌های بعد نیاز به این دارند تا منطق رفتاری و انگیزه حرکت را نیز بررسی کنند تا اطلاعات بیشتری را فراهم کنند. خط سیر^۱ مدلی برای نمایش مسیر حرکت جسم متحرک است که معمولاً به صورت رشته‌ای از موقعیت‌های زمان‌دار به شکل (P_i, t_i) تعریف می‌شود که در آن P_i موقعیت دوبعدی نقطه یعنی (x_i, y_i) است و t_i نیز زمان ثبت مربوط به نقطه است [۱].

در حوزه مطالعات مربوط به خط سیر، خط سیر معنایی^۲ مفهوم نسبتاً جدیدی است که با هدف انجام آنالیزهای معنایی مؤثر روی داده‌ها ایجاد می‌شود. خط سیر معنایی یک نمایش ثانویه از مسیر حرکت شیء است که فهم مسیر را ساده‌تر می‌کند. ایده اصلی این است که مسیر حرکت شیء دنباله‌ای از بخش‌های همگن و معنی‌دار است. یک مدل مفهومی رایج در شناسایی این بخش‌های همگن، مدل توقف-حرکت است با این فرض اساسی که

^۱ Trajectory^۲ Semantic Trajectory

قابل پیش‌بینی هستند؛ در نتیجه بسیاری از اطلاعات اضافی می‌توانند از خط سیر حذف شوند.

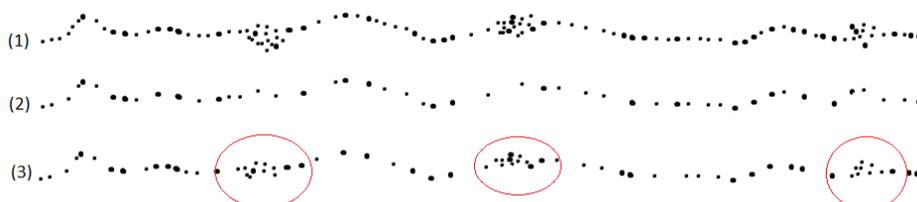
مورد نیاز به حذف تعدادی از داده‌ها پرداخت. با توجه به ماهیت خطی حرکت اشیای متحرک، بسیاری از کاربردهای مربوط به خدمات مکان‌مبنا دارای الگوهای



شکل ۱: خط سیر هندسی (بالا) که معادل خط سیر معنایی (پایین) است [۲]

مشاهده می‌شود، یک تکنیک فشردگی سیر بر اساس ساده‌سازی خطی قادر به حفظ مناطق توقف در خط سیر نیست. اما در شکل ۲ (۳) تکنیک فشردگی معنایی علاوه بر کاهش حجم داده‌های خط سیر، مناطق توقف را نیز حفظ کرده است.

اغلب تکنیک‌های کاهش داده خط سیر، بر اساس روش‌های ساده‌سازی خط هستند. در این روش‌ها هدف از فشردگی سیر، کاهش تعداد نقاط با حفظ ماهیت هندسی خط سیر می‌باشد. با این حال در خطوط سیر معنایی حفظ ماهیت خط سیر، که مستلزم حفظ نقاط توقف می‌باشد، از اهمیت بالایی برخوردار است. همانطور که در شکل ۲ (۲)



شکل ۲- ضرورت فشردگی خطوط سیر برای حفظ مناطق توقف، (۱) خط سیر اصلی، (۲) خط سیر فشردگی شده با تکنیک ساده‌سازی خطی، (۳) خط سیر فشردگی شده با هدف حفظ مناطق توقف

در آنالیزهای مکانی و معنایی مورد استفاده قرار گیرد. ساختار مقاله پیش‌رو به این شکل است: بخش ۲ به مرور مطالعات پیشین در زمینه فشردگی خطوط سیر هندسی و معنایی می‌پردازد. بخش ۳ به بیان مبانی نظری این تحقیق پرداخته است. در بخش ۴ روش پیشنهادی معرفی و تحلیل شده است. و مراحل مختلف روش مورد بررسی قرار گرفته است. در بخش ۵ الگوریتم فشردگی ارائه شده روی داده‌های واقعی پیاده‌سازی شده و نتایج آن

به علت وجود کاستی‌های مذکور در روش‌های موجود، این مقاله سعی در ارائه روشی جدید برای رفع این مشکلات دارد. الگوریتم ارائه شده با در نظر گرفتن سرعت و زمان حرکت شیء متحرک و انجام پردازش‌های لازم روی این دو پارامتر قادر به فشردگی سیر خط سیرهای مکانی با حفظ مناطق توقف و حرکت برای پردازش‌های بعدی در خط سیر است. نتیجه این تحقیق می‌تواند به عنوان مسیری جدید در فشردگی خطوط سیر معنایی برای استفاده



شکل ۳- نمایشی از خط سیر هندسی در سایت bikely5

شناخته شده‌ترین الگوریتم دسته‌ای، الگوریتم داگلاس-پوکر^۴ است. این الگوریتم روشی برای ساده‌سازی خط با کاهش تعداد نقاط است. در این روش، اندازه‌گیری خط بر اساس فاصله اقلیدسی قائم انجام می‌شود و از میانگین و یا مجموع فواصل خط برای ارزیابی دقت تقریب استفاده می‌شود. این روش اندازه‌گیری خط به شدت به تعداد نقاط نمونه وابسته است. ایده تصویر تمام نقاط ممکن در خط سیر اصلی روی پاره خط تقریبی نقاط، که اساس این روش است، تنها ویژگی‌های مکانی نقاط خط سیر را در نظر می‌گیرد و بعد زمانی نادیده گرفته می‌شود. فاصله اقلیدسی همزمان، روشی برای اندازه‌گیری خط برای نقاط است که در الگوریتم‌های کاهش داده خط سیر نیز می‌تواند استفاده شود. برای پرداختن به این موضوع مارتینا و دیبای^۵ با هدف اتخاذ معیارهای جدید خط که نرخ فاصله زمانی^۵ نامیده می‌شود، به جای فاصله اقلیدسی قائم از فاصله اقلیدسی همزمان^۶ استفاده کردند که معیار دقیق‌تری برای اندازه‌گیری خط ارائه می‌دهد، چون هر دو ویژگی هندسی و زمانی شیء متحرک را در نظر می‌گیرد. تابع خط در الگوریتم داگلاس پوکر از نقاطی استفاده می‌کند که بیشترین انحراف را نسبت به خط سیر اصلی دارد. با این حال هیچ تضمینی وجود ندارد که این نقاط

مورد ارزیابی قرار گرفته است. بخش آخر نیز به جمع‌بندی و نتیجه‌گیری می‌پردازد.

۲- مروری بر مطالعات پیشین

مطالعات گسترده‌ای در حوزه فشردن خطوط سیر انجام شده است. تکنیک‌های ارائه شده برای فشردن خطوط سیر بر اساس نوع خط سیر را می‌توان به دو دسته تقسیم کرد:

۱. تکنیک‌های فشردن خطوط سیر مبتنی بر خطوط سیر هندسی
 ۲. تکنیک‌های فشردن خطوط سیر معنایی
- در ادامه به بررسی و ارزیابی نمونه‌هایی در هر یک از دسته‌بندی‌های فوق پرداخته می‌شود.

۲-۱- تکنیک‌های فشردن خطوط سیر مبتنی بر خطوط سیر هندسی

به طور کلی مطالعات مربوط به تکنیک‌های کاهش داده خطوط سیر هندسی را می‌توان به دو بخش اصلی بر اساس نحوه بررسی و ورود داده‌ها در الگوریتم تقسیم کرد: فشردن خطوط سیر آفلاین و فشردن خطوط سیر آنلاین. در تکنیک‌های فشردن خطوط سیر آفلاین یا دسته‌ای^۱ ابتدا یک مجموعه کامل از نمونه‌ها جمع‌آوری شده و سپس فشردن خطوط سیر مجموعه داده‌ها با حذف داده‌های اضافی انجام می‌شود. از آنجا که این تکنیک‌های فشردن خطوط سیر از کل مجموعه داده‌ها به صورت یکجا استفاده می‌کند، نتایج آنها منجر به دستیابی به دقتی بهتر نسبت به سایر تکنیک‌ها می‌شود. به عنوان مثال این تکنیک‌ها برای بارگذاری و تحلیل داده‌های خط سیر در وبسایت‌های مختلف چون EveryTrail^۲ و bikely^۳ (شکل ۳) بسیار مناسب هستند^۳ در ادامه به بررسی نمونه‌هایی از این تکنیک پرداخته می‌شود.

⁴ Douglas-Peucker algorithm

⁵ Time distance ratio

⁶ Time synchronized

¹ batched

² <http://www.everytrail.com>

³ <http://www.bikely.com>

استفاده می‌کنند. به عنوان مثال در [۹]، با ارائه یک روش پیش‌بینی از سرعت و جهت در تصمیم‌گیری برای حفظ یا حذف نقاط از مجموعه داده استفاده شده است. در الگوریتم پیشنهادی با تعریف منطقه امن به ارزیابی هر یک از نقاط خط سیر پرداخته شده است.

۲-۲- تکنیک‌های فشردن سازی مبتنی بر خطوط سیر معنایی

روش‌های کاهش داده خطوط سیر معنایی با هدف حفظ مناطق توقف و حرکت در مجموعه داده‌ها ارائه شده‌اند. در [۱۰]، یک روش کاهش داده آنلاین بر اساس حفظ نقاط مهم در خط سیر ارائه شده است. این روش روی داده‌های خط سیر کشتی پیاده سازی شده است. در روش پیشنهادی، موقعیت هر کشتی به صورت آنلاین به سرور ارسال می‌شود. سپس سرعت لحظه‌ای هر یک از نقاط به طور تقریبی با کمک نقطه قبل محاسبه می‌شود. در الگوریتم ارائه شده نقاط شاخص در خط سیر به چندین دسته تقسیم می‌شوند. سپس با تعریف سرعت هر یک از نقاط و مقایسه سرعت حاصل با حد آستانه تعریف شده برای هر گروه از نقاط شاخص تعریف شده، الگوریتم به ارزیابی نقاط می‌پردازد. اگر سرعت نقاط خط سیر در هیچ یک از گروه‌های تعریف شده نقاط شاخص نباشد، نقاط از مجموعه داده حذف می‌شوند.

در [۱۱]، دو الگوریتم KiT^4 و PaT^5 برای کاهش داده خط سیر ارائه شده است. در الگوریتم KiT نقاط مهم به ۵ دسته تقسیم می‌شود و نقطه‌ای که در این ۵ دسته قرار نگیرد از خط سیر حذف می‌شود. الگوریتم PaT نیز با خط سیر به صورت پلیگون برخورد می‌کند و ویژگی‌های حرکت با آنالیز ویژگی‌های هندسی پلیگون به دست آید.

در روش‌های ارائه شده در [۱۰، ۱۱] شناسایی نقاط مهم

بهترین انتخاب باشند. الگوریتم بلمن^۱ [۶] از تکنیک برنامه نویسی پویا برای تقریب نقاط در فضای یک بعدی استفاده می‌کند. این الگوریتم می‌تواند برای تقریب خط سیر در فضای دو بعدی نیز تعمیم داده شود. با این حال، از آنجا که این روش یک تابع پیوسته را تقریب می‌زند در کار با حلقه‌ها که در داده‌های خط سیر به وفور دیده می‌شود، دچار مشکل است. از سوی دیگر پیچیدگی زمانی بالای این روش، مشکل بعدی این الگوریتم است.

بسیاری از خدمات مکان مبنا نیاز به بروزرسانی آنلاین داده‌های خط سیر دارند. به عنوان مثال در مدیریت حمل و نقل و نظارت بر ترافیک از تکنیک‌های فشردن سازی آنلاین نمی‌توان به طور مستقیم استفاده کرد. الگوریتم نمونه برداری مخزن^۲ در [۷]، برای پردازش داده‌های خط سیر یک الگوریتم مناسب است. در این روش موقعیت n نقطه ابتدایی به عنوان تقریب خط سیر ذخیره سازی می‌شوند. با اضافه شدن هر نقطه در این روش، الگوریتم با محاسبه یک تابع احتمالی حذف یا حفظ نقطه را مشخص می‌کند.

الگوریتم پنجره متحرک^۳ [۸]، که با هدف داده کاوی سری‌های زمانی ایجاد شده است برای تقریب خط سیر نیز می‌تواند مورد استفاده قرار گیرد. در [۵]، یک روش کاهش داده آنلاین بر اساس الگوریتم پنجره متحرک ارائه شده است. در روش پیشنهادی از هر دو فاصله اقلیدسی قائم و اقلیدسی همزمان برای کاهش داده خط سیر استفاده شده است.

علاوه بر تکنیک‌های کاهش داده آنلاین و آنلاین که از موقعیت نقاط خط سیر برای کاهش داده خط سیر استفاده می‌کنند، گروه دیگر از روش‌ها، از ویژگی‌های دیگر خط سیر نیز در تقریب

¹ Bellman

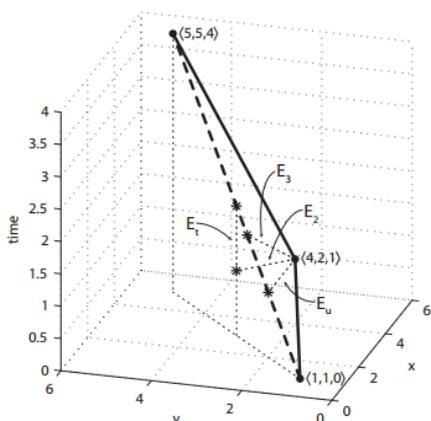
² reservoir

³ Sliding window

⁴ Key-in-Trajectory

⁵ Polygon-as-Trajectory

در مدل PLS استفاده شود. شکل ۴ نمونه‌ای از توابع خطا را نشان می‌دهد، که در ادامه به مرور هر یک از توابع پرداخته می‌شود.



شکل ۴- روابط بین توابع مختلف فاصله [12]

E_2 : این تابع خطا همان تابع استفاده شده در الگوریتم داگلاس - پوکر است که در آن خط سیر به صورت یک خط در فضای دوبعدی تعریف می‌شود و از پارامتر زمان صرف‌نظر می‌شود.

در رابطه ۱، E_2 فاصله قائم نقطه (x_i, y_i) را از (x'_i, y'_i) روی پاره خط واصل دو نقطه ابتدا و انتهای خط سیر یعنی (x_1, y_1) و (x_n, y_n) نشان می‌دهد. همانطور که مشاهده می‌شود استفاده از تابع فاصله E_2 به تنهایی برای فشرده‌سازی خط سیر کافی نیست، چون بعد زمان در این تابع فاصله نادیده گرفته می‌شود.

E_3 : در این تابع خطا، زمان به صورت بعد سوم مکانی تعریف می‌شود.

در رابطه ۲، E_3 فاصله نقطه (x_i, y_i, t_i) از پاره‌خط واصل دو نقطه ابتدا و انتهای خط سیر یعنی (x_i, y_i, t_i) و (x_n, y_n, t_n) در هر تقریب است.

E_u : در این تابع خطا، زمان به صورت بعدی است که به صورت متفاوت عمل می‌کند و درونیابی خطی آن بر اساس زمان روی پاره‌خط انجام می‌شود. این تابع فاصله همان فاصله اقلیدسی همزمان^۲ نام دارد.

در داده‌های خط سیر نیازمند معرفی بازه تعیین کننده هر یک از گروه‌هاست. با این حال، تعیین این بازه برای هر یک از گروه‌ها یک چالش است. از سوی دیگر، در این نوع روش‌های کاهش داده، مقادیر شناسایی شده در هر گروه به مقادیر حد بالا و حد پایین در هر بازه حساس هستند و با وجود کوچکترین اختلاف با مقادیر مرزی ممکن است بسیاری از نقاط به اشتباه از مجموعه داده‌ها کنار گذاشته شوند.

در این مقاله روش کاهش داده‌ای ارائه شده است که از تلفیق دو تابع در فشرده‌سازی استفاده می‌کند. تابع نخست یک تابع بر اساس سرعت نقاط است و تابع دوم نیز توسعه الگوریتم داگلاس-پوکر است. الگوریتم ارائه شده از دو تابع فاصله بازگشتی برای اندازه‌گیری خطای تقریب استفاده می‌کند. به این ترتیب روش ارائه شده مشکلات موجود در روش‌های [۱۰، ۱۱] را که به دلیل دسته‌بندی نقاط و تعیین بازه تعیین کننده نقاط مهم ایجاد شده است، نخواهد داشت. در ادامه مقاله، پس از معرفی مفاهیم اولیه، روش پیشنهادی ارائه می‌گردد.

۳- مبانی نظری تحقیق

تکنیک‌های فشرده‌سازی استاندارد بر اساس ساده‌سازی خطی برای حفظ نقاط مهم در خط سیر کافی نیستند. در مباحث مربوط به خط سیر معنایی، با تمرکز بر مدل توقف-حرکت، نقاط مهم در خط سیر همان مناطق توقف هستند که در آن شیء متحرک در حداقل بازه زمانی تعریف شده بر اساس کاربرد موردنظر در آن منطقه باقی بماند. در این کار فشرده‌سازی بر اساس اصول PLS^۱ توسعه یافته است که در آن برای حفظ مناطق توقف و حرکت، پارامتر سرعت نیز در طول خط سیر در نظر گرفته می‌شود. توابع خطاهای مختلفی می‌تواند

² Synchronized Euclidian distance

¹ Piecewise Linear Segmentation

نشان می‌دهد.

$$E_2((x_i, y_i), (x_1, y_1), (x_n, y_n)) = \|(x_i - x'_i)^2 + (y_i - y'_i)^2\| \quad (۱)$$

$$E_3((x_i, y_i, t_i), (x_1, y_1, t_1), (x_n, y_n, t_n)) = \|(x_i - x'_i)^2 + (y_i - y'_i)^2 + (t_i - t'_i)^2\| \quad (۲)$$

$$SED((x_i, y_i, t_i), (x_1, y_1, t_1), (x_n, y_n, t_n)) = \|(x_i - x'_i)^2 + (y_i - y'_i)^2\| \quad (۳)$$

$$x'_i = x_i + v_{1n}^x \cdot (t_i - t_1), \quad y'_i = y_i + v_{1n}^y \cdot (t_i - t_1) \quad (۴)$$

$$v_{1n}^x = \frac{x_n - x_1}{t_n - t_1}, \quad v_{1n}^y = \frac{y_n - y_1}{t_n - t_1} \quad (۵)$$

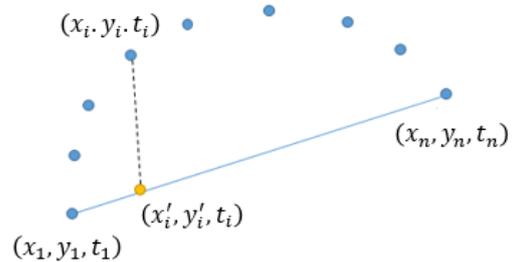
به (x_i, y_i, t_i) است.

واضح است که استفاده از توابع فاصله E_1 و E_2 برای فشرده‌سازی خط سیر کافی نیست، چون به ترتیب بعد زمانی و مکانی نادیده گرفته می‌شود. کاو و همکاران در [۱۳]، به بررسی کاهش داده خط سیر با در نظر گرفتن اثر کاهش داده در پاسخ به پرسش‌های مکانی-زمانی پرداخته‌اند. فشرده‌سازی با استفاده از ساده‌سازی خط از یک تابع فاصله در تولید تقریب خط سیر استفاده می‌کند. در این روش کاهش داده، فاصله خط سیر اصلی از خط سیر تقریبی توسط یک پارامتر به نام حدآستانه خطا محدود می‌شود. با این حال حتی اگر خطای تقریب محدود باشد، خطای پاسخ به پرسش‌ها ممکن است نامحدود باشد. به عبارت دیگر، در جستجو روی خط سیرهای ساده شده، پاسخ‌ها ممکن است در مقایسه با نتایج به‌دست آمده از خط سیر اصلی، انحراف داشته باشد. بنابراین، برای تکنیک‌های کاهش داده خط سیر انحراف معرفی شده بوسیله ساده‌سازی خط باید مدیریت شود.

برای مدیریت خطای پاسخ به پرسش‌های مکانی-زمانی ناشی از ساده‌سازی خط، مفهومی به نام بی‌نقص بودن^۱ معرفی شده است. بی‌نقص بودن به این معنی است که اگر اختلاف پاسخ به پرسش‌های مکانی - زمانی روی خط سیر اصلی و خط سیر ساده‌سازی شده در یک محدوده مشخص باشد، آن تابع فاصله (که برای

شکل ۵ درونیایی خطی بر اساس سرعت ثابت را در فضای مکانی در تابع فاصله اقلیدسی همزمان

روابط ۳ تا ۵ محاسبات تابع خطای اقلیدسی همزمان را نشان می‌دهند. همانطور که مشاهده می‌شود، نقطه (x'_i, y'_i, t_i) ، نقطه همزمان متناظر با (x_i, y_i, t_i) روی پاره‌خط واصل بین ابتدا و انتهای خط سیر یعنی (x_1, y_1, t_1) و (x_n, y_n, t_n) در هر تقریب است. به این ترتیب تابع فاصله اقلیدسی همزمان از هر دو بعد مکانی و زمانی خط سیر در تقریب استفاده می‌کند.



شکل ۵- درونیایی خطی بر اساس سرعت ثابت در تابع فاصله اقلیدسی همزمان [۵]

E_t : این فاصله که کم و بیش دوگان تابع خطای E_u نیز هست، به جای تعیین اختلاف مکانی در زمان‌های یکسان (تعریف E_u)، از اختلاف زمانی در مکان‌های یکسان یا مکان‌های نزدیک به هم استفاده می‌کند. فشرده‌سازی با این تابع خطا کامل نیست چون خطا در بعد مکانی نادیده گرفته می‌شود.

رابطه (۶)

$$E_t((x_i, y_i, t_i), (x_1, y_1, t_1), (x_n, y_n, t_n)) = \sqrt{(t_i - t'_i)^2}$$

در رابطه ۶، t'_i زمان نقطه (x'_i, y'_i) روی نگاشت دوبعدی پاره خط واصل دو نقطه (x_1, y_1, t_1) و (x_n, y_n, t_n) روی صفحه xy است که نزدیک‌ترین نقطه

¹ soundness

۴- روش پیشنهادی

در این تحقیق تمرکز روی حفظ نقاط توقف خط سیر معنایی در مسیر فشرده‌سازی داده‌ها است. روش پیشنهادی این پژوهش E_v-E_2 نامیده شده است. ایده اصلی این است که رفتار توقف- حرکت یک شیء بیشتر در مشتق آن، یعنی در سری‌های زمانی سرعت خط سیر، ظاهر می‌شود:

$$E_v((x_i, y_i, t_i, v_i), (x_1, y_1, t_1, v_1), (x_n, y_n, t_n, v_n)) = \sqrt{(v_i - v'_i)^2} \quad \text{رابطه (۷)}$$

به این ترتیب درونیایی خطی نیز با همین فرض نقطه متناظر را تخمین می‌زند:

$$v'_i = v_1 + a_{1n} \cdot (t_i - t_1) \quad \text{رابطه (۸)}$$

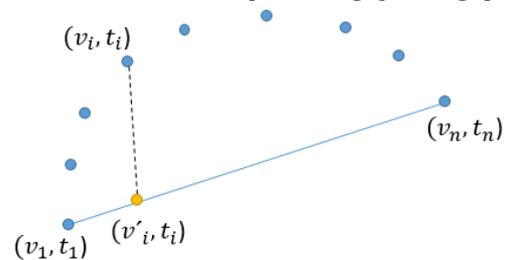
$$a_{1n} = (v_n - v_1) / (t_n - t_1) \quad \text{رابطه (۹)}$$

رابطه ۸، درونیایی خطی سرعت هر یک از نقاط را با فرض ثابت بودن شتاب در تابع E_v نشان می‌دهد و رابطه ۹ معادله محاسبه شتاب بر اساس نقاط ابتدایی و انتهایی خط سیر در هر تکرار برای رسیدن به مقدار بهینه است.

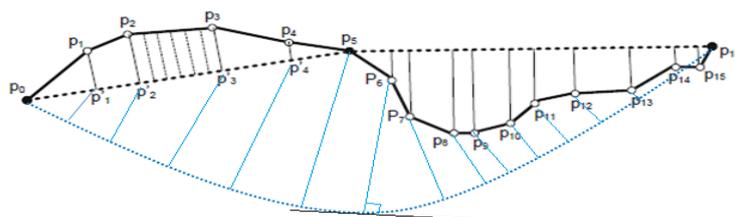
گام دوم در کاهش داده خط سیر با استفاده از الگوریتم E_v-E_2 ، محاسبه فاصله با استفاده از تابع E_2 است. تابع فاصله E_2 از فرض ثابت بودن سرعت در درونیایی استفاده می‌کند. همانطور که اشاره شد، تابع فاصله E_v از فرض شتاب ثابت استفاده می‌کند. بنابراین برای ترکیب این دو تابع، E_2 نیز باید بر اساس ثابت بودن سرعت بازنویسی گردد. به این ترتیب درونیایی در فضای مکانی به جای خط مستقیم تبدیل به سهمی می‌شود (شکل ۷).

ساده‌سازی خط استفاده شده است) برای پرسش مربوطه بی‌نقص است. در [۱۳] نشان داده شده است که استفاده از ترکیب توابع فاصله E_t و E_u برای تمام پرسش‌های مکانی-زمانی روی خط سیر بی‌نقص است. در فشرده‌سازی خط سیر معنایی علاوه بر مفهوم بی‌نقص بودن، حفظ مناطق توقف و حرکت در خط سیر نیز مهم است. بر اساس مطالب بیان شده، روش پیشنهادی در بخش بعد معرفی می‌شود.

در رابطه ۷، E_v تابع فاصله بر اساس سرعت است. در این تابع فاصله، (x'_i, y'_i, t_i, v'_i) نقطه همزمان متناظر با (x_i, y_i, t_i, v_i) روی پاره خط واصل (x_1, y_1, t_1, v_1) و (x_n, y_n, t_n, v_n) است. اما فشرده‌سازی صرفاً بر اساس سرعت کامل نیست. در این کار یک الگوریتم دو مرحله‌ای به نام E_v-E_2 ارائه شده است، که در مرحله اول از تابع فاصله E_v و در مرحله دوم از تابع E_2 برای اندازه‌گیری خطا استفاده می‌کند. در تابع خطا E_v هدف یافتن نقطه همزمان متناظر با (x_i, y_i, t_i, v_i) یعنی (x'_i, y'_i, t_i, v'_i) است و از فرض ثابت بودن شتاب بین ابتدا و انتهای خط سیر استفاده می‌کند. شکل ۶ درونیایی خطی بر اساس سرعت را در فضای سرعت-زمان را نشان می‌دهد. در این درونیایی، شیب خط واصل نقاط همان شتاب حرکت است. در درونیایی در تابع سرعت از فرض ثابت بودن شتاب حرکت استفاده شده است.



شکل ۶- درونیایی خطی تابع فاصله E_v بر اساس شتاب ثابت



شکل ۷- تابع فاصله E_2 ، مقایسه درونیابی با سرعت ثابت و شتاب ثابت

حدآستانه سرعت بر اساس بیشترین فاصله در تقریب اول محاسبه شده است. سپس الگوریتم با مقایسه رابطه بیشترین فاصله با حد آستانه‌های تعیین شده، نقطه مورد نظر را برای تقریب خط سیر ارزیابی می‌کند.

۵- پیاده‌سازی و ارزیابی نتایج

پیاده‌سازی تکنیک‌های فشرده‌سازی روی داده‌های خط سیر پاک‌سازی شده انجام می‌شود. برای این کار، از یک روش سرعت-مبنا برای شناسایی و حذف داده‌های پرت استفاده شده است. به این منظور، سرعت لحظه‌ای نقاط به صورت تقریبی با کمک دو نقطه قبل و بعد محاسبه شده است. سپس از قانون ۳-سیگما برای تعریف حد آستانه سرعت و شناسایی و حذف داده‌های پرت استفاده شده است.

برای پیاده‌سازی، الگوریتم فشرده‌سازی E_v - E_2 از داده‌های خط سیر جئولایف^۱ استفاده شده است [۱۴، ۱۵، ۱۶]. این مجموعه داده شامل ۱۷۶۲۱ خط سیر است که توسط ۱۸۲ کاربر در طول ۵ سال (از آوریل ۲۰۰۷ تا آگوست ۲۰۱۲) جمع‌آوری شده است. داده‌های جمع‌آوری شده توسط دستگاه‌های مجهز به GPS در سیستم مختصات جغرافیایی WGS84 جمع‌آوری می‌شوند. از آنجائیکه در محاسبه تابع فاصله E_v (که گام اول در فشرده‌سازی به روش پیشنهادی است) خط سیر به صورت دنباله‌ای از سرعت نقاط نمایش می‌یابد، تبدیل مختصات از سیستم جغرافیایی به سیستم مختصات کارتزین ضروری است. بنابراین، ابتدا روی داده‌های مورد نظر تبدیل مختصات لازم

نکته دیگری که باید به آن توجه شود، موضوع هم‌مقیاس نبودن دو تابع فاصله E_v و E_2 به منظور مقایسه مقادیر است. ایده استفاده شده در این کار برای هم‌مقیاس کردن دو تابع فوق، تقسیم فواصل خطی تقریب هر یک از توابع به حد آستانه‌های تعریف شده است.

$$\text{رابطه (۱۰)} \quad E_{v_ND} = E_v / Th_{E_v}$$

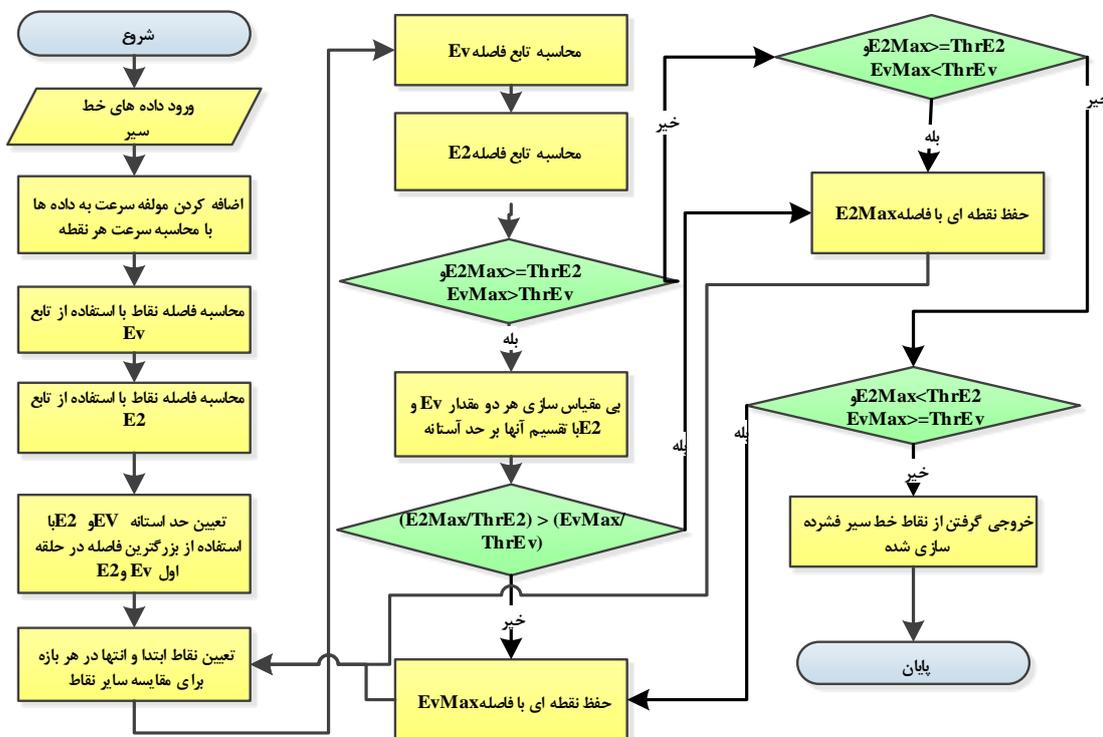
$$\text{رابطه (۱۱)} \quad E_{2_ND} = E_2 / Th_{E_2}$$

در رابطه ۱۰، E_{v_ND} مقدار بدون واحد تابع فاصله E_v است و Th_{E_v} حد آستانه تعریف شده در تابع فاصله E_v برای شناسایی نقطه با بزرگترین فاصله در هر تقریب است. به همین ترتیب در رابطه ۱۱، E_{2_ND} مقدار بدون واحد E_2 است و Th_{E_2} حد آستانه تعریف شده در تابع فاصله E_2 برای شناسایی نقطه با بزرگترین فاصله در هر تقریب است.

فرآیند فشرده‌سازی با استفاده از تابع E_v - E_2 در شکل ۸ نشان داده شده است. همانگونه که مشاهده می‌شود، ابتدا داده‌های خط سیر ورودی که به صورت لیستی منظم از نقاط به شکل (x, y, t) وارد فرآیند محاسباتی می‌شود. سپس فاصله هر یک از نقاط خط سیر از اولین تقریب یعنی خط واصل نقاط ابتدا و انتهای خط سیر با تابع E_v محاسبه می‌شود. این محاسبات با فرض استفاده از تابع E_2 نیز برای نقاط خط سیر انجام می‌شود. به این ترتیب فاصله هر یک از نقاط از سهمی ایجاد شده به واسطه ابتدا و انتهای نقاط، محاسبه می‌شود. با محاسبه فاصله نقاط با دو تابع E_v و E_2 بزرگترین فاصله برای مقایسه با حد آستانه تعیین شده و تصمیم‌گیری برای حفظ یا حذف نقطه مورد نظر، انجام می‌شود. در این تحقیق تعیین

¹ GeoLife

انجام گرفت تا داده‌ها از سیستم مختصات طول و عرض جغرافیایی به سیستم مختصات کارتزین تبدیل شوند.



شکل ۸- فرآیند فشردن سازی با استفاده از تابع Ev_E2

با الگوریتم داگلاس-پوکر نشان می‌دهد. در این شکل، محور قائم بیانگر نرخ فشردن سازی و محور افقی تنظیمات مختلف مقادیر حد آستانه تعریف شده را بر اساس بیشترین فاصله نشان می‌دهد. همانطور که مشاهده می‌شود، نرخ فشردن سازی الگوریتم Ev_E2 نسبت به الگوریتم داگلاس-پوکر بیشتر است. با توجه به اینکه الگوریتم Ev_E2 یک الگوریتم ترکیبی است، نقاط حفظ شده بیشتر، اغلب نقاطی هستند که تابع Ev بر اساس فاصله در فضای سرعت-زمان آن‌ها را به‌عنوان نقاط مهم شناسایی و حفظ کرده‌است. بنابراین حفظ مناطق توقف در خط سیر به بهای افزایش نرخ فشردن سازی است. پارامتر دیگر برای ارزیابی دقت یک الگوریتم فشردن سازی پیچیدگی زمانی است. در بدترین حالت، زمان اجرای فشردن سازی با الگوریتم‌های ساده سازی خطی استاندارد (به عنوان مثال الگوریتم داگلاس-پوکر) $O(n^2)$ است. الگوریتم Ev_E2 نیز دارای

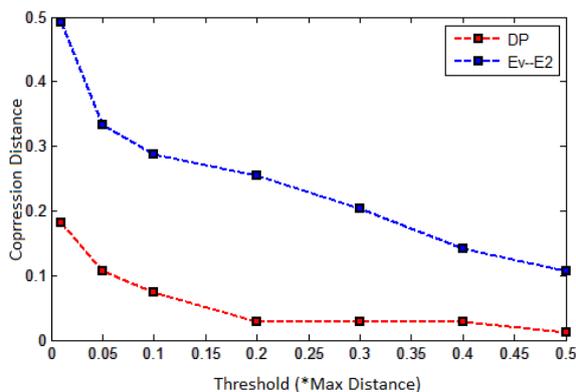
با پاکسازی داده‌ها از خطا و انجام تبدیلات لازم روی مختصات ورودی، الگوریتم پیشنهادی روی داده‌های خط سیر پیاده‌سازی شد. نتایج به دست آمده حاکی از موفقیت الگوریتم در کاهش تعداد نقاط، همزمان با حفظ مناطق توقف در خط سیر است. ارزیابی الگوریتم‌های فشردن سازی بر اساس پارامترهای مختلف می‌تواند انجام شود. یکی از معیارهای ارزیابی، نرخ فشردن سازی است. نرخ فشردن سازی برابر با نسبت تعداد نقاط حفظ شده حاصل از پیاده‌سازی الگوریتم فشردن سازی به تعداد کل نقاط در خط سیر است. الگوریتم فشردن سازی Ev_E2 با هدف حفظ مناطق توقف در خط سیر اجرا و پیاده‌سازی شده است. از این رو تعداد نقاط حفظ شده به مراتب از الگوریتم‌های فشردن سازی معمولی که بر اساس ساده‌سازی خطی هستند بیشتر است. شکل ۹ نرخ فشردن سازی روش پیشنهادی را در مقایسه

مورد توجه محققان این حوزه بوده است. در فرآیند غنی سازی معنایی خط سیرهای مکانی یک گام مهم در مدیریت داده ها، کاهش تعداد نقاط با حفظ دقت مورد نیاز برای آنالیزهای مختلف است. با این حال اغلب تکنیک های کاهش داده بر اساس ماهیت مکانی زمانی خط سیر هستند و تمرکز روش های ارائه شده که اغلب بر اساس ساده سازی خطی هستند، حفظ نقاطی از خط سیر است که قادر به نمایش انحراف شی متحرک از مسیر حرکت می باشد. در مفاهیم مربوط به خط سیر معنایی، مسیر شی متحرک به صورت دنباله ای از مناطق توقف و حرکت نمایش می یابد. با این حال اغلب تکنیک های کاهش داده خط سیر قادر به حفظ مناطق و توقف نیستند.

در این مقاله یک روش کاهش داده خط سیر بر اساس سرعت نقاط پیشنهاد شده است که در آن تابع فاصله خط سیر مکانی-زمانی را به شکل یک سری زمانی از سرعت نقاط در نظر می گیرد. روش پیشنهادی که از ترکیب دو تابع فاصله E_2 و E_v برای تقریب استفاده کرده است، هدف حفظ نقاطی از خط سیر است که در فضای سرعت زمان بیشترین انحراف را از تقریب داشته باشد. از سوی دیگر نقاط با بیشترین انحراف در فضای مکانی-زمانی نیز به عنوان نقاط مهم در خط سیر حفظ می شوند.

روش پیشنهادی روی داده های خط سیر واقعی پیاده سازی شده است. نتایج به دست آمده از اجرای الگوریتم حاکی از فشردن سازی مؤثر داده های حرکت با حفظ مناطق و توقف در خط سیر است. با این حال این امر منجر به افزایش نرخ فشردن سازی و به دنبال آن افزایش پردازش های بعدی روی داده های خط سیر است. در فرآیند فشردن سازی خط سیر، نقاط با بیشینه و کمینه سرعت در فضای سرعت-زمان با تابع فاصله E_v و نقاط با بیشترین انحراف در فضای مکانی با تابع فاصله E_2 در خط سیر به عنوان نقاط مهم حفظ می شوند و از نقاط دیگر صرف نظر می شود.

همین پیچیدگی است. در واقع، اساساً الگوریتم Ev_E2 دو بار از الگوریتم های PLS استفاده کرده است.

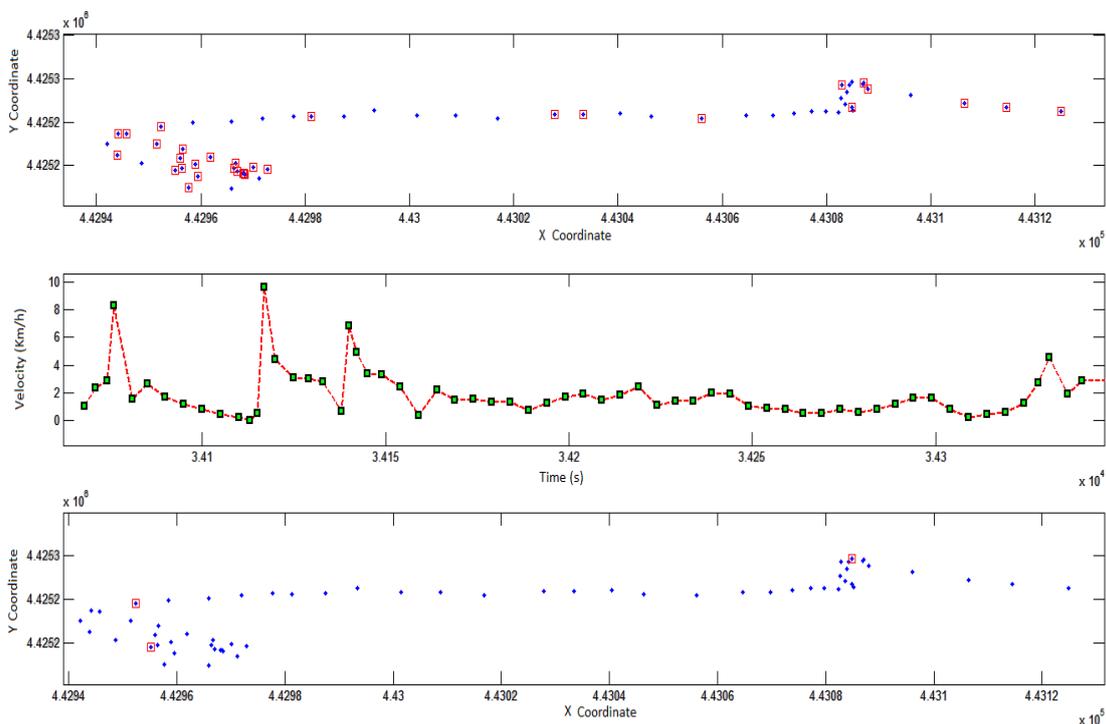


شکل ۹- مقایسه نرخ فشردن سازی روش داگلاس-پوکر (خط چین قرمز) و روش پیشنهادی (خط چین آبی)

شکل ۱۰ نمونه ای از خط سیر فشردن سازی شده را نشان می دهد. در شکل ۱۰ (بالا) خط سیر فشردن سازی شده با الگوریتم پیشنهادی و در شکل ۱۰ (پایین) خط سیر فشردن سازی شده با الگوریتم داگلاس-پوکر نشان داده شده است. در این شکل نقاط حفظ شده توسط دو الگوریتم با مربع قرمز نشان داده شده اند. همانطور که مشاهده می شود، مناطق توقف در خط سیر که اغلب به صورت تراکم مکانی نقاط دیده می شود، در الگوریتم پیشنهادی در مقایسه با الگوریتم داگلاس-پوکر به نحو مؤثرتری حفظ شده است. این نقاط مناطقی از خط سیر هستند که در آن شی متحرک سرعت خود را کاهش داده است (شکل ۱۰ (وسط)). علاوه بر حفظ نقاط با سرعت پایین الگوریتم مناطقی از خط سیر که در آن شی متحرک با سرعت بیشتر از میانگین حرکت کرده است را حفظ کرده که علت آن فاصله بیشتر این نقاط از تقریب خط سیر است.

۶- جمع بندی و نتیجه گیری

با تولید روزافزون داده های حرکت توسط دستگاه های تعیین موقعیت، حجم عظیمی از داده های مکانی زمانی خط سیر تولید شده است. در مطالعات مربوط به خط سیر مفهوم خط سیر معنایی در چند سال اخیر



شکل ۱۰- مقایسه نتایج الگوریتم پیشنهادی (بالا)، نمودار سرعت نقاط (وسط) و نتایج حاصل از الگوریتم داگلاس پوکر (پایین)

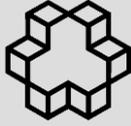
سیر انجام می‌شود. به این ترتیب نتایج حاصل از این تحقیق به صورت مستقل از نوع داده‌های جمع‌آوری شده می‌تواند در تحلیل خطوط سیر معنایی مورد استفاده قرار گیرد.

الگوریتم‌های فشرده‌سازی با هدف کاهش حجم نقاط با حفظ دقت مورد نیاز برای تحلیل‌های مختلف روی داده‌ها اجرا می‌شوند. زمانی که هدف از تحلیل داده‌های خط سیر انجام آنالیزهای معنایی است، فرآیند فشرده‌سازی نقاط با رویکرد حفظ مناطق توقف در خط

مراجع

- [1] Alvares, L. O., Oliveira, G., Heuser, C. A., and Bogorny, V., "A Framework for Trajectory Data Preprocessing for Data Mining," in Conf. on Software Engineering and Knowledge Engineering, 2009.
- [2] Pelekis, N., Theodoridis, Y., Janssens, D., "On the Management and Analysis of Our LifeSteps," ACM SIGKDD Explorations Newsletter, vol. 15, no. 1, pp. 23-32, 2013.
- [3] Zheng, Y., , Zhou, X., Computing with Spatial Trajectories, New York: Springer-Verlag New York, 2011.
- [4] Douglas, D., Peucker, T., "Algorithms for the Reduction of the Number of Points Required to Represent a Line or its Caricature," Cartographica, vol. 10, no. 2, pp. 112-122, 1973.
- [5] Maratnia, N., de By, R., "patio-Temporal Compression Techniques for Moving Point Objects," in International Conference on Extending Database Technology (EDBT), 2004.
- [6] R. Bellman, "On the Approximation of Curves by Line Segments Using Dynamic Programming," Communications of the ACM, vol. 4, no. 6, 1961.

- [7] J. Vitter, "Random sampling with a reservoir," ACM Transactions on Mathematical Software(TOMS), vol. 11, no. 1, 1985.
- [8] Keogh, E., Chu, S., Hart, D., Pazzani, M., "An On-Line Algorithm for Segmenting Time Series," in International Conference on Data Mining (ICDM), 2001.
- [9] Potamias, M., Patrourmpas, K., Sellis, T., "Sampling Trajectory Streams with Spatio-Temporal Criteria," in In: International Conference on Scientific and Statistical Database Management (SSDBM), 2006.
- [10] K. Patrourmpas, "Online tracking and summarization over streaming maritime trajectories," in Workshop on Moving Objects at Sea, 2013.
- [11] W. Ting, "SOMETIMES TOO BIG: COMPRESSING TRAJECTORY DATA," in PACIS 2014 Proceedings, 2014.
- [12] de Vries, G. K. D. and Someren, M., "Machine learning for vessel trajectories using compression, alignments and domain knowledge," ELSEVIER, vol. 39, no. 18, p. 13426–13439, 2012.
- [13] Cao, H., Wolfson, O. and Trajcevski, G., "Spatio-temporal data reduction with deterministic error bounds," The VLDB Journal — The International Journal on Very Large Data Bases , vol. 15, no. 3, pp. 211-228, 2006.
- [14] Zheng, Y., Zhang, L., Xie, X., & Ma, W. Y., "Mining interesting locations and travel sequences from GPS trajectories," in In Proceedings of the 18th international conference on World wide, Madrid Spain, 2009.
- [15] Zheng, Y., Li, Q., Chen, Y., Xie, X., & Ma, W. Y., "Understanding mobility based on GPS data," in In Proceedings of the 10th international conference on Ubiquitous computing, Seoul, Korea, 2008.
- [16] Zheng, Y., Xie, X., & Ma, W. Y., "GeoLife: A Collaborative Social Networking Service among User, location and trajectory," in IEEE Data Engineering Bulletin, 2010.



An algorithm for compression of a spatio-temporal trajectory preserving its semantic nature

Somaie Aghel Shahneshin¹, Simin Sadat Mirvahabi¹, Rahim Ali Abbaspor^{*2}

1- MSc student, School of Surveying and Geospatial Information Engineering, College of Engineering, University of Tehran

2- Assistant professor, School of Surveying and Geospatial Information Engineering, College of Engineering, University of Tehran

Abstract

A common way to store information of spatio-temporal moving objects is to display the path of the objects as the form of a three-dimensional trajectory using the geographic location and time. In recent years, extensive research has been done on the trajectories. These studies have focused mainly on geometric aspects of trajectories. However, semantic trajectory is a relatively new concept that has been developed with the purpose of effective semantic analysis on captured data. In semantic trajectory, which is a secondary display of geometric trajectory, the movement of object is described as series of stop-and-move. Production of semantic trajectory from the collected raw data is a process with several steps. Due to the huge amount of data, one of the important processes is reducing the number of points of trajectory with maintaining the required accuracy by using compression techniques. However, data reduction techniques commonly are based on linear simplification and are not able to protect stop and move of trajectories. In this paper, a data reduction technique is presented which is based on combination of two distance functions for approximation of semantic trajectory. The first distance function has used speed of points to calculate the approximation error of trajectories. The second function is based on the development of well-known Douglas-Peucker algorithm, which assumes constant acceleration to calculate the approximation error. The proposed algorithm is implemented on real trajectory data and the results show improved performance compared with other algorithms in preservation of the stop and move of trajectories.

Key words: Semantic Trajectory, compression, Stop-Move Model, E_v - E_2