

توصیه‌کننده مکانی در شبکه‌های اجتماعی



مکان‌مبنا مبتنی بر یادگیری عمیق

محمد راستگو^۱، حمیدرضا غفاری^{۲*}

دانشجوی دکتری دانشکده مهندسی کامپیوتر، واحد فردوس، دانشگاه آزاد اسلامی، فردوس، ایران^۱

استادیار دانشکده مهندسی کامپیوتر، واحد فردوس، دانشگاه آزاد اسلامی، فردوس، ایران^{۲*}

چکیده

پتانسیل شبکه‌های اجتماعی برای استخراج آمار و اطلاعات در مورد رفتار کاربران مورد توجه بسیاری از پژوهش‌گران قرار گرفته‌است. با توسعه و محبوبیت این شبکه‌ها، بسیاری از انسان‌ها ترجیح می‌دهند تجربیات خود را به اشتراک بگذارند. با جمع‌آوری داده‌های رفتاری کاربران، فرصت‌های منحصر به فردی برای درک الگوهای حرکتی و پیش‌بینی رفتار مکانی آن‌ها ایجاد می‌شود. یک نمونه از شبکه‌های اجتماعی مبتنی بر مکان Foursquare است. در این شبکه‌ها محتوای تولیدشده توسط کاربر در موقعیت مکانی ثبت می‌شود و مکان‌های جدید را به کاربران توصیه می‌کند. این شبکه‌ها امکان ثبت و اشتراک‌گذاری موقعیت مکانی کاربران را فراهم می‌کنند. این سکوها حجم عظیمی از داده‌های رفتاری را تولید می‌کنند که می‌توان برای درک الگوهای حرکتی و پیش‌بینی رفتار آینده کاربران استفاده کرد. این موضوع کمک شایانی در زمینه کسب‌وکارها و خدمت به امور جهانگردی دارد. برای بهبود دقت پیش‌بینی مکان بعدی در ابتدا نیاز است دوستان و یا افرادی که بیشترین نقاط مشترک را با هم دارند شناسایی شوند؛ بنابراین عواملی شامل تأثیر دوستان، تاریخچه بازدیدها و ویژگی‌های زمانی - مکانی در پیش‌بینی انتخاب مکان بعدی کاربر نقش بسزایی دارد؛ لذا اهمیت در نظر گرفتن ویژگی‌های زمانی در فرایند پیش‌بینی بسیار مهم است. روش پیشنهادی دقت روش‌های یادگیری ماشین و شبکه‌های عصبی بازگشتی را برای پیش‌بینی مکان بعدی کاربران مورد بررسی قرار داده‌است. در این مقاله با استفاده از الگوریتم Random Forest داده‌ها مورد بررسی قرار گرفته‌اند تا نقش داده‌ها در دسته‌بندی مشخص شود؛ سپس با استفاده از شبکه‌های عصبی بازگشتی LSTM، RNN و GRU عمل پیش‌بینی عملکرد کاربران مورد ارزیابی واقع شد. در این راستا شبکه عصبی بازگشتی LSTM با دقت ۷۱ درصد در میان شبکه‌های عصبی بازگشتی بیشترین دقت را داشته است. این پژوهش نشان می‌دهد که ترکیب هوش مصنوعی و داده‌های مکانی - زمانی می‌تواند درک عمیقی از رفتارهای انسانی در فضاهای شهری و رقمی ارائه دهد.

واژگان کلیدی: شبکه‌های اجتماعی مکان‌مبنا، سامانه‌های توصیه‌گر، داده‌کاوی مکانی.

A location recommender in social networks based on location based on deep learning

Mohammad Rastgoo¹, Hamid Reza Ghaffari^{2*}

Phd student of Computer Engineering Faculty, Ferdous Branch,
Islamic Azad University, Ferdous, Iran¹

Assistant Professor, Faculty of Computer Engineering, Ferdous Branch,
Islamic Azad University, Ferdous, Iran^{2*}

Abstract

The potential of social networks to extract valuable insights into user behavior has become a focal point of research. With the proliferation of social media platforms, people are increasingly sharing their experiences online. This wealth of user-generated data provides unique opportunities to understand movement patterns and predict future behavior. Location-based social networks like Foursquare exemplify this, allowing users to check in at various locations and enabling researchers to analyze these data points. By analyzing the data collected from these platforms, we can uncover patterns in user

* Corresponding author

* نویسنده عهده‌دار مکاتبات

behavior, such as frequently visited locations and the factors influencing these choices. This information can be invaluable for businesses and urban planners. To improve the accuracy of predicting a user's next location, this study focuses on identifying the most influential friends or individuals in a user's social network. Factors such as the strength of these relationships, historical visit data, and temporal-spatial characteristics are considered. Additionally, the study emphasizes the importance of data quality, focusing on locations that have been visited more than 100 times to ensure reliability.

A key aspect of this research is understanding the influence of social connections on individual behavior. By analyzing the overlap in visited locations between friends, the study aims to identify the most influential friends for each user. These influential friends are then used to predict the user's next location.

The proposed method employs machine learning techniques, specifically RandomForest and recurrent neural networks (LSTM, RNN, and GRU), to predict user behavior. RandomForest is used to analyze the data and identify the most significant features, while recurrent neural networks are employed to model the sequential nature of user behavior. Among these, LSTM achieved the highest accuracy of 71% in predicting users' next locations. This research demonstrates that combining artificial intelligence with spatial-temporal data can provide profound insights into human behavior in urban and digital environments. By understanding these patterns, businesses can tailor their offerings to individual customers, and urban planners can design more efficient and user-friendly cities.


Keywords: Location-based social networks, recommender systems, spatial data mining.

۱- مقدمه

فناوری اطلاعات در چند دهه اخیر امکان ایجاد ارتباطات اجتماعی بر روی بستر وب را فراهم کرده است که یکی از نتایج آن به وجود آمدن شبکه‌های اجتماعی تحت وب است. گسترش شبکه‌های اجتماعی بر خط این اجازه را به کاربران می‌دهد که بتوانند پست‌ها و تصاویر خود را با دوستانشان به اشتراک بگذارند. در این خصوص، کاربران به‌طور معمول تمایل دارند موارد بیشتری را به اشتراک بگذارند؛ همچنین بداند دوستانشان چه کاری انجام می‌دهند، کجا هستند و چه کسانی همراه آن‌هاست؛ لذا یکی از سرویس‌هایی که در بین کاربران تلفن‌های همراه هوشمند با استقبال زیادی روبه‌رو شده است، سرویس‌های مکان‌مبنا در شبکه‌های اجتماعی است. در این سرویس‌ها افراد می‌توانند تصاویر و یا پست‌های خود را با دیگران به اشتراک بگذارند؛ همچنین مجهز شدن دستگاه‌های تلفن همراه به فناوری‌های مکان‌یابی مانند GPS و ارتباطات بی‌سیم همانند Wi-Fi این امکان را به وجود آورده است که افراد بتوانند موقعیت‌ها و مسیرهای خود را ذخیره کنند و بر روی بستر اینترنت منتشر سازند. با ایجاد این فناوری، کاربران می‌توانند داده‌های مکانی خود، مانند عکس‌ها یا یادداشت‌هایی را که برچسب مکانی دارند، در شبکه‌های اجتماعی به اشتراک بگذارند. این شبکه‌ها، شبکه‌های اجتماعی مکان‌مبنا نامیده می‌شوند. توصیه مکان، یکی از سرویس‌های محبوب برای شبکه‌های اجتماعی مکان‌مبنا است. این سرویس بر اساس پیشینه رفتار کاربر و اطلاعات مکان، مکان‌های بازدید نشده را به کاربران پیشنهاد می‌دهد.

در حال حاضر برخی از سرویس‌های مکان‌مبنا مانند Gowalla و Foursquare ظهور یافته‌اند؛ این سرویس‌ها به

کاربران اجازه می‌دهند پیشینه مکانی خود از بازدیدهای انجام‌شده را در سامانه ثبت کنند. کاربران این سرویس‌ها تمایل دارند نکات و تجربیات مکانی بازدیدهای خود، از مکان‌های مختلف از جمله رستوران‌ها، فروشگاه‌ها، جاذبه‌های گردشگری و غیره را با دیگران به اشتراک گذارند؛ بنابراین در زندگی روزمره هر فرد تلاش می‌کند افرادی را که علایق مشابهی به او دارند پیدا کرده و در انتخاب‌های خود از آن‌ها کمک بگیرد. سامانه توصیه‌گر این فرایند را با افزایش آگاهی کاربر، برای انتخاب بهترین گزینه در بین گزینه‌های پیش‌رو با در نظر گرفتن علایق و ترجیحات کاربر انجام می‌دهد. سامانه اطلاعات مکانی به‌عنوان یک سامانه توصیه‌گر مکان‌مبنا که با انواع وضعیت‌های تصمیم‌گیری سازگار است، می‌تواند در تصمیم‌گیری برای یافتن بهترین مکان به کاربر کمک کند. حال اصطلاحی که باید به آن پرداخته شود، داده‌های ثبت موقعیت است. این داده‌ها، داده‌هایی هستند که نشان می‌دهد هر کاربر در چه زمانی و در چه مکانی بوده است؛ به عبارت دیگر این داده‌ها شامل سه مؤلفه کاربر، مکان و زمان است؛ از این‌رو توصیه مکان یک سرویس محبوب برای شبکه‌های اجتماعی مکان‌مبنا است که بر اساس پیشینه رفتار کاربر و اطلاعات مکان، مکان‌های بازدید نشده را به کاربران پیشنهاد می‌دهد. چگونگی توصیه مکان‌های جدید به کاربران در شبکه‌های اجتماعی مکان‌مبنا به یکی از چالش‌های جدید در حوزه دانشگاه و صنعت تبدیل شده است. این موضوع به تازگی توجه بسیاری از پژوهش‌گران را به خود جلب کرده است.



(شکل-۱): ارتباطات اجتماعی در شبکه مکان‌مبنا
(Figure-1): Social communication in the location-based network

داده‌کاوی ۱، به‌عنوان یک ابزاری قدرتمند برای استخراج خودکار اطلاعات ضمنی و بالقوه از داده‌هاست که به‌طور فزاینده‌ای در زمینه تجاری، علمی و سایر زمینه‌ها مورد استفاده قرار می‌گیرد. داده‌کاوی فرایندی است که وظیفه کشف الگوها را در مجموعه داده‌های بزرگ برعهده دارد. این دانش شامل تجزیه، تحلیل و خلاصه‌کردن داده‌ها از دیدگاه‌های مختلف و استخراج خودکار اطلاعات مفید است. داده‌کاوی روندها، الگوها و سایر اطلاعات پنهان‌شده در حجم عظیمی از داده‌ها را نشان می‌دهد که امروزه از آن در زمینه‌های تجاری، پزشکی، علمی، جغرافیایی، هواشناسی و علوم مختلف استفاده می‌شود.

۲-پیشینه پژوهش

شبکه‌های اجتماعی مکان‌مبنا، نوعی از شبکه‌های اجتماعی است که در آن خدمات و قابلیت‌های مکانی مانند مختصات جغرافیایی و برچسب‌گذاری مکانی تعریف شده‌است. ژانگ^۲ در سال ۲۰۱۱ [۱] مفهوم شبکه‌های اجتماعی مکان‌مبنا را کلی‌تر به صورت زیر بیان کرده‌است.

شبکه اجتماعی مکان‌مبنا تنها به معنی اضافه‌کردن یک موقعیت مکانی به شبکه‌های اجتماعی موجود نیست؛ بلکه منظور ایجاد یک ساختار اجتماعی جدید متشکل از افرادی است که بر اساس اشتراک رفتار مکانی در دنیای فیزیکی با هم در ارتباط‌اند؛ علاوه بر این، ارتباطات ایجادشده در شبکه اجتماعی مکان‌مبنا، تنها بر اساس اینکه دو نفر هم‌زمان در یک مکان باشند و پیشینه مکانی مشابهی داشته باشند، محدود نمی‌شوند؛ بلکه بر مبنای اطلاعات مکانی کاربران، رفتارها و فعالیت‌های مشابه آن‌ها استنباط شده و ساختار ارتباطی جدید بر این اساس شکل خواهد گرفت.

تشخیص ساختارهای ارتباطی و جوامع، با استفاده از الگوریتم جست‌وجوی هماهنگی مبحث مهمی است. در این مقاله [۲۵] برای ساخت خوش‌های شبکه بر اساس

^۱ Data Mining

^۲ Zheng

گراف شبکه و تشخیص ارتباطات مؤثر بر اساس معیارهای مختلف، روش جدیدی پیشنهاد شد. این روش جدید درواقع نسخه گسسته‌ای از الگوریتم جست‌وجوی هماهنگی است که برای کشف جوامع و ساختارهای ارتباطی در شبکه‌های اجتماعی به کار می‌رود.

کاربر و مکان دو موضوع مهم در یک شبکه اجتماعی مکان‌مبنا هستند که ارتباط نزدیکی با هم دارند. همان‌طور که در شکل (۱) مشاهده می‌شود، کاربران برخی مکان‌ها را بازدید می‌کنند و در بازدید بدون در نظر گرفتن پیشینه مکانی خود، محتوای جدیدی با برچسب مکانی ایجاد می‌کنند. اگر این مکان‌ها با توجه به زمان آن‌ها به هم وصل شوند، یک مسیر برای هر کاربر به‌دست می‌آید. بر اساس این مسیرها، می‌توان سه گراف مختلف در شبکه‌های اجتماعی مکان‌مبنا ایجاد کرد که شامل گراف مکان‌مکان، گراف کاربر مکان و گراف کاربر کاربر است.

در گراف مکان‌مکان، یک گره نشان‌دهنده یک مکان است و یک یال جهت‌دار مسیر را مشخص می‌کند. در این نوع گراف، یک کاربر که دو مکان را به صورت متوالی بازدید کرده‌است، نشان داده می‌شود. در این گراف وزنی که به هر یک از یال‌ها اختصاص داده شده‌است به‌عنوان هم‌بستگی بین آن دو مکان است. در گراف کاربر مکان دو نوع گره وجود دارد. گره‌ها به نام‌های کاربر و مکان است. یک یال از یک کاربر شروع شده و به یک مکان ختم می‌شود و نشان‌دهنده این است که کاربر از آن مکان بازدید کرده‌است. وزن یال‌ها نشان‌دهنده تعداد بازدیدها از آن مکان است. در گراف کاربر کاربر، یک گره نشان‌دهنده یک کاربر و یک یال بین گره‌هاست. این گراف نشان‌دهنده روابط بین کاربران است. دو رابطه در این گراف وجود دارد. رابطه اول رابطه اصلی بین دو کاربر در شبکه اجتماعی است و رابطه دیگر رابطه جدیدی است که با توجه به مکان‌هایی که کاربر بازدید کرده‌است به‌دست می‌آید؛ بنابراین اگر دو کاربر، مکان یکسانی و یا انواع مشابهی از مکان‌ها را بازدید کنند، ممکن است با هم ارتباط برقرار کنند. ارتباط دوم از پیشینه به‌دست می‌آید که می‌تواند در یک روش توصیه استفاده شود. به عبارت دیگر می‌توان کاربران را بر اساس ارتباط مکانی آن‌ها که از پیشینه مکانی‌شان استنباط می‌شود به دیگر کاربران توصیه کرد. زمانی که فرد برای نخستین بار توصیه‌ای را می‌پذیرد، ارتباط از نوع دوم به نوع اول تبدیل می‌شود.

یک ثبت موقعیت نشان می‌دهد که کاربر در چه زمانی و در چه مکانی بوده‌است. یک ثبت موقعیت را می‌توان به صورت زیر تعریف کرد:

$$C=(u,l,t)$$

(۱)

در معادله (1)، C ثابت موقعیتی است که ارتباط یک کاربر u و مکان l را در زمان t نشان می‌دهد [2]. بر اساس تعریف ثابت موقعیت، یک ثابت موقعیت یک رده‌بندی ضمنی در نظر گرفته می‌شود. یک رده‌بندی ضمنی، ارتباط و ترجیح کاربر را می‌رساند. نوع دیگری از رده‌بندی، رده‌بندی مستقیم یا صریح است. به این صورت که کاربر ترجیحات خود را نسبت به یک آیتم مستقیم و با استفاده از مقادیر رده‌بندی نشان می‌دهد؛ برای مثالی از این نوع رده‌بندی یک کاربر در Netflix است که امتیاز به فیلم‌ها می‌دهد و یا بر اساس مکان لحظه‌ای کاربر در یک سامانه راهنمای گشت همراه، توصیه مکان را ارائه می‌دهد [3 و 4]. پارک^۱ و همکاران یک سامانه توصیه شخصی را ارائه می‌دهد که ترجیحات کاربر را بر اساس مدل شبکه بیزین ارائه می‌دهد [5]؛ با این حال هیچ یک از پژوهش‌های بالا در مورد رفتار ثابت موقعیت افراد با توجه به فاصله مکان ثابت موقعیت کاربر تا خانه او را در نظر نگرفته‌اند؛ علاوه بر این، آن‌ها از الگوهای زمانی رفتار ثابت موقعیت افراد نیز برای توصیه مکان استفاده نکرده‌اند؛ بنابراین در توصیه مکان، معیار زمان و محدوده مکانی بسیار اهمیت دارد. یک روش توصیه مکان باید محدوده‌های مکانی را نیز در نظر بگیرد. مطالعات اخیر ارتباطات اجتماعی بین کاربران را نیز برای توصیه مکان در شبکه‌های اجتماعی مکان‌مبنا در نظر گرفته‌اند.

عباسی و همکاران [19] در سال 2018 یک مدل یادگیری ماشین برای پیش‌بینی تحرکات انسانی بر روی شبکه اجتماعی Foursquare ارائه دادند. مدل پیشنهادی از الگوریتم LightGBM بهره می‌برد که یک الگوریتم یادگیری ماشین مبتنی بر درخت تصمیم است. نتایج نشان می‌دهد مدل پیشنهادی دقت بالاتری نسبت به مدل‌های پایه در پیش‌بینی مقصد بعدی افراد دارد. میانگین خطای مدل پیشنهادی در حدود چهار کیلومتر بوده است.

در پژوهشی دیگر [20] مدل‌سازی و پیش‌بینی مکان کاربران را در شبکه‌های اجتماعی بزرگ ارائه داده‌اند. در این مقاله مقایسه بین الگوریتم‌های یادگیری ماشین و الگوریتم‌های یادگیری عمیق بر روی مجموعه داده‌های Foursquare و Gowalla انجام شد. الگوریتم‌های LSTM و BiLSTM نتایج خوبی داشته‌اند.

در سال 2014 دو الگوریتم توصیه‌گر به نام‌های PCR و PCLR با استفاده از اطلاعات دسته مکان در داده‌های ثابت موقعیت ارائه شد [2]. در این الگوریتم از تابع توزیع احتمال زمانی برای مد کردن الگوهای دوره‌ای ثابت

موقعیت کاربر استفاده شده است. این الگوریتم دسته مکان را در یک زمان معین و با استفاده از تابع توزیع احتمال زمانی و پیشینه ثابت موقعیت کاربران، به آن‌ها توصیه می‌کند. برای ارزیابی الگوریتم‌های پیشنهادی از دو پارامتر دقت و جامعیت و همچنین از مجموعه داده مربوط به شبکه اجتماعی Gowalla استفاده شد.

روش مناسب برای ایجاد یک سامانه توصیه‌گر، به چالشی برای طراحان تبدیل شده است. در این مقاله [24] روشی مبتنی بر الگوریتم ژنتیک برای اجتماع نتایج روش‌های همسایه‌محور و انتخاب بهترین پیشنهادها از بین پیشنهادهای تولیدشده با روش‌های مختلف با معیارهای فاصله متفاوت، برای یک سامانه توصیه‌گر با هدف پیشنهاد N آیتم برتر ارائه شده است. در پیاده‌سازی این روش‌ها، علاوه بر محاسبه شباهت مستقیم کاربران، تعیین اطمینان استنتاج شده کاربران نیز در نظر گرفته شده است تا اطلاعات موجود از ارتباط بین علایق کاربران افزایش یابد. خدمات مبتنی بر مکان در حال محبوبیت هستند. پیش‌بینی مقاصد آینده و الگوهای حرکت جمعیت اجزای حیاتی این خدمات هستند. مقاله [25] یک مدل رگرسیون شبکه عصبی را ارائه می‌کند که برای پیش‌بینی مختصات مقصد کاربر طراحی شده است. با استفاده از دو مجموعه داده حرکت در دنیای واقعی، داده‌های بررسی شده از مجموعه داده Foursquare است. این مدل از یک شبکه عصبی رمزگذار-رمزگشا برای پیش‌بینی مختصات مقصد کاربر در عرض و طول جغرافیایی استفاده می‌کند. فراتر از قابلیت‌های پیش‌بینی، این پژوهش به پیچیدگی‌های الگوهای حرکت انسان می‌پردازد که به درک عمیق‌تر رفتار حرکت کمک می‌کند.

تحلیل احساسات یکی از رویکردهای امیدوارکننده برای توسعه سامانه توصیه‌گر است که از فن‌های پردازش زبان طبیعی استفاده می‌کند که بینش‌های تخصصی را از محتوای تولیدشده توسط کاربر مانند نظرات و بازخورد استخراج می‌کند. با اعمال تحلیل احساسات (مثبت، منفی یا خنثی) مرتبط با هر مکان، سامانه پیشنهاد مناسب را به کاربر می‌دهد. در مقاله [26] با استفاده از شبکه LSTM برای پیش‌بینی احساسات استفاده شده است. سپس با پیش‌بینی که انجام شده برچسب کلاس‌ها در مجموعه داده Foursquare انجام شد. در ادامه با استفاده از توکن‌های کاربر و مختصات مربوطه بهترین پیشنهاد به کاربران داده می‌شود.

۳- داده‌های مورد مطالعه

مجموعه داده‌ای که در این مقاله استفاده شده است مربوط می‌شود به داده‌های Foursquare که شامل اعلام حضور

¹ Park

کاربران در شهر نیویورک است. این داده‌ها برای حدود ده ماه (از ۱۲ آوریل ۲۰۱۲ تا ۱۶ فوریه ۲۰۱۳) جمع‌آوری شده‌است و شامل ۲۲۷۴۲۸ رکورد است. هر ورودی با زمان و مختصات GPS مرتبط است. این مجموعه داده برای مطالعه نظم مکانی-زمانی فعالیت کاربر در LBSN^۱ ها استفاده می‌شود.

۴-روش پژوهش

در این بخش ابتدا به مبانی نظری برای روش‌های طبقه‌بندی با استفاده از یادگیری ماشین شامل روش الگوریتم جنگل‌های تصادفی و روش‌های شبکه عصبی بازگشتی پرداخته شده‌است و نوع روش پژوهش در پیاده‌سازی مورد ارزیابی قرار می‌گیرد.

۴-۱-الگوریتم جنگل تصادفی


الگوریتم جنگل تصادفی یک الگوریتم محبوب یادگیری ماشین و زیرمجموعه هوش مصنوعی است که به فن یادگیری نظار شده تعلق دارد. این الگوریتم برای حل مشکلات طبقه‌بندی و رگرسیون در یادگیری ماشین استفاده می‌شود. الگوریتم جنگل تصادفی مبتنی بر مفهوم یادگیری گروه است و با استفاده از یک فرایند ترکیب‌چندین طبقه‌بند برای حل یک مسئله پیچیده و بهبود عملکرد مدل استفاده می‌شود. همان طور که از نام این الگوریتم پیداست، الگوریتم جنگل تصادفی یک طبقه‌بندی است که شامل تعدادی درخت تصمیم در زیرمجموعه‌های مختلف مجموعه داده قرار دارد و برای بهبود دقت پیش‌بینی آن مجموعه داده میانگین می‌گیرد. جنگل تصادفی به جای تکیه بر یک درخت تصمیم، پیش‌بینی را از هر درخت و بر اساس بیشترین آرا پیش‌بینی می‌کند و نتیجه نهایی را به عنوان خروجی در نظر می‌گیرد. تعداد بیشتر درختان در جنگل منجر به دقت بالاتری می‌شود و از بروز مشکل Overfitting جلوگیری می‌کند. در گام نخست ایجاد جنگل تصادفی با ترکیب N درخت تصمیم انجام می‌شود. در گام دوم پیش‌بینی برای هر درخت ایجاد شده در گام نخست به دست می‌آید.

۴-۲-شبکه عصبی بازگشتی

یادگیری عمیق یکی از زیرشاخه‌های یادگیری ماشین مبتنی بر شبکه‌های عصبی است. در یادگیری عمیق به منظور کشف ساختارهای پیچیده از چندین لایه یادگیری استفاده می‌شود [۷] یکی از نمونه‌های اصلی و

بر کاربرد روش‌های یادگیری عمیق، شبکه‌های عصبی بازگشتی^۲ هستند. شبکه‌های عصبی بازگشتی توانایی بالایی در پردازش داده‌ها با ساختار توالی^۳ دارد. داده‌ها به صورت توالی (گام به گام) به وسیله شبکه طی شده و در هر مرحله حالت شبکه نسبت به مراحل قبلی در حافظه نورون وجود دارد؛ به این ترتیب این نوع شبکه‌ها می‌توانند با بهره‌گیری از ساختار پویا، به طور کامل ساختار داده‌ها را طی کنند [۸]. با ظهور یادگیری عمیق، مدل‌های جدید برای تحلیل و پیش‌بینی سری‌های زمانی توسعه یافته‌اند. شبکه‌های عصبی مکرر [۹]، کارآمدترین روش پیش‌بینی سری زمانی‌اند [۱۰]. این نوع شبکه عصبی در پردازش اطلاعات سری‌های زمانی^۴، زبان گفتار^۵ و متن مورد استفاده قرار گرفته‌است [۱۱]. شکل (۲) نمای بسته و باز یک شبکه عصبی بازگشتی بدون لایه خروجی [۸] را نشان می‌دهد. با توجه به رابطه (۲) در هر مرحله، حالت فعلی برگرفته از مجموعه حالت‌های قبلی است. در این مطالعه از الگوی زمانی فعالیت کاربران در پیش‌بینی مکان بعدی کاربر و طبقه‌بندی اطلاعات استفاده می‌شود.

$$h^t = f(h^{(t-1)}, x^{(t)}; \theta) \quad (2)$$



(شکل-۲): نمای بسته و باز یک شبکه عصبی بازگشتی

(Figure 2): closed and open views of a recurrent neural network

RNN شبکه عصبی مصنوعی است که در آن گره‌ها به صورت حلقه وصل می‌شوند و حالت داخلی شبکه می‌تواند رفتار زمان‌بندی پویا را به نمایش بگذارد. مهم‌ترین ضعف شبکه‌های مبتنی بر RNN در هنگام یادگیری وابستگی‌های طولانی‌مدت است. برای غلبه بر این مشکل LSTM [۱۲] و واحدهای مکرر گیت‌دار GRU [۱۳] ارائه شدند که عملیات خطی ساده را روی اطلاعات نورون انجام می‌دهند و اطلاعات خارجی در لحظه فعلی را از طریق مکانیزم گیت اضافه می‌کنند. با وجود مزیت‌های شبکه‌های LSTM هنوز عملکرد آن‌ها بر داده‌های پیش‌بینی سری زمانی رضایت‌بخش نیست؛ زیرا معماری‌های کم‌عمق

^۲ Recurrent Neural Network


^۳ Sequence data

^۴ Time Series

^۵ Natural Language

^۱ Location-Based Social Network

ویژگی‌های داده‌های سری زمانی را به طور کارآمد نشان نمی‌دهند؛ به خصوص زمانی که داده‌های سری زمانی با فواصل طولانی مدت و بسیار غیرخطی پردازش می‌شوند [۱۴]؛ همچنین با پیچیده شدن معماری شبکه‌های عمیق، یک سؤال پیش می‌آید که چگونه یک شبکه را می‌توان تنظیم کرد. البته می‌توان تعداد محدودی از ابرپارامترها را با آزمایش بهینه کرد، اما شبکه‌های عمیق دارای توپولوژی پیچیده و صدها ابرپارامتر است. بیشتر موفقیت‌ها در حل مسئله به انتخاب معماری مناسب برای آن مسئله بستگی دارد. به طور گسترده، افزایش عمق یک شبکه عصبی روشی مؤثر برای بهبود عملکرد کلی است [۱۴]. با توجه به شکل (۳)، در LSTM عمیق، چندین بلوک LSTM یکی پس از دیگری به روش شبکه مکرر به یکدیگر متصل شده‌اند تا مزایای یک لایه LSTM تنها را ترکیب کنند. هدف از انباشت چند LSTM در چنین معماری سلسله‌مراتبی، ایجاد ویژگی‌هایی در لایه‌های پایین‌تر است که عوامل تغییرات در داده‌های ورودی را از هم جدا کنند؛ سپس این بازنمایی‌ها در لایه‌های بالاتر ترکیب می‌شود [۱۴]. درباره داده‌های بزرگ یا پیچیده نشان داده شده است که چنین معماری عمیقی به دلیل نمایش ساده‌تر از معماری کم‌عمق، بهتر تعمیم خواهد یافت [۱۵].



(شکل ۳-۳): معماری شبکه LSTM عمیق
(Figure-3): Deep LSTM network architecture

مزیت معماری پشته‌ای این است که هر لایه بخشی از وظیفه مدنظر را پردازش می‌کند و به لایه بعد می‌دهد تا در نهایت لایه آخر خروجی را تولید کند. مزیت دیگر این است که چنین معماری‌هایی به وضعیت‌های پنهان اجازه می‌دهند در بازه زمانی متفاوت فعالیت کنند. این دو مزیت در استفاده از داده‌ها با وابستگی طولانی مدت یا در صورت دستیابی به مجموعه داده‌های سری چندمتغیره، تأثیر زیادی دارند [۱۴].

در هر مرحله، اطلاعات موجود در گره اصلی به‌روزی می‌شود، اما پس از ثبت اطلاعات، دیگر محاسبه یا تغییری در اطلاعات صورت نمی‌گیرد. این نوع معماری اجازه حرکت روبه‌جلو و روبه‌عقب در طول زمان را به شبکه عصبی می‌دهد [۱۶]. این معماری از شبکه‌های عصبی دارای سربار کمتری بوده و بهترین روش برای استفاده در شبکه‌های عصبی بازگشتی عمیق است. برای جلوگیری از سربار حافظه مورد نیاز برای ذخیره‌سازی اطلاعات حالت‌های قبلی شبکه، این حافظه‌ها کوتاه‌مدت‌اند. در معماری حافظه طولانی، کوتاه‌مدت هر گره از سه دروازه ورودی، خروجی و فراموشی با دو حالت صفر یا یک به صورت دودویی تشکیل شده است. این سه دروازه به ترتیب مقادیر داده‌های ورودی از حالت قبلی شبکه، داده‌های ارسالی و ذخیره‌شده برای حالت بعدی شبکه و اطلاعات قابل حذف را کنترل می‌کنند. با توجه به توانایی معماری حافظه طولانی کوتاه‌مدت در پردازش داده‌های زمانی، در این پژوهش از این نوع معماری شبکه جهت طبقه‌بندی اطلاعات زمانی کاربر استفاده می‌شود.


معماری GRU در سال ۲۰۱۴ معرفی شد [۱۷]. این معماری که ساختار آن در شکل (۴) نشان داده شده است به منظور برطرف کردن کاستی‌های شبکه عصبی بازگشتی سنتی RNN نظیر مشکل محوشدن گرادیان و همچنین کاهش سربار موجود در معماری LSTM ارائه شده است. GRU مبتنی بر LSTM بهبود یافته است و به طور عمومی به عنوان نسخه تغییر یافته از LSTM در نظر گرفته می‌شود. در GRU، دروازه فراموشی و دروازه ورودی موجود در LSTM در یک دروازه به‌روزرسانی^۱ ترکیب شده است. کل فرایند را می‌توان با روابط (۳ تا ۶) بیان کرد.

$$z_t = \text{Sigmoid}(W_z * [h_{t-1}, x_t]) \quad (3)$$

$$r_t = \text{Sigmoid}(W_r * [h_{t-1}, x_t]) \quad (4)$$

$$h_t = \tanh(W * [h_{t-1} * r_t, x_t]) \quad (5)$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * h_t \quad (6)$$



(شکل ۴-۴): ساختار GRU
(Figure-4): The structure of GRU

¹ update gate

(جدول-۲): مکان‌های بالای صد بازدید

(Table-2): Places with more than 100 visits

support	f1-score	recall	precision	Venue Category	
859	0.97	0.99	0.96	Airport	۱
1138	0.76	0.75	0.77	American Restaurant	۲
114	0.93	0.92	0.94	Arcade	۳
175	0.72	0.70	0.74	Asian Restaurant	۴
217	0.78	0.72	0.85	Athletic & Sport	۵
202	0.81	0.81	0.81	BBQ Joint	۶
290	0.74	0.71	0.77	Bagel Shop	۷
495	0.76	0.72	0.80	Bakery	۸
154	0.88	0.94	0.82	Beach	۹
157	0.88	0.90	0.87	Beer Garden	۱۰

یکی از مسائل مهم در شبکه‌های اجتماعی میزان ارتباط هر کاربر با دیگر کاربران است تا میزان تأثیرگذاری و یا تأثیرپذیری هر کاربر شناسایی شود [۱۸]. زمانی که میزان تأثیرپذیری و یا تأثیرگذاری هر کاربر شناسایی شد، می‌توان میزان پیش‌بینی رفتار کاربر را نیز شناسایی کرد؛ بنابراین در گام بعدی، باید رابطه هر کاربر با کاربران دیگر سنجیده شود و به میزان ارتباط هر کاربر با کاربران دیگر وزنی تعلق گیرد؛ لذا برای اینکه صحت کار سنجیده شود و عملکرد سامانه مورد ارزیابی قرار گیرد، یک کاربر که میزان فعالیت‌های متوسطی دارد، انتخاب می‌شود و طبق شکل (۵) بهترین دوستان و یا دوستانی که بیشترین ارتباط را با او دارد شناسایی و میزان ارتباط هر دوست با کاربر اصلی محاسبه می‌شود. کاربر ۸۱۶ به‌عنوان کاربر اصلی، تعداد ۴۹۷ مکان را بازدید کرده‌است. با توجه به فرمول‌های (۷ و ۸) باید میزان اشتراک مکانی هر کاربر با تمامی کاربران محاسبه شود.

(۷)

$$Communitiy = U_i(venueCategory) - U_j(venueCategory)$$

(۸)

$$Communicat\ weight = \frac{Community}{\sum U_i(v_Category) * \sum U_j(v_Category)}$$

سپس میزان ارتباط کاربر اصلی ۸۱۶ با چهار کاربر به نام‌های ۱۰۸۱-۷۴۰-۱۸-۲۶۸ که در شکل (۵) نشان داده شده‌است، شناسایی می‌شود. این کاربران بیشترین ارتباط با کاربر ۸۱۶ دارند. در ادامه می‌توان پیش‌پردازش‌های لازم (تاریخچه بازدید از مکان‌های بازدیدشده و قراردادن یک برای مکان با بازدید مشترک و صفر برای مکان‌های

یک سلول GRU از دو دروازه به‌روزرسانی z و دروازه بازنشانی r ^۱ ساخته شده‌است. در روابط (۳) تا (۶) z_t خروجی دروازه به‌روز رسانی در لحظه t ، r_t خروجی دروازه بازنشانی در لحظه t است. w نشان‌دهنده ماتریس وزن‌ها و h_t حالت را در لحظه t نشان می‌دهد.

۴-۳-مدل پیشنهادی

فیلد UTC time، زمان به همراه تاریخ را نشان می‌دهد؛ بنابراین باید ارقام را جدا کرد تا تحلیل بهتری روی داده‌ها صورت گیرد. ویژگی‌هایی که به‌عنوان ورودی به الگوریتم داده شده شامل longitude، latitude، userId، venueCategory، این ویژگی‌ها به‌عنوان هدف مشخص شده‌است و نشان‌دهنده مکان بازدید کاربر است. این مشخصه شامل ۲۵۱ مکان است. در این روش، معیارهای ارزیابی precision، recall، f1-score [۶] روی تک‌تک مکان‌ها حساب می‌شود؛ سپس میانگین معیارها به‌دست می‌آید؛ برای مثال طبق جدول (۱) تعدادی از مکان‌ها به همراه معیارهای ارزیابی آن قرار گرفته‌است.

(جدول-۱): معیارهای ارزیابی

(Table-1): Evaluation criteria

f1-score	recall	precision	Venue Category	
۰.۹۷	۰.۹۹	۰.۹۶	Airport	۱
۰.۷۶	۰.۷۵	۰.۷۷	American Restaurant	۲
۰.۹۱	۰.۸۹	۰.۹۴	Animal Shelter	۳
۰.۶۷	۰.۶۰	۰.۷۵	Antique Shop	۴

در پایان دقتی که با مدل Random Forest به‌دست‌آمده برابر ۸۴ درصد است. در این روش نکته مهمی که می‌توان از آن استنباط کرد، صحت^۲ بالای داده‌هایی است که تعداد افراد بازدیدکننده از مکان‌ها بیشتر از صد مورد بوده‌است؛ لذا در این گونه موارد مکان‌هایی که بیشترین بازدید را داشته‌است، دارای معیارهای ارزیابی بالاتری هستند. همانند جدول (۲) تعدادی از مکان‌هایی که بازدیدهای بالای صد مورد را داشته‌اند نشان داده شده‌است. در این جدول مشخص شده که مکان‌هایی که بالای صد مورد بازدید شده‌اند، دارای صحت بالای هفتاد درصد بوده‌است؛ لذا از این نمونه داده‌ها در شبکه‌های عصبی بازگشتی استفاده شده‌است تا نتایج در این مدل شبکه‌ها بهبود یابد.


^۱ Reset gate

^۲ precision

بازدید غیر مشترک) را برای ورود به شبکه‌های عصبی بازگشتی انجام داد.

نتایج ارزیابی با $epochs = 1000$ در شبکه عصبی بازگشتی شامل LSTM، RNN و GRU برای یک کاربر در جدول (۳) محاسبه شده است. نمودارهای (۱ تا ۳) مربوط به دقت و خطای شبکه‌های عصبی بازگشتی مذکور است.

حال مسئله در ابعاد اصلی داده‌ها کامل بررسی می‌شود. شبکه عصبی بازگشتی یکی از انواع قدرتمند شبکه‌های عصبی است و به خاطر حافظه داخلی، یکی از امیدبخش‌ترین انواع شبکه عصبی نیز به حساب می‌آید.



(شکل-۵): بهترین دوستان کاربر ۸۱۶


(Figure-5): Best friends of user 816

(جدول-۳): ارزیابی شبکه عصبی بازگشتی تک کاربره

(Table-3): Evaluation of single-user recurrent neural network


نام شبکه عصبی	دقت
LSTM	۰.۷۱
RNN	۰.۵۹
GRU	۰.۵۵

این شبکه‌ها به‌طور ویژه برای پردازش داده‌های سری طراحی شده‌اند؛ همچنین با توجه به اینکه داده‌ها دارای سری زمان است، می‌توان از شبکه‌های عصبی بازگشتی استفاده کرد. ابتدا باید تمامی دوستان هر کاربر را شناسایی کرد تا رفتار هر کاربر برای انتخاب محل بعدی برای بازدید را از روی رفتار دوستانش پیش‌بینی کرد. پایگاه داده شامل ده ویژگی طبق جدول (۴) برای ۱۰۸۳ کاربر است.




(نمودار-۱): دقت شبکه LSTM تک کاربر

(Chart-1): Accuracy of single user LSTM network



(نمودار-۲): دقت شبکه RNN تک کاربره

(Chart-2): Accuracy of single-user RNN network



(نمودار-۳): دقت شبکه GRU تک کاربره

(Chart-3): Accuracy of single user GRU network

در این مرحله هر کاربر با تمامی کاربران مقایسه و تعداد اشتراک‌های مکانی با توجه به فرمول‌های (۷ و ۸) محاسبه می‌شود؛ سپس نسبت دوستی هر کاربر با دیگر کاربران در ماتریس community_matrix قرار می‌گیرد. در ادامه چهار مورد از بهترین دوستان هر کاربر انتخاب می‌شوند تا عمل پیش‌بینی رفتار کاربر بر اساس آن چهار کاربر شناسایی شود؛ سپس مکان‌های بازدید شده هر کاربر با کاربران دوست خود بر اساس ویژگی timestamp_converted ادغام می‌شود.


(جدول-۴): ویژگی‌های مجموعه داده foursquare

(Table-4): characteristics of foursquare dataset

نام ویژگی
userId
venueId
venueCategoryId
venueCategory
latitude
longitude
timezoneOffset
utcTimestamp
timestamp_converted
venue_cat_encoded


نکته مهمی که باید در پیش‌پردازش به آن توجه داشت، تاریخچه فعالیت هر کاربر است؛ لذا برای هر کاربر دو تاریخچه از مکان‌هایی که در گذشته بازدید کرده است دو ویژگی جدید قرار می‌گیرد؛ سپس می‌بایست هم‌بستگی بین داده‌ها طبق جدول (۵) مورد بررسی قرار گیرد.

از تابع softmax استفاده شده‌است. نتایج حاصل از شبکه بازگشتی RNN طبق نمودار (۵) شامل Accuracy است.



(نمودار-۵): دقت شبکه RNN
(Chart-5): Accuracy of RNN network

در مرحله آخر نیز از شبکه عصبی بازگشتی GRU¹ استفاده شده‌است. این شبکه نوع خاصی شبکه عصبی بازگشتی RNN است و تا حد زیادی مشابه شبکه عصبی LSTM است؛ به عبارت دیگر، شبکه GRU نوع پیشرفته‌تری از شبکه عصبی بازگشتی RNN و شبکه LSTM است. مجموعه داده پیش‌پردازش شده در این شبکه همانند مجموعه داده شبکه LSTM است. در این شبکه از دو لایه مخفی و تابع relu optimizer=adam و epochs=1000 و در لایه خروجی از تابع softmax استفاده شده‌است. نتایج حاصل از شبکه بازگشتی GRU طبق نمودار (۶) شامل Accuracy است.



(نمودار-۶): دقت شبکه GRU
(Chart-6): Accuracy of GRU network

این مقاله بر روی کاربرد الگوریتم‌های یادگیری ماشین، از جمله Random Forest ، RNN ، LSTM و GRU برای پیش‌بینی سری‌های زمانی تمرکز دارد؛ همچنین مزایای استفاده از LSTM نسبت به سایر الگوریتم‌ها، مانند توانایی آن در گرفتن وابستگی‌های بلندمدت و اثربخشی آن در مدیریت داده‌های متوالی مورد بحث قرار گرفت و در این خصوص بر اهمیت در نظر گرفتن جنبه داده‌های زمانی و تأثیر ویژگی‌های مختلف بر عملکرد پیش‌بینی تأکید می‌کند؛ لذا اهمیت در نظر گرفتن


¹ Gated Recurrent Unit

(جدول-۵): جدول هم‌بستگی

(Table-5): Correlation table

userid	1	-0.035	0.12	-0.0085	0.63	0.022	-0.021	0.0088	-0.0085	-0.0084	-0.0085
latitude	-0.035	1	-0.019	0.096	-0.052	-0.0063	0.0081	0.077	0.091	0.093	0.09
longitude	0.12	-0.019	1	0.011	0.1	-0.018	0.02	-0.0021	0.012	0.012	0.013
venue_cat_encoded3	-0.0085	0.096	0.011	1	-0.061	-0.084	0.084	0.54	0.71	0.71	0.7
userid3	0.63	-0.052	0.1	-0.061	1	0.67	-0.67	0.44	-0.061	-0.061	-0.061
latitude3	0.022	-0.0063	-0.018	-0.084	0.67	1	-1	0.66	-0.084	-0.084	-0.084
longitude3	-0.021	0.0081	0.02	0.084	-0.67	-1	1	-0.66	0.084	0.084	0.084
venue_cat_encoded3	-0.0088	0.077	-0.0021	0.54	0.44	0.66	-0.66	1	0.54	0.54	0.54
next_venue	-0.0085	0.091	0.012	0.71	-0.061	-0.084	0.084	0.54	1	0.7	0.7
venue_his1	-0.0084	0.093	0.012	0.71	-0.061	-0.084	0.084	0.54	0.7	1	0.71
venue_his2	-0.0085	0.09	0.013	0.7	-0.061	-0.084	0.084	0.54	0.7	0.71	1
userid	1										
latitude		1									
longitude			1								
venue_cat_encoded				1							
userid3					1						
latitude3						1					
longitude3							1				
venue_cat_encoded3								1			
next_venue									1		
venue_his1										1	
venue_his2											1

در جدول هم‌بستگی ارتباطی بین تاریخچه مکان‌های بازدید با بازدید لحظه‌ای هر کاربر مشاهده می‌شود. نکته مهم داشتن ارتباط کمابیش خوب بین هر کاربر با عرض و طول جغرافیایی است؛ لذا از این ارتباطات می‌توان در تهیه یک مجموعه داده مناسب‌تر برای ارسال به شبکه عصبی بازگشتی استفاده کرد؛ بنابراین مجموعه داده‌ای شامل ویژگی‌های کاربران، عرض جغرافیایی، طول جغرافیایی و تاریخچه مکان‌های بازدید و مکان بازدید فعلی ایجاد می‌شود؛ سپس از شبکه عصبی LSTM با تنظیمات هاینپارامتر شامل پنج لایه مخفی، تابع relu optimizer=adam و epochs=1000 و در لایه خروجی از تابع softmax استفاده می‌شود. نتایج حاصل از شبکه بازگشتی LSTM طبق نمودار (۴) شامل Accuracy است.



(نمودار-۴): دقت شبکه LSTM
(Chart-4): Accuracy of LSTM network

در مرحله بعدی از شبکه عصبی بازگشتی RNN استفاده شده‌است. این شبکه برای مدل‌سازی داده‌های دنباله دار استفاده می‌شود. توانایی این شبکه در پردازش داده‌های دنباله‌ای کوتاه‌مدت است. مجموعه داده پیش‌پردازش شده در این شبکه همانند مجموعه داده شبکه LSTM است. در این شبکه از یک لایه مخفی و تابع relu optimizer=adam و epochs=1000 و در لایه خروجی

Accuracy مربوط به شبکه‌های عمیق LSTM است که می‌توان با دقت ۷۱ درصد پیش‌بینی مکان بعدی کاربر را تعیین کرد.

(جدول ۶-): ارزیابی الگوریتم‌ها
(Table-6): Evaluation of algorithms

نام الگوریتم	دقت
Random Forest	۰.۸۴
LSTM	۰.۷۱
RNN	۰.۴۶
GRU	۰.۵۹

بنابراین استفاده از الگوریتم جنگل تصادفی برای دسته‌بندی داده‌های مکانی کاربران در شبکه‌های اجتماعی نکته‌ی حائز اهمیت برای پیش‌بینی رفتار کاربر است. پس از دسته‌بندی کاربران، فرمول نوع محاسبه‌ی افراد تأثیرگذار بر رفتار کاربر نقش بسزایی در پیش‌بینی رفتار کاربر دارد؛ همچنین استفاده از ویژگی‌های زمانی در کنار مکان، پیش‌بینی رفتار کاربر را بهبود می‌بخشد؛ بنابراین از مهم‌ترین کارها استفاده‌ی هوشمندانه از الگوریتم‌های یادگیری ماشین و یادگیری عمیق برای پیش‌بینی و توصیه‌ی مکان‌های بعدی بازدید در شبکه‌های اجتماعی است که در این پژوهش انجام گرفته است؛ لذا با توجه به ارزیابی تمامی نتایج پیشنهاد می‌شود، داده‌های بیشتری از مکان بازدید افراد در نظر گرفته شود، اما نکته‌ای که باید با آن توجه داشت میزان علایق هر کاربر است که نیاز به مجموعه‌داده‌ای است که ویژگی‌هایی شامل نوع مکان مانند تفریحی، علمی، فرهنگی و... در آن درج شود و با توجه به آن ویژگی، میزان علایق کاربر به مکان خاص سنجیده شده تا پیش‌بینی دقیق‌تری از رفتار کاربر به دست آید. نکته‌ی دیگر در خصوص مکان‌های بازدید شده توسط کاربر است که نشان‌دهنده‌ی این است که مکان‌هایی که بیشتر کاربران از آن‌ها بازدید کرده‌اند، از نظر جغرافیایی نزدیک به هم هستند که می‌توان دریافت محل استقرار کاربر نیز در همان حوالی است.

از این موضوع می‌توان نتیجه گرفت که بیشتر کاربران تمایل دارند، از مکان‌هایی بازدید کنند که نزدیک محل استقرار آن‌هاست.

ویژگی‌های زمانی در فرایند پیش‌بینی بسیار مهم است. در روش‌های مشابه [۲۱] برای پیش‌بینی انتخاب مکان بازدید بعدی برای کاربران در شبکه‌های اجتماعی روی داده‌های Foursquare مقایسه انجام شده است و دقت در این مقاله به ۵۷.۱۲ رسیده است. در مقاله [۲۲] از یک مدل چندوجهی برای ارائه‌ی پیشنهاد استفاده شده است. در این مقاله با اینکه تنها روی یک قسمت از مجموعه داده متمرکز شده، توانسته است به دقت ۵۴ درصد برسد؛ همچنین در مقاله [۲۳] که یک روش توصیه‌ی متوالی تطبیقی مبتنی بر ترجیحات کوتاه مدت و بلندمدت مکانی - زمانی پیشنهاد شده است، دقت نزدیک به ۷۰ درصد بر روی مجموعه داده Foursquare به دست آمده است.

روش پیشنهادی ما دقت روش‌های یادگیری ماشین و شبکه‌های عصبی بازگشتی را برای پیش‌بینی مکان بعدی کاربران مورد بررسی قرار داد. از این روش که از قابلیت بالایی برای پیش‌بینی دقیق انتخاب مکان بعدی کاربران بر اساس الگوهای تعیین شده برخوردار است، استفاده می‌شود؛ لذا از این روش‌ها می‌توان برای به دست آوردن نتایج دقیق‌تر و پیشرفته‌تر در پیش‌بینی مکان بعدی کاربران کمک گرفت. با توجه به این عوامل، استفاده از روش‌های یادگیری ماشین و شبکه‌های عصبی بازگشتی به عنوان روش پیشنهادی در این مقاله توجیه پذیر به نظر می‌رسد.

۵- نتیجه گیری

در روش پیشنهادی دو مفهوم مهم برای پیش‌بینی دقیق یک کاربر در انتخاب مکان بعدی بازدید، مورد توجه قرار گرفت. در ابتدا نحوه انتخاب بهترین دوستان برای یک کاربر انجام شد؛ زیرا بیشترین تأثیر بر روی کاربر برای انتخاب مکان بازدید، افرادی هستند که بیشترین اشتراک را دارند و بر روی کاربر اثر می‌گذارند؛ سپس مکان‌هایی انتخاب می‌شوند که بیش از صد مرتبه بازدید شده‌اند. این دو عامل با توجه به نتایجی که به دست آمده است نقش بسزایی در پیش‌بینی انتخاب مکان بعدی کاربر دارد. در میان الگوریتم‌های انتخاب شده در این مقاله از الگوریتم جنگل‌های تصادفی استفاده شد که می‌تواند برای مشکلات طبقه‌بندی و رگرسیون در یادگیری ماشین استفاده شود. Accuracy که به دست آمد طبق جدول (۶) برابر ۸۴ درصد است که نشان‌دهنده این است که این روش از مناسب‌ترین روش‌ها برای پیش‌بینی مکان‌های بعدی است که کاربر بازدید خواهد کرد. در میان شبکه‌های بازگشتی که در این مقاله به کار گرفته شده است، بیشترین

6-References

۶-مراجع

- [1] Zheng, Yu, and Xiaofang Zhou. "Computing with Spatial Trajectories". Springer Science & Business Media, 2011.
- [2] Rahimi, Seyyed Mohammadreza, and Xin Wang. "Location Recommendation Based on

- Neural Networks." *Advances in neural information processing systems* 26, 2013
- [16] A. Graves, "Supervised sequence labelling," in *Supervised Sequence Labelling with Recurrent Neural Networks*: Springer, 2012
- [17] Chung, Junyoung, Caglar Gulcehre, KyungHyun Cho, and Yoshua Bengio. "Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling." *arXiv preprint arXiv:1412.3555*, 2014
- [18] Luceri, Luca, Torsten Braun, and Silvia Giordano. "Analyzing and Inferring Human Real-Life Behavior through Online Social Networks with Social Influence Deep Learning." *Applied network science* 4, no. 1, 2019
- [19] Abbasi, Omid Reza, and Ali Asghar Alesheikh. "Exploring the Potential of Location-Based Social Networks Data as Proxy Variables in Collective Human Mobility Prediction Models." *Arabian Journal of Geosciences* 11, 2018
- [20] Liu, Yang, and An-bo Wu. "Poi Recommendation Method Using Deep Learning in Location-Based Social Networks." *Wireless Communications and Mobile Computing* 2021, no. 1, 2021
- [21] Liao, Jianxin, Tongcun Liu, Meilian Liu, Jingyu Wang, Yulong Wang, and Haifeng Sun. "Multi-Context Integrated Deep Neural Network Model for Next Location Prediction." *IEEE access* 6, 2018
- [22] Kanzawa, Yuta, Toyotaro Suzumura, Hiroki Kanezashi, Jiawei Yong, and Shintaro Fukushima. "Multimodal Point-of-Interest Recommendation." *arXiv preprint arXiv:2410.03265*, 2024
- [23] Wan, Jun, Cheng Chi, Haoyuan Yu, Yang Liu, Xiangrui Xu, Hongmei Lyu, and Wei Wang. "Fed-Attgru Privacy-Preserving Federated Interest Recommendation." *Paper presented at the Proceedings of the ACM Turing Award Celebration Conference-China*, 2024
- [۲۴] انارکی، ریاحی «روش تکاملی بهبود انتخاب الگوریتم در سیستم‌های توصیه‌گر فیلترینگ مشارکتی»، پردازش علائم و داده‌ها، ۲۰۲۳
- [25] Anaraki, Riahi "Evolutionary Method for Improving Algorithm Selection in Collaborative Filtering Recommender Systems", *Signal and Data l Processing*, ۲۰۲۳
- [۲۶] محمود دی پیر، احسان بیات، «تشخیص انجمن‌ها در شبکه‌های اجتماعی با استفاده از الگوریتم جستجوی هارمونی گسسته»، پردازش علائم و داده‌ها، ۲۰۲۳
- [27] Mahmoud De Pierre, Ehsan Bayat, "Detecting Associations in Social Networks Using Discrete Harmony Search Algorithm", *Signal and Data l Processing*, ۲۰۲۳
- [28] Shukla, Pushpak, and Shailendra Shukla. "Exploring the Potential of Deep Regression Model for Next-Location Prediction." *Knowledge and Information Systems*, 1-32, 2024

- Periodicity of Human Activities and Location Categories." *Paper presented at the Advances in Knowledge Discovery and Data Mining: 17th Pacific-Asia Conference, PAKDD 2013*, Gold Coast, Australia, April 14-17, 2013, Proceedings, Part II 17, 2013.
- [3] Beeharee, Ashweeni, and Anthony Steed. "Exploiting Real World Knowledge in Ubiquitous Applications." *Personal and Ubiquitous Computing* 11, 2007.
- [4] Simon, Rainer, and Peter Fröhlich. "A Mobile Application Framework for the Geospatial Web." *Paper presented at the Proceedings of the 16th international conference on World Wide Web*, 2007.
- [5] Park, Moon-Hee, Jin-Hyuk Hong, and Sung-Bae Cho. "Location-Based Recommendation System Using Bayesian User's Preference Model in Mobile Devices." *Paper presented at the Ubiquitous Intelligence and Computing: 4th International Conference, UIC 2007*, Hong Kong, China, July 11-13, 2007. Proceedings 4, 2007.
- [6] AlZoman, Razan M, and Mohammed JF Alenazi. "A Comparative Study of Traffic Classification Techniques for Smart City Networks." *Sensors* 21, no. 14, 2021
- [7] Jia, Yuanxin, Yong Ge, Feng Ling, Xian Guo, Jianghao Wang, Le Wang, Yuehong Chen, and Xiaodong Li. "Urban Land Use Mapping by Combining Remote Sensing Imagery and Mobile Phone Positioning Data." *Remote Sensing* 10, no. 3, 2018
- [8] Arruda, Henrique F de, Alexandre Benatti, César Henrique Comin, and Luciano da F Costa. "Learning Deep Learning." *Revista Brasileira de Ensino de Física* 44, 2022
- [9] Rumelhart, David E, Geoffrey E Hinton, and Ronald J Williams. "Learning Representations by Back-Propagating Errors." *nature* 323, no. 6088, 1986
- [10] Liu, Yeqi, Chuanyang Gong, Ling Yang, and Yingyi Chen. "Dstp-Rnn: A Dual-Stage Two-Phase Attention-Based Recurrent Neural Network for Long-Term and Multivariate Time Series Prediction." *Expert Systems with Applications* 143, 2020
- [11] Liu, Pengfei, Xipeng Qiu, and Xuanjing Huang. "Recurrent Neural Network for Text Classification with Multi-Task Learning." *arXiv preprint arXiv:1605.05101*, 2016
- [12] Hochreiter, S. "Long Short-Term Memory." *Neural Computation MIT-Press*, 1997
- [13] Chung, Junyoung, Caglar Gulcehre, KyungHyun Cho, and Yoshua Bengio. "Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling." *arXiv preprint arXiv:1412.3555*, 2014
- [14] Sagheer, Alaa, and Mostafa Kotb. "Time Series Forecasting of Petroleum Production Using Deep Lstm Recurrent Networks." *Neurocomputing* 323, 2019
- [15] Hermans, Michiel, and Benjamin Schrauwen. "Training and Analysing Deep Recurrent



حمید رضا غفاری عضو هیئت علمی دانشگاه آزاد واحد فردوس و دارای مدرک دکتری رشته نرم افزار از دانشگاه فردوسی است. نشانی رایانامه ایشان عبارت است از:

hamidghaffariy53@yahoo.com



محمد راستگو دانشجوی دکتری رشته کامپیوتر گرایش نرم افزار در دانشگاه آزاد فردوس است. ایشان دارای مدرک کارشناسی ارشد در رشته هوش مصنوعی، همچنین مدرک کارشناسی ارشد در رشته نرم افزار است. نشانی رایانامه ایشان عبارت است از:

rastgoo.mhd@gmail.com