



مروری بر کاربرد الگوریتم‌های یادگیری عمیق استفاده‌شده در توصیه POI

مهشید صالحی^(۱) حسن شاکری*^(۲)

(۱) گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

(۲) گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران*

تاریخ دریافت: ۱۴۰۲/۰۵/۰۸ تاریخ پذیرش: ۱۴۰۲/۰۶/۲۹

چکیده

با توسعه سریع فناوری اطلاعات، حجم داده‌ها روزبه‌روز در حال افزایش است و این موضوع منجر به چالش‌های جدی در پیداکردن اطلاعات درست و مناسب برای کاربران اینترنت می‌شود. به خصوص، مشکلات کاربران در یافتن مطالب یا خدماتی که واقعاً به آنها نیاز دارند، بیشتر و بیشتر چالش‌برانگیز می‌شود. برای رفع این مشکل، انواع سیستم‌های توصیه‌گر برای تحلیل داده‌های سابقه رفتاری کاربران و ارائه خدمات شخصی برای بهبود تجربه‌ها و بررسی نظرهای مشتریان در بسیاری از زمینه‌ها ایجاد شده‌اند که از جمله می‌توان به توصیه *POI*، خدمات چندرسانه‌ای و وب‌سایت‌های تجارت الکترونیکی اشاره کرد. با افزایش محبوبیت شبکه‌های اجتماعی مبتنی بر مکان، طراحی مدل‌های دقیق برای توصیه‌های *POI* توجه بیشتری را به خود جلب کرده است. با توجه به اهمیت و کاربردهای گسترده توصیه *POI*، این موضوع هم در تحقیقات آکادمیک و هم در صنعت در کانون توجه قرار گرفته است. با این حال، فناوری‌های سنتی مانند فیلترینگ مشارکتی با چالش کمبود داده‌ها محدود شده‌اند و نمی‌توانند به طور دقیق ترجیحات کاربران را از متن‌های پیچیده استخراج کنند و همچنین بسیاری از روش‌های قدیمی‌تر برای استخراج و توصیه *POI* طراحی نشده‌اند، بنابراین نمی‌توانند خصوصیات منحصر به فردی را که تأثیرات زیادی بر روابط توصیه *POI* دارد، استخراج کنند. در سال‌های اخیر الگوریتم‌های مختلفی از حوزه یادگیری عمیق برای توصیه‌های *POI* مورد توجه محققین بوده است. در این تحقیق، کارهای تحقیقاتی و مدل‌های ارائه شده در زمینه توصیه *POI* به کمک یادگیری عمیق مورد مطالعه قرار گرفته و همچنین نتایج به دست آمده از نظر الگوریتم‌های یادگیری عمیق استفاده شده، مجموعه داده‌های مورد استفاده، معیارهای ارزیابی و ابزارهای پیاده‌سازی مورد بررسی و تحلیل قرار گرفته‌اند.

کلمات کلیدی: توصیه *POI*، سیستم‌های توصیه‌گر، شبکه‌های اجتماعی مبتنی بر مکان، یادگیری عمیق

*عهده‌دار مکاتبات:

حسن شاکری

نشانی: گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران

پست الکترونیکی: shakeri@mshdiau.ac.ir

شبکه‌های اجتماعی مبتنی بر مکان (LBSNs)^۱ مانند Gowalla و Foursquare در سال‌های اخیر به سرعت در حال رشد هستند. در ژانویه ۲۰۱۳، براساس رکوردهای ثبت‌شده در Foursquare، سی میلیون کاربر از بیش از سه میلیارد مکان بازدید کرده‌اند. در شبکه‌های اجتماعی مبتنی بر مکان، کاربران می‌توانند مکان‌های فیزیکی خود را به صورت مکان‌های بازدید شده ارسال کنند و تجربیات و نکات خود را برای توصیه مکان‌های مورد علاقه (POI)^۲ مانند رستوران‌ها و غیره به اشتراک بگذارند. در دسترس بودن حجم زیادی از داده مکان‌های بازدید شده توسط کاربران، باعث توصیه‌های POI ناخواسته به کاربران می‌شود. توصیه‌های POI هم برای کاربران و هم برای صاحبان مشاغل بسیار ارزشمند است [۱].

توصیه POI یکی از مهمترین قابلیت‌ها در شبکه‌های اجتماعی مبتنی بر مکان است که به کاربران کمک می‌کند مکان‌های جالب جدیدی را کشف کنند. توصیه POI به طور معمول از سوابق مکان‌های بازدید شده توسط کاربران، اطلاعات مربوط به آن مکان و دوستان اجتماعی کاربران برای تولید لیستی از توصیه‌ها استفاده می‌کند. توصیه POI از آژانس‌های تبلیغاتی با روشی مؤثر برای ارائه تبلیغات به مصرف‌کنندگان سود می‌برد. به طور خاص، کاربران می‌توانند رستوران‌های اطراف و مراکز خرید در محدوده مورد نظر را در Foursquare کشف کنند. در همین حال، صاحبان مشاغل می‌توانند از طریق توصیه POI کاربران را به راحتی پیدا کنند. با توجه به راحتی کاربران و فرصت‌های شغلی برای صاحبان مشاغل، توصیه POI توجه جدی را به خود جلب می‌کند و اخیراً چندین روش برای توصیه‌های POI مورد استفاده قرار گرفته‌اند [۲].

در روش سیستم‌های توصیه‌گر سنتی و قدیمی‌تر، رتبه بندی امتیاز آیت‌ها به‌عنوان شاخص ترجیح‌های یک کاربر در نظر گرفته می‌شد. با این حال، تنها داده‌ای که برای توصیه‌های POI در شبکه‌های اجتماعی مبتنی بر مکان می‌تواند جمع‌آوری کند، فراوانی مکان‌های بازدید شده توسط کاربر است. برخلاف رتبه بندی داده‌ها به روش سنتی برای مکان‌های بازدید شده که در مقیاس ۱ تا ۵ بودند، نمی‌توانستند کاملاً ترجیحات کاربر را نشان دهند. مثلاً کاربری ممکن است به یک مکان، پنج بار و به مکان دیگر ۱۰۰ بار مراجعه کند، با این حال، این بدان معنا نیست که کاربر مکان دوم را ۲۰ برابر بیشتر از مکان قبلی ترجیح می‌دهد. علاوه بر این، مقیاس فراوانی در مکان‌های بازدید شده در بین دسته‌ها قابل مقایسه نیستند. مثلاً شش بار بازدید از یک موزه در هفته نباید برابر با شش بار مراجعه به یک سوپر مارکت در هفته باشد. اکثر روش‌های موجود در توصیه POI به طور مستقیم داده‌های کاربر را به‌عنوان ماتریسی از فراوانی بازدید یا شماره‌های دودویی (۰ یا ۱) نمایش داده که نشان می‌دهد کاربر از مکانی بازدید کرده است [۳].

در تحقیق‌های جدیدتر انجام شده در در سیستم‌های توصیه‌گر، الگوریتم‌های یادگیری عمیق مورد توجه تعداد زیادی از محققین بوده است. تکنیک‌های یادگیری عمیق به دلیل افزایش امکانات محاسباتی با کارایی بالا محبوب شدند. یادگیری عمیق به دلیل توانایی پردازش تعداد زیادی از ویژگی‌ها و داده‌های بدون ساختار، به قدرت و انعطاف پذیری بالاتری دست می‌یابد. الگوریتم

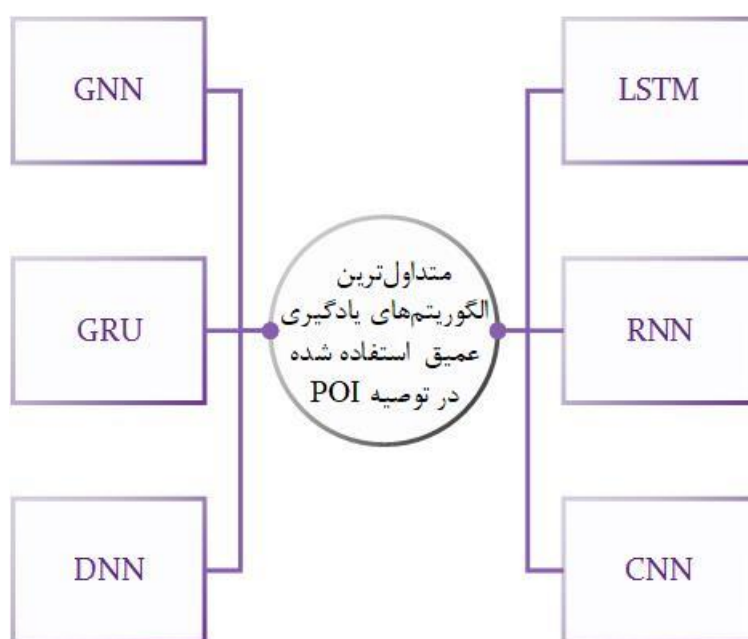
^۱ Location-Based Social Networks (LBSNs)

^۲ Point of interest

های یادگیری عمیق داده‌ها را از چندین لایه عبور می‌دهد. هر لایه به تدریج قادر به استخراج ویژگی‌ها است و آن را به لایه بعدی منتقل می‌کند. لایه‌های اولیه ویژگی‌های سطح پایین را استخراج می‌کنند و لایه‌های بعدی ویژگی‌ها را با هم ترکیب می‌کنند تا یک نمایش کامل را تشکیل دهند [۴].

یادگیری عمیق به مدل‌های محاسباتی که از لایه‌های پردازش چندگانه تشکیل شده‌اند اجازه می‌دهد تا نمایش داده‌ها با چندین سطح انتزاع را یاد بگیرند. این روش‌ها به طرز چشمگیری باعث بهبود شرایط در تشخیص گفتار، تشخیص اشیاء و بسیاری از حوزه‌های دیگر شده است. یادگیری عمیق با استفاده از الگوریتم انتشار معکوس، ساختار پیچیده را در مجموعه داده‌های بزرگ کشف می‌کند تا نشان دهد چگونه یک ماشین باید پارامترهای داخلی خود را با توجه به لایه قبلی که برای محاسبه بازنمایی در هر لایه استفاده می‌شود، تغییر دهد [۵]. در شکل ۱ تعدادی از الگوریتم‌های یادگیری عمیق به کار برده شده در توصیه POI بیان شده است. این تحقیق مجموعه‌ای از تحقیق‌ها برای کاربرد الگوریتم‌های یادگیری عمیق در توصیه POI را بررسی کرده و آن‌ها را از نظر نوع الگوریتم یادگیری عمیق، مجموعه داده، معیار ارزیابی و روش پیاده‌سازی با یکدیگر مقایسه می‌نماید.

ساختار این مقاله در ادامه، به این صورت است که در بخش دوم الگوریتم‌های یادگیری عمیق در توصیه POI بررسی می‌شوند. در بخش سوم مجموعه داده‌های مورد استفاده قرار گرفته در توصیه POI بررسی می‌شوند. در بخش چهارم انواع روش‌ها و معیارهای ارزیابی در POI بیان می‌شوند. در بخش پنجم ابزارهای پیاده‌سازی مدل پیشنهادی بیان شده، در بخش ششم تحلیل نتایج و در بخش هفتم نتیجه‌گیری و کارهای آینده برای ادامه دادن تحقیق‌ها در زمینه ارائه مدل پیشنهادی با استفاده از یادگیری عمیق بیان می‌شود.



شکل ۱- متداول‌ترین الگوریتم‌های یادگیری عمیق استفاده‌شده در توصیه POI

۲- الگوریتم‌های یادگیری عمیق مورد استفاده در توصیه POI

از سال ۲۰۰۶، یادگیری ساختار یافته عمیق، که معمولاً به عنوان یادگیری عمیق یا یادگیری سلسله مراتبی شناخته می‌شود، به عنوان حوزه جدیدی از زیرمجموعه یادگیری ماشین معرفی شد. در طی چند سال گذشته، تکنیک‌های حاصل از تحقیقات یادگیری عمیق طیف گسترده‌ای از کارهای پردازش سیگنال و اطلاعات، سیستم‌های تشخیص نفوذ، سیستم‌های توصیه‌گر و... مدل‌های پیشنهادی را تحت تأثیر خود قرار داده است که از دامنه‌های گسترده و جنبه‌های اصلی یادگیری ماشین و هوش مصنوعی می‌باشد [۶]. الگوریتم‌های مختلف یادگیری عمیق مثل GNN [۷] و GCN [۸] در توصیه POI مورد استفاده قرار گرفته شده‌اند که در این بخش الگوریتم‌های یادگیری عمیق پرکاربردتر به طور کامل شرح داده می‌شوند.

۱-۲ LSTM

مدل LSTM^۱ یکی از انواع قدرتمند RNN^۲ است. معماری LSTM از مجموعه‌ای از شبکه‌های فرعی که به طور مکرر متصل هستند، تشکیل شده است که به بلاک‌های حافظه معروف هستند. ایده اصلی بلاک حافظه حفظ وضعیت خود در طول زمان و تنظیم واحدهای دروازه غیرخطی جریان اطلاعات است. بلاک‌های حافظه شامل دروازه‌ها، سیگنال ورودی $x(t)$ ، سیگنال خروجی $y(t)$ ، توابع فعال‌ساز و اتصالات چشمی هستند. خروجی بلاک به طور مکرر به ورودی بلاک و تمام دروازه‌ها متصل می‌شود. شبکه LSTM در طیف گسترده‌ای از حوزه‌های مختلف، به صورت جداگانه و در ترکیب با سایر معماری‌های یادگیری عمیق، اعمال می‌شود. LSTM یکی از پیشرفته‌ترین شبکه‌ها برای پردازش توالی‌های زمانی است. به همین دلیل، مدل پایه LSTM هنوز هم یکی از محبوب‌ترین گزینه‌های شبکه است، حتی می‌توان آن را با سایر شبکه‌ها ترکیب کرد تا مدل‌های ترکیبی ایجاد شود. LSTM برای رسیدگی به پیش‌بینی‌های سری زمانی مناسب است همچنین برای حل هر مسئله دیگری مثل پردازش زبان طبیعی، توضیح نویسی برای عکس و ویدیو، بینایی کامپیوتر، تشخیص متن و سیستم‌های توصیه‌گر که به حافظه زمانی نیاز دارند، مناسب است [۹].

در مدل‌های پیشنهادی مختلفی از الگوریتم LSTM استفاده شده است. در [۱۰] یک مدل توصیه POI مبتنی بر LSTM پیشنهاد شد. الگوریتم پیشنهادی به عنوان دو نسخه: Loc LSTM و Loc-Interest-LSTM، که در آن Loc-Interest-LSTM ویژگی‌های علاقه مکان استخراج شده را با ساختار LSTM برای پیش‌بینی توصیه POI ترکیب می‌کند، در حالی که Loc-LSTM تنها از اطلاعات مسیر مکان برای LSTM بدون ویژگی‌های علاقه مکان استفاده می‌کند. در تحقیق [۱۱] نویسندگان مدلی برای تأثیر مکان و دسته در توصیه POI با توجه به ترتیب مکان‌های بازدید شده برای رفتار بازدید مکان کاربران ارائه می‌دهد. ابتدا، شبکه‌های عصبی LSTM برای مدل‌سازی دوره‌ای کاربران که در آن فعالیت‌های روزانه تکراری برای پیش‌بینی مبتنی بر توالی احتمال و اینکه آیا کاربر از یک توصیه POI بازدید می‌کند یا خیر استفاده می‌کنند. دوم، اولویت جغرافیایی کاربر در فضای دو بعدی توسط KDE^۳ نشان داده شده و برای ایجاد یک پیش‌بینی احتمال ورود مبتنی

^۱ Long Short-Term Memory (LSTM)

^۲ Recurrent Neural Network (RNN)

^۳ KDE یک جامعه نرم‌افزار آزاد بین‌المللی است که نرم‌افزار رایگان و منبع باز را توسعه می‌دهد. به عنوان یک مرکز توسعه مرکزی، ابزارها و منابعی را

بر مکان استفاده می‌شود. در مرحله بعد، اولویت دسته کاربر برای پیش‌بینی احتمال بازدید از توصیه POI نامزد شده و در نهایت، یک مدل ترجیحی کاربر از سه منظر زمان، مکان، دسته و احتمال بازدید آن مکان برای توصیه Top-N استفاده می‌شود. نتایج در مجموعه داده Foursquare تأیید می‌کند که روش پیشنهادی از نظر دقت و recall، هم از رویکرد پایه LSTM و هم روشی که فقط از اطلاعات مکان استفاده می‌کند برتر است. علاوه بر این، نتایج تجربی تأیید کرد، اولویت جغرافیایی که با «خوشه‌بندی» مکان‌های بازدید شده توسط کاربر منعکس می‌شود، پایدار است، اما اولویت دسته‌بندی کاربر مستعد تغییر است.

۲-۲ CNN

شبکه عصبی پیچشی (CNN^۱) یک معماری شناخته شده یادگیری عمیق است که با الهام از مکانیسم درک طبیعت موجودات زنده ساخته شده است. در سال ۱۹۹۰، LeCun و همکاران [۱۲] مقاله اصلی را برای ایجاد چارچوب CNN مدرن منتشر کرد و بعداً آن را در [۱۳] بهبود بخشیدند. آن‌ها یک شبکه عصبی مصنوعی چند لایه به نام LeNet-5 را ایجاد کردند که می‌تواند ارقام دست نوشته را طبقه بندی کند. همانند سایر شبکه‌های عصبی، LeNet-5 دارای چندین لایه است و با الگوریتم انتشار معکوس قابل آموزش است. این الگوریتم می‌تواند نمایش‌های موثری از تصویر اصلی به دست آورد، که باعث می‌شود الگوهای بصری را مستقیماً از پیکسل‌های خام پردازش کند. انواع مختلفی از معماری‌های CNN وجود دارد. با این حال، اجزای اصلی آن‌ها بسیار مشابه هستند. LeNet-5 از سه نوع لایه تشکیل شده است، یعنی لایه‌های پیچشی^۲، لایه ادغام^۳ و لایه تماماً متصل^۴. هدف از لایه پیچشی، یادگیری بازنمایی ویژگی‌های ورودی‌ها است. این لایه از جمع‌آوری چندین هسته تشکیل شده است که برای محاسبه خروجی‌های لایه پیچشی مختلف استفاده می‌شود. به طور خاص، هر نورون از یک خروجی لایه پیچشی به یک منطقه از نورون‌های همسایه در لایه قبلی وصل شده است. به چنین همسایگی فیلد گیرنده نورون در لایه قبلی گفته می‌شود. خروجی لایه پیچشی جدید را می‌توان با ادغام ورودی با یک هسته آموخته شده و سپس اعمال یک تابع فعال ساز غیرخطی بر روی نتایج پیچیده به دست آورد. برای تولید هر خروجی لایه پیچشی، هسته توسط کلیه مکان‌های ورودی به اشتراک گذاشته می‌شود. همه ویژگی‌ها با استفاده از چندین هسته مختلف به دست می‌آید [۱۴].

CNN ها با موفقیت در کارهای مختلف مرتبط با یادگیری ماشین، یعنی تشخیص شی، طبقه بندی، رگرسیون، تقسیم بندی و غیره استفاده شده‌اند. با این حال، CNN به طور کلی به تعداد زیادی از داده‌ها برای یادگیری نیاز دارد. تمام مسائلی که CNN

فراهم می‌کند که امکان کار مشترک روی این نوع نرم افزار را فراهم می‌کند. KDE یک جامعه باز متشکل از افراد دوستانه است که می‌خواهند جهانی ایجاد کنند که در آن همه کنترل زندگی دیجیتال خود را داشته باشند و از آزادی و حریم خصوصی لذت ببرند.

^۱ Convolutional Neural Networks (CNN)

^۲ Convolutional

^۳ Pooling

^۴ Fully-connected

قبلاً در آن موفقیت فوق العاده‌ای نشان داده است، دارای تعداد نسبتاً کافی داده دارای لیبیل مانند تشخیص علائم راهنمایی و رانندگی، تقسیم تصاویر پزشکی، تشخیص چهره‌ها و متن و عابران پیاده و انسان‌ها در تصاویر طبیعی هستند [۱۵].

در [۱۶] مدلی برای تحلیل یکپارچه از اثرات مشترک عوامل متعددی که بر یک کاربر تأثیر می‌گذارد تا یک توصیه POI را انتخاب کند. یک چارچوب کلی ReGS پیشنهاد شد که CNN را در PMF ادغام می‌کند تا ترجیحات کاربران را برای توصیه POI در شبکه‌های اجتماعی مبتنی بر مکان یاد بگیرد. برای آن روش پیشنهادی چندین مزیت وجود دارد اول: این مدل تأثیر جغرافیایی را بر مکان‌های بازدید شده توسط کاربر به ثبت می‌رساند. اطلاعات بررسی‌های موجود در شبکه‌های اجتماعی مبتنی بر مکان می‌تواند مربوط به مکان‌های بازدید شده کاربر باشد که فرصتی منحصر به فرد برای توصیه POI فراهم می‌کند. در نهایت، یک عملکرد جامع انجام می‌شود. ارزیابی برای ReGS با استفاده از دو مجموعه داده دنیای واقعی جمع‌آوری شده از Foursquare است. نتایج تجربی نشان می‌دهد که ReGS دقت و نرخ فراخوانی بسیار بالاتری نسبت به سایر مدل‌های پیشنهادی پیشرفته به دست می‌آورد.

در [۱۷] یک سیستم توصیه POI طبقه‌بندی فراسطیحی عمیق (DML-SC) را برای گرفتن و رفتارهای کاربران را با ترکیب اطلاعات مکانی و طبقه‌ای پیشنهاد می‌دهد. در مرحله اول، از یک شبکه عصبی بازگشتی برای شناسایی کاربران با کمک قطبیت احساسات کاربران بر اساس نظرات استفاده می‌کند. همچنین یک مکانیسم توجه را برای استخراج موثرترین موارد یکپارچه شد. سپس، یک شبکه عصبی کانولوشنال قرار گرفت که هدف آن تشخیص ترجیحات کاربران از ورودی‌های ناهمگن بر اساس دو عامل تأثیرگذار، یعنی مکان و دسته بندی است. نتایج تجربی روی مجموعه داده‌های واقعی اثربخشی را نشان می‌دهد.

۳-۲ GNN

با ظهور سریع حجم گسترده‌ای از داده‌های گرافی مانند شبکه‌های اجتماعی و گراف‌های دانش تعداد مطالعات بر روی الگوریتم شبکه عصبی گراف (GNN^1) در سال‌های اخیر گسترش یافته است. پیدایش GNN عمدتاً از پیشرفت شبکه عصبی پیچشی و یادگیری نمایش گراف (GRL^2) سرچشمه می‌گیرد. الگوریتم CNN به داده‌های منظم اقلیدسی مانند تصاویر یا متن اعمال می‌شود و در استخراج ویژگی‌های محلی بسیار مؤثر است. با این حال، CNN برای داده‌های غیراقلیدسی مانند گراف‌ها، برای رسیدگی به موقعیت‌هایی که اشیاء عامل (به عنوان مثال، پیکسل‌ها در تصاویر یا نودهای موجود در گراف‌ها) که از نظر اندازه ثابت نیستند، نیاز به تعمیم دارد. هدف GRL تولید بردارهایی با بعد کم برای نودهای گراف، لبه‌ها یا گراف‌های فرعی است که اتصال‌های پیچیده در ساختار گراف‌ها را نشان می‌دهد. با ترکیب CNN و GRL، GNN های مختلفی برای بهبود چکیده ساختار اطلاعات و یادگیری در سطح بالا توسعه می‌یابد [۱۸].

واضح‌ترین دلیل برای استفاده از تکنیک‌های GNN نمایش یادگیری برای داده‌های گراف در حوزه‌های مختلف است. به عنوان مثال، داده‌های تعامل کاربر و آیتم را می‌توان با یک گراف دو طرفه بین نودهای کاربر و آیتم نشان داد. علاوه بر این، دنباله‌ای

¹ Graph Neural Network (GNN)

² Graph Representation Learning (GRL)

از آیت‌ها را می‌توان به دنباله‌ای از گراف‌ها تبدیل کرد که در آن می‌توان هر آیت را به یک یا چند آیت بعدی متصل کرد. در مقایسه با دنباله داده‌های اصلی، دنباله گراف امکان انعطاف پذیری بیشتری را برای روابط آیت به آیت فراهم می‌کند. با توجه به این که انواع مختلف داده‌ها ویژگی‌های مخصوص در سیستم‌های توصیه‌گر دارند، الگوریتم‌ها و مدل‌های متنوعی ارائه شده تا به طور موثر الگوی خود را برای نتایج توصیه بهتر یاد بگیرند که یک چالش بزرگ برای طراحی مدل است. با در نظر گرفتن اطلاعات پیشنهاد شده از منظر گراف، می‌توان از یک چهارچوب GNN برای رسیدگی به این کار استفاده کرد. به عنوان مثال، وظیفه توصیه‌های غیرترتیبی برای یادگیری کارآمد نمایش داده‌ها و نمایش کاربر / آیت و پیش‌بینی بیشتر ترجیحات کاربر است. هر دو نمایش نود و گراف را می‌توان از طریق GNN آموخت. علاوه بر این، ترکیب اطلاعات بیشتر (در صورت موجود بودن)، در مقایسه با دیدگاه غیرگرافی، راحت‌تر و انعطاف پذیرتر است. به عنوان مثال، شبکه اجتماعی می‌تواند به عنوان یک گراف یکپارچه در روابط دو طرفه کاربر و آیت مورد استفاده قرار گیرد [۱۹].

در [۲۰] وانگ و همکاران یک مدل متوالی توجه مبتنی بر شبکه عصبی گراف (ASGNN) را برای توصیه‌های POI دقیق بعدی پیشنهاد می‌کند. به طور خاص، ASGNN ابتدا دنباله مکان‌های بازدید شده کاربر را به عنوان گراف مدل‌سازی می‌کند و سپس از شبکه‌های عصبی گراف (GNN) برای یادگیری ویژگی‌های پنهان با ابعاد پایین اطلاعات استفاده می‌کند. همچنین، یک شبکه توجه سلسله مراتبی شخصی برای بهره‌برداری از همبستگی‌های پیچیده بین کاربران و توصیه‌های POI در توالی‌های ورود و ثبت ترجیحات بلند مدت و کوتاه مدت کاربر اتخاذ شده است. در نهایت، توصیه POI بعدی را از طریق اعمال اولویت‌های بلندمدت و کوتاه‌مدت کاربر که از توالی رفتار آن‌ها با ASGNN به دست آمده، انجام می‌دهد. آزمایش‌های گسترده‌ای بر روی سه مجموعه داده در دنیای واقعی، انجام می‌شود و نتایج نشان می‌دهد که مدل پیشنهادی ASGNN از جمله برخی روش‌های پیشرفته، بهتر عمل می‌کند.

در [۲۱] یک مدل شبکه عصبی گراف مکانی-زمانی مبتنی بر توجه (ATST-GGNN) را برای توصیه‌های POI بعدی پیشنهاد می‌شود. در مرحله اول، ترتیب ورود کاربر به عنوان یک ساختار گرافی نشان داده می‌شود. در مرحله دوم، ما از اطلاعات زمینه مکانی-زمانی برای به‌روزرسانی پویا گره‌ها و گراف‌ها استفاده می‌شود سپس به عنوان ترکیب اولویت بلند و کوتاه با استفاده از شبکه توجه نشان داده می‌شود. نتایج تجربی نشان می‌دهد که میزان دقت و میانگین رتبه‌بندی متقابل روش ATST-GGNN در مقایسه با روش‌های پیشرفته بسیار بهبود یافته است.

در [۲۲] محققین GNN-POI را پیشنهاد می‌کنند که یک چهارچوب توصیه POI عمومی که از شبکه‌های عصبی گراف (GNN) استفاده می‌کند که ظرفیت مدل‌سازی قدرتمندی را برای یادگیری بازنمایی گره از اطلاعات گره و ساختار توپولوژیکی برای بهبود توصیه‌های POI نشان می‌دهند. به طور خاص، یک گراف متشکل از دو نوع گره، یعنی گره کاربر و گره POI در شبکه‌های اجتماعی مبتنی بر مکان می‌سازد. از (Bi-LSTM) برای مدل‌سازی رفتار ورود متوالی کاربران با در نظر گرفتن شرایط جغرافیایی استفاده می‌شود و ویژگی‌های زمانی آزمایش‌های گسترده‌ای که روی سه مجموعه داده واقعی LBSN انجام

شد نشان می‌دهد که چارچوب پیشنهادی مبتنی بر GNN از نظر دقت، فراخوان و (NDCG) به طور قابل توجهی بهتر از توصیه‌های POI پیشرفته است.

۴-۲ GRU

شبکه‌های GRU در دسته RNN ها قرار می‌گیرند. شبکه GRU نوعی از RNN های دروازه‌دار است که برای حل مشکلات رایج محو شدن و منفجر شدن گرادیان در RNN های سنتی هنگام یادگیری وابستگی‌های طولانی مدت استفاده می‌شود. یک لایه ورودی متشکل از نورون‌های متعدد وجود دارد، تعداد نورون‌ها با توجه به اندازه فضای ویژگی مشخص می‌شود. به طور مشابه، تعداد سلول‌های عصبی موجود در لایه خروجی با فضای خروجی مطابقت دارد. لایه یا لایه‌های پنهان حاوی سلول‌های حافظه هستند که کارکرد اصلی شبکه‌های GRU را پوشش می‌دهد. تغییر و نگهداری وضعیت سلول به دو دروازه در سلول بستگی دارد: یک دروازه تنظیم مجدد و یک دروازه به‌روزرسانی دارد [۲۳].

برخلاف شبکه عصبی قدیمی‌تر انتشار معکوس و شبکه عصبی پیچشی، ورودی لایه پنهان RNN نه تنها خروجی لایه بالایی را شامل می‌شود، بلکه خروجی بین نودهای لایه پنهان همان لایه در آخرین زمان است. تعداد زیادی آزمایش نشان می‌دهد که RNN سنتی هنگام یادگیری وابستگی‌های دوربرد با مشکلات زیادی روبرو خواهد شد. در میان آنها، شایع‌ترین مشکل محو شدن یا انفجار گرادیان است. برای حل این مشکل، رایتر و اشمیدهابر [۲۴] یک شبکه LSTM را پیشنهاد کردند که با کنترل دروازه‌های ورودی، دروازه‌های فراموشی و دروازه‌های خروجی، سلول‌های حافظه را می‌خواند و اصلاح می‌کند و سپس از توابع مختلف برای به‌روزرسانی وضعیت لایه پنهان استفاده می‌کند. LSTM تاکنون یکی از محبوب‌ترین معماری‌های RNN است و در زمینه‌های مختلف موفقیت‌های بزرگی کسب کرده است. اگر چه صحت LSTM از سایر الگوریتم‌ها بالاتر است، اما زمان آموزش LSTM از سایر الگوریتم‌ها طولانی‌تر است. چگونگی کاهش زمان آموزش هنوز مشکلی است که ارزش مطالعه دارد. GRU یک مورد خاص از LSTM است که توسط چو [۲۵] در سال ۲۰۱۴ پیشنهاد شده است. عملکرد آن در مدل‌سازی سیگنال گفتار شبیه LSTM است. علاوه بر این، زمان آموزش کوتاه‌تری نسبت به LSTM سنتی دارد و پارامترهای کمتری نسبت به LSTM دارد، زیرا فاقد دروازه خروجی هستند [۲۶].

در [۲۷] لیو و همکاران مدلی را پیشنهاد دادند که ابتدا یک نوع جدید از GRU طراحی شد. این مدل ترجیحات متوالی و اولویت مکانی-زمانی کاربر را با اطلاعات فاصله جغرافیایی پیوسته و بازه زمانی در هر مرحله زمانی به دست آورد. سپس، آن‌ها یک مدل توجه را در شبکه خود ادغام کردند، که یک فرآیند شخصی‌سازی شده است و می‌تواند قصد رفتاری اصلی کاربر را در تاریخچه مکان‌های بازدید شده کاربر ثبت کند. علاوه بر این، یک ارزیابی عملکرد گسترده بر روی دو مجموعه داده دنیای واقعی یعنی Foursquare و Gowalla انجام دادند. نتایج تجربی نشان می‌دهد که مدل پیشنهادی ATST-GRU از عملکرد بهتری نسبت به سایر مدل‌های پیشنهادی برخوردار است و همچنین از دو معیار ارزیابی روش‌های پیشنهادی پیشرفته توصیه POI موجود استفاده می‌شود.

۵-۲ BI-LSTM

BI-LSTM نسخه‌ای از معماری LSTM است که از زمینه‌های آینده و همچنین گذشته بهره‌برداری می‌کند. یعنی در مشکلات رونویسی توالی، دسترسی به موارد بعدی توالی (آینده) برای استنتاج خروجی‌های جریان صحیح می‌تواند مفید باشد. در BI-LSTM، یک طرفه‌های معمولی با هم ترکیب می‌شوند. شبکه LSTM با دنباله‌های گذشته با شبکه یک طرفه دیگری که با آینده کار می‌کند. با پردازش داده‌ها در هر دو جهت، مدل قادر است رابطه بین توالی‌ها را بهتر درک کند.

در [۲۹] سه کار نوآورانه انجام شده است. (۱) یک گراف از مکان‌های بازدید شده می‌سازد و الگوریتم DeepWalk را برای یادگیری توصیه POI اتخاذ می‌کند. (۲) یک مدل شبکه عصبی ایجاد شد که توسط یک BI-LSTM، یک شبکه توجه و یک شبکه حافظه، برای درک ویژگی‌های حافظه موجود در تاریخچه مکان‌های بازدید شده استفاده می‌شود. (۳) یک فیلتر برای کاندید شدن توصیه POI جدید پیشنهاد می‌کند، روشی که امتیاز رتبه‌بندی را با ارزیابی فاصله اقلیدسی بین بردارها توصیه POI کاندید و مرکز علاقه را به روز می‌کند. عملکرد روش بر روی چهار مجموعه داده بررسی در دنیای واقعی ساخته شده از Foursquare ارزیابی می‌شود.

در [۳۰] باو و همکاران در این مطالعه مدلی را پیشنهاد می‌کنند که از برچسب‌های جغرافیایی شبکه‌های اجتماعی برای پیش‌بینی مکان‌های بعدی کاربران استفاده می‌کند. در مدل پیشنهادی از الگوریتم HiSpatialCluster برای شناسایی مناطق خوشه‌بندی (CAs) از مکان‌های بازدید شده استفاده می‌کند. مناطق خوشه‌بندی واحد مکانی پایه برای پیش‌بینی مکان‌های بعدی کاربران است. سپس، از LINE برای به دست آوردن بردار نمایش هر منطقه خوشه‌بندی استفاده می‌شود. در نهایت، BiLSTM-CNN برای پیش‌بینی مکان اعمال می‌شود. نتایج نشان می‌دهد که مدل مجموعه پیشنهادی بهتر از مدل‌های LSTM یا CNN است. در مطالعه موردی که صد منطقه خوشه‌بندی خارج از مکان‌های بازدید شده Weibo جمع‌آوری شده در ووهان، چین را شناسایی کرد، پنج منطقه برتر پیش‌بینی شده حاوی مکان‌های بعدی با دقت هشتاد درصد می‌باشد. دقت بالا از ارزش عالی برای توصیه و پیش‌بینی در واحد منطقه‌ای برخوردار است.

۲-۶ سایر الگوریتم‌های یادگیری عمیق

در [۳۱] در این مقاله، یک توصیه POI با چهارچوبی با نام RecNet پیشنهاد شده است که بر اساس آن در یک شبکه عصبی عمیق DNN توسعه یافته تا برای ترکیب ویژگی‌های مختلف در شبکه‌های اجتماعی مبتنی بر مکان و تأثیر مشترک آنها بر رفتار کاربر را یاد بگیرند. به طور خاص، بازدید از مکان‌های مشترک، طول و عرض جغرافیایی و طبقه‌بندی در شبکه‌های اجتماعی مبتنی بر مکان برای کاهش مشکل پراکندگی داده‌ها در توصیه POI مورد استفاده قرار می‌گیرند و به نمایش برداری ویژگی‌های توصیه POI و کاربران از طریق تعبیه ویژگی تبدیل می‌شوند.

در جدول ۱ خلاصه‌ای بر مدل‌های پیشنهادی در توصیه POI که مبتنی بر الگوریتم‌های یادگیری عمیق هستند، بررسی می‌شود.

جدول ۱- خلاصه‌ای از الگوریتم‌های یادگیری عمیق استفاده شده در توصیه POI

مرجع	مدل پیشنهادی	سال چاپ	GAT	MLP	GRU	BILSTM	CNN	LSTM	DNN	GCN	GNN
[۲۷]	ATST-GRU	۲۰۱۹			✓						
[۳۰]	BiLSTM_CNN	۲۰۲۰				✓	✓				
[۱۱]		۲۰۲۰						✓			
[۱۰]	Loc-Interest-LSTM	۲۰۲۰						✓			
[۳۱]	RecNet	۲۰۱۸							✓		
[۲۹]		۲۰۲۳		✓		✓					
[۳۲]	MGCAN	۲۰۲۲								✓	
[۳۳]	PGD	۲۰۲۲								✓	
[۲۰]	ASGNN	۲۰۲۱									✓
[۳۴]	GSTA-GNN	۲۰۲۲									✓
[۳۵]	MI-GNN	۲۰۲۳									✓
[۳۶]	GSTN	۲۰۲۲						✓			
[۳۷]	HAGCN	۲۰۲۳								✓	
[۳۸]	RMGCN	۲۰۲۲								✓	
[۱۶]	ReGS	۲۰۱۸					✓				
[۲۲]	GNN-POI	۲۰۲۱				✓					✓
[۳۹]	PPR	۲۰۲۲		✓				✓			
[۴۰]	Graph-POIR	۲۰۲۳		✓							✓
[۴۱]	MGRU	۲۰۱۹			✓						
[۱۷]	DML-SC	۲۰۲۳					✓	✓			
[۲۱]	ATST-GGNN	۲۰۲۲									✓

۳- مجموعه داده‌های به کار برده شده در توصیه POI

مجموعه داده‌های مختلفی در زمینه سیستم‌های توصیه‌گر به کار برده شده‌اند. در ادامه به برخی مجموعه داده‌های پرکاربردتر در این حوزه پرداخته می‌شود.

۱-۳ مجموعه داده Foursquare

مجموعه داده Foursquare شامل داده‌های مکان‌های بازدید شده در شهرهای مختلف و دارای مزیت‌های زیادی مثل ساختار سلسله مراتبی تعریف شده با توجه به توضیحات مکانی آن‌ها است. این موضوع باعث می‌شود که مجموعه داده Foursquare برای بررسی‌ها و تجزیه و تحلیل رفتار مکانی و زمانی کاربران بسیار ارزشمند باشد زیرا امکان توصیف دقیق مکان‌های بازدید شده را فراهم می‌کند. این مزیت زمانی ارزشمندتر است که در نظر بگیریم سلسله مراتب یک سلسله مراتب تحمیلی معتبر نیست، بلکه توسط خود کاربران مورد توافق قرار گرفته است و بعداً در سطح جهانی استاندارد شده است. بنابراین، مقوله‌های خاص به جای برخی سازمان‌ها آنچه را که به کاربران مرتبط است، منعکس می‌کنند [۴۲]. جزئیات دسته‌بندی مختلف این مجموعه داده در جدول ۲ ارائه شده است [۴۳].

جدول ۲- مشخصات مجموعه داده Foursquare

نام مجموعه داده	تعداد داده‌ها	زمان داده‌ها	توضیحات
مجموعه داده رستوران‌های نیویورک	۳۱۱۲ کاربر ۲۷۱۴۹ مکان بازدید شده ۱۰۳۷۷ نظر	از ۲۴ اکتبر ۲۰۱۱ تا ۲۰ فوریه ۲۰۱۲	
مجموعه داده مکان‌های بازدید شده در توکیو و نیویورک	۲۲۶۴۲۸ مکان بازدید شده در نیویورک ۵۷۳۷۰۳ مکان بازدید شده در توکیو	از ۱۲ آوریل ۲۰۱۲ تا ۱۶ فوریه ۲۰۱۳	این مجموعه داده برای تحقیق‌های مکانی-زمانی فعالیت کاربر استفاده می‌شود
مجموعه داده مکان‌های بازدید شده جهانی	۳۳۲۷۸۶۸۳ مکان بازدید شده توسط ۲۶۶۹۰۹ کاربر ۴۱۵ شهر ۷۷ کشور	از آوریل ۲۰۱۲ تا سپتامبر ۲۰۱۳	
مجموعه داده پروفایل کاربران	۱۸۲۰۱ و ۱۱۸۷۴ کاربر که شهرهای توکیو و نیویورک را بازدید کرده بودند		این مجموعه داده اغلب برای تحقیق‌های بخش حریم خصوصی مورد استفاده قرار می‌گیرد.
مجموعه داده مکان‌های بازدید شده در جهان و شبکه‌های اجتماعی کاربران	۲۲۸۰۹ مکان بازدید شده ۱۱۴۳۲۴ کاربر	از آوریل ۲۰۱۲ تا ژانویه ۲۰۱۴	

۲-۳ مجموعه داده Gowalla

Gowalla یک وب سایت شبکه اجتماعی مبتنی بر مکان است که در آن کاربران مکان‌های بازدید شده خود را به اشتراک می‌گذارند. شبکه دوستی بدون جهت است و با استفاده از API عمومی آن‌ها جمع‌آوری شده است و از ۱۹۶۵۹۱ رأس و ۹۵۰۳۲۷ یال تشکیل شده است. در مجموع ۶،۴۴۲،۸۹۰ اعلام مکان‌های بازدید شده از این کاربران در دوره فوریه ۲۰۰۹ تا اکتبر ۲۰۱۰ جمع‌آوری شده است. فایل‌های کلی‌تر این مجموعه داده در جدول ۳ شرح داده شده است [۴۴]، [۴۵].

جدول ۳- مشخصات مجموعه داده Gowalla

نام فایل	ستون‌ها	توضیحات
Gowalla edges	User,user	شبکه دوستی کاربران Gowalla

اطلاعات زمان و مکان‌های بازدید شده توسط کاربران	User, check-in time, latitude, longitude, location id	Gowalla total Check-ins
--	--	-------------------------

۳-۳ مجموعه داده Brightkite

زمانی یک ارائه‌دهنده خدمات شبکه اجتماعی مبتنی بر مکان بود که در آن کاربران مکان‌های بازدید شده خود را با به اشتراک می‌گذاشتند. شبکه دوستی با استفاده از API عمومی آنها جمع‌آوری شد و از ۵۸۲۲۸ نود و ۲۱۴۰۷۸ یال تشکیل شده است. این شبکه در اصل یک طرفه است، اما شبکه‌ای با لبه‌های هدایت نشده ساخته شده که دوستی از هر دو طرف وجود داشته باشد. همچنین در مجموع ۴,۴۹۱,۱۴۳ اعلام مکان بازدید شده از این کاربران در دوره آوریل ۲۰۰۸ تا اکتبر ۲۰۱۰ جمع‌آوری شده و فایل‌های کلی‌تر این مجموعه داده در جدول ۴ شرح داده شده است [۴۴], [۴۶].

جدول ۴- مشخصات مجموعه داده brightkite

نام فایل	ستون‌ها	توضیحات
Brightkite edges	User, user	شبکه دوستی کاربران Brightkite
Brightkite total Check-ins	User, check-in time, latitude, longitude, location id	اطلاعات زمان و مکان‌های بازدید شده توسط کاربران

۴-۳ مجموعه داده Yelp

مجموعه داده Yelp زیرمجموعه‌ای از کسب‌وکارها، نظرات و داده‌های کاربران برای استفاده در اهداف شخصی، آموزشی و دانشگاهی است که در قالب فایل‌های JSON موجود است. از آن برای آموزش دانشجویان در مورد پایگاه‌های داده، یادگیری پردازش زبان طبیعی یا برای نمونه داده‌های تولید در ساخت برنامه‌های تلفن همراه می‌تواند مورد استفاده قرار گیرد. به طور کلی مجموعه داده شامل ۹۰۸,۹۱۵ نظر که توسط ۱,۹۸۷,۸۹۷ کاربر و بیش از ۱,۲ میلیون ویژگی تجاری مانند ساعت، پارکینگ، در دسترس بودن و محیط است. تجمیع مکان‌های بازدید شده در طول زمان برای هر یک از ۱۳۱۹۳۰ کسب‌وکار نیز وجود دارد. فایل‌های جزئی‌تر این مجموعه داده در جدول ۵ شرح داده شده است [۴۷].

جدول ۵- برخی از مشخصات مجموعه داده Yelp

نام فایل	نام ویژگی	نوع ویژگی	توضیحات ویژگی
business.js on	business_id	string	شناسه کسب‌وکار منحصر به فرد ۲۲ کاراکتری
	name	string	نام کسب‌وکار
	address	string	آدرس کامل کسب‌وکار

	latitude	float	عرض جغرافیایی
	longitud	float	طول جغرافیایی
review.json	review_id	string	شناسه نظر منحصر به فرد ۲۲ کاراکتری
	stars	integer	ستاره‌های رتبه بندی
	date	string	تاریخ با فرمت YYYY-MM-DD
	text	string	متن نظر
user.json	user_id	string	شناسه کاربری منحصر به فرد ۲۲ کاراکتری، منطبق بر کاربر در user.json
	name	string	نام کاربر
	review_count	integer	تعداد نظرهای نوشته شده
	yelping_since	string	تاریخ پیوستن به Yelp با فرمت YYYY-MM-DD
checkin.json	business_id	string	شناسه کسب‌وکار ۲۲ کاراکتری، منطبق بر کسب‌وکار در business.json
	date	string	فهرستی از مهرهای زمانی جدا شده با کاما برای هر اعلام حضور، هرکدام با فرمت YYYY-MM-DD HH:MM:SS
tip.json	text	string	متن نظر
	date	string	زمان نوشتن نظر با فرمت YYYY-MM-DD
photo.json	photo_id	string	شناسه عکس منحصر به فرد ۲۲ کاراکتری

business_id	string	شناسه کسب‌وکار ۲۲ کاراکتری، منطبق بر کسب‌وکار در business.json
label	string	دسته‌بندی عکس

در جدول ۶ خلاصه‌ای از مجموعه داده‌ها بیان شده است.

جدول ۶- مقایسه مشخصات مجموعه داده‌های استفاده شده در توصیه POI

مرجع	Reddit	Trivago	Jdata	Yelp	Brightkite	Weibo	Gowalla	Foursquare
[۲۷]							✓	✓
[۳۰]						✓		
[۱۱]								بخش‌هایی از مجموعه داده استفاده شده است. ✓
[۱۰]					✓		✓	
[۳۱]							✓	✓
[۲۹]								بخش‌هایی از مجموعه داده استفاده شده است. ✓
[۳۲]								بخش‌هایی از مجموعه داده استفاده شده است. ✓
[۳۳]				✓			✓	✓
[۲۰]					✓		✓	✓
[۳۴]							✓	بخش‌هایی از مجموعه داده استفاده شده است. ✓
[۳۵]	✓	✓	✓					
[۳۶]					✓		✓	✓
[۳۷]								بخش‌هایی از مجموعه داده استفاده شده است. ✓
[۳۸]				✓				بخش‌هایی از مجموعه داده‌ها استفاده شده است. ✓
[۱۶]								بخش‌هایی از مجموعه داده استفاده شده است. ✓
[۲۲]				✓			✓	✓
[۳۹]					✓		✓	✓
[۴۰]				✓				بخش‌هایی از مجموعه داده استفاده شده است. ✓
[۴۱]							✓	✓
[۱۷]				✓				✓
[۲۱]							✓	✓

۴- معیارهای ارزیابی مورد استفاده در توصیه POI

معیارهای ارزیابی مختلفی در زمینه سیستم‌های توصیه‌گر به کار برده شده‌اند. در ادامه به برخی معیارهای پرکاربردتر در این حوزه پرداخته می‌شود.

فراخوانی^۱: از بین مکان‌های بازدید شده، چند درصد توصیه شده است. به عبارت دیگر کسری از مواردی که توصیه به کاربران با موفقیت انجام می‌شود و توسط رابطه (۱) قابل محاسبه خواهد بود [۴۸]، [۴۹].

$$Recall = \frac{TP}{TP + FN} \quad (1)$$

دقت^۲: چند درصد از موارد توصیه شده، بازدید شده است. به عبارت دیگر کسری از موارد توصیه شده که واقعاً مورد علاقه کاربر بوده است. این معیار توسط رابطه (۲) قابل محاسبه خواهد بود [۴۸]، [۴۹].

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

معیار **F**^۳: یک نوع میانگین بین پارامتر Precision و پارامتر Recall است که توسط رابطه (۳) محاسبه می‌شود.

$$F - Measure = \frac{2 \times (Precision \times Recall)}{precision + Recall} \quad (3)$$

میانگین رتبه متقابل^۴: این معیار ارزیابی رتبه اولین آیتم مورد علاقه پیدا شده در لیست توصیه‌ها را بررسی می‌کند. اگر MRR نزدیک به یک باشد، به این معنی است که نتایج مورد علاقه نزدیک به بالای نتایج جستجو هستند. MRR های پایین‌تر نشان دهنده کیفیت جستجوی ضعیف‌تر و پاسخ مناسب در نتایج جستجو پایین‌تر که با رابطه (۴) قابل محاسبه است.

$$MRR = \frac{1}{|U|} \sum_{u=1}^U \frac{1}{rank_u} \quad (4)$$

NDCG: اندازه‌گیری اثربخشی یک سیستم رتبه بندی، با در نظر گرفتن موقعیت موارد مرتبط در لیست رتبه بندی شده. براساس این ایده است که به مواردی که در رده بندی بالاتر هستند باید اعتبار بیشتری نسبت به مواردی که در رتبه بندی پایین‌تر هستند، داده شود. رابطه این معیار در (۵) بیان شده است.

$$NDCG = \frac{DCG@K}{IDCG@K} \quad (5)$$

صحت^۵: این معیار نشان می‌دهد که چه درصدی از مدل پیشنهادی درست بوده است که رابطه آن در (۶) مشاهده می‌شود.

$$Accuracy = \frac{Correct\ Predictions}{Total\ Cases} \times 100 \quad (6)$$

^۱ Recall

^۲ Precision

^۳ F-measure

^۴ Mean Reciprocal Rank (MRR)

^۵ Accuracy

میانگین مطلق خطا^۱: این معیار یکی از ساده‌ترین توابع ضرر و یک معیار ارزیابی است که رابطه آن در (۷) مشاهده می‌شود.

$$MAE = \frac{1}{N} \sum_{i=0}^n |Y_i - \hat{Y}_i| \quad (7)$$

میانگین متوسط دقت^۲: میانگین دقت متوسط برای مجموعه‌ای از پرس و جوها، میانگین نمرات دقت متوسط برای هر پرس و جو است که رابطه آن در (۸) مشاهده می‌شود.

$$MAP = \frac{\sum_{q=1}^Q AveP(q)}{Q} \quad (8)$$

در جدول ۷ معیارهای ارزیابی در توصیه POI به طور خلاصه آورده شده است.

جدول ۷- معیارهای ارزیابی در سیستم‌های پیشنهاد POI

Recall	F1-score	Accuracy	Precision	MR R	cross- entropy loss	NDCG	MAP	MAE	RMSE	MSE	مرجع
✓	✓										[۲۷]
		✓									[۳۰]
✓			✓								[۱۱]
✓	✓		✓								[۱۰]
✓			✓	✓							[۳۱]
✓			✓	✓		✓					[۲۹]
✓						✓					[۳۲]
✓			✓								[۳۳]
✓				✓							[۲۰]
✓						✓					[۳۴]
			✓	✓		✓					[۳۵]
✓						✓					[۳۶]
			✓				✓				[۳۷]
✓			✓								[۳۸]
✓			✓								[۱۶]
✓			✓			✓					[۲۲]
✓		✓	✓								[۳۹]
✓			✓				✓	✓	✓		[۲۰]

^۱ Mean Absolute Error (MAE)

^۲ Mean Average Precision (MAP)

✓						✓					[۴۱]
		✓	✓		✓			✓		✓	[۱۷]
			✓	✓							[۲۱]

۵- ابزارهای پیاده‌سازی مورد استفاده در توصیه POI

در جدول ۸ ابزارهای پیاده‌سازی مدل پیشنهادی ارائه شده است. البته تعدادی از منابع ابزارهای پیاده‌سازی مورد استفاده قرار گرفته شده توسط محققین را ذکر نکرده‌اند.

جدول ۸- ابزارهای پیاده‌سازی در سیستم‌های توصیه POI

Tensorflow	Keras	Python	PyTorch	Theano	مرجع
		✓		✓	[۲۷]
	✓				[۳۰]
✓	✓				[۲۹]
✓		✓			[۳۲]
					[۳۳]
✓		✓			[۲۰]
		✓	✓		[۳۵]
✓					[۳۶]
		✓			[۱۷]
		✓			[۲۱]

۶- تحلیل نتایج


در این بخش به تحلیل مجموعه داده استفاده شده، الگوریتم‌های یادگیری عمیق مختلف، معیارهای ارزیابی و ابزارهای لازم برای پیاده‌سازی مدل پیشنهادی و تحلیل و ارزیابی نتایج پرداخته می‌شود.

۶-۱ الگوریتم‌های یادگیری عمیق در توصیه POI

فراوانی به‌کارگیری الگوریتم‌های مختلف حوزه یادگیری عمیق در مبحث توصیه POI در شکل ۲ ارائه شده است.

ستون‌ها در شکل ۲ بیانگر تعداد دفعاتی هستند که از یک الگوریتم یادگیری عمیق استفاده شده است. نمودار ارائه شده در شکل دو نشان می‌دهد که الگوریتم GNN با شش تکرار در تحقیق‌ها بیشترین استفاده را نسبت به سایر الگوریتم‌های یادگیری عمیق

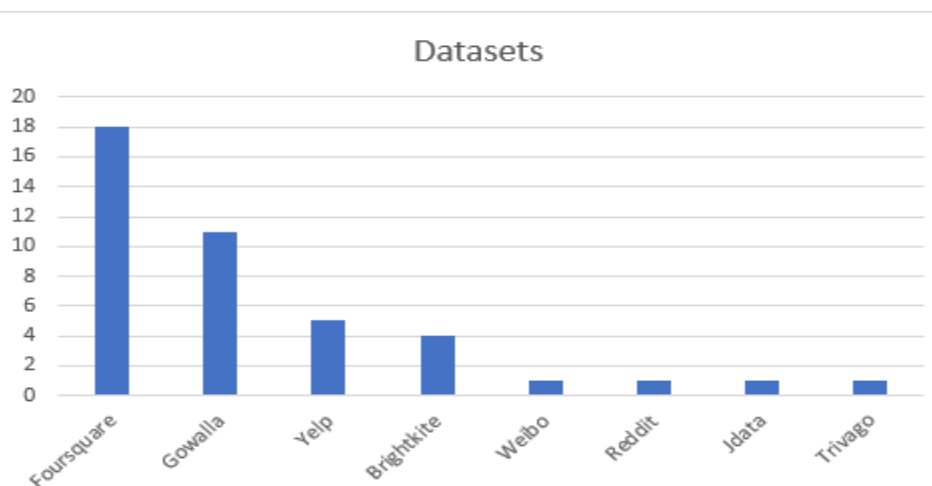
داشته است و بعد از آن LSTM با پنج بار و GCN با چهار بار و CNN، BILSTM و MLP با سه بار بیشترین تکرارها را در الگوریتم‌ها داشته‌اند. در تعدادی از تحقیق‌ها نیز از دو الگوریتم یادگیری عمیق استفاده شده است.



شکل ۲- مقایسه فراوانی به‌کارگیری الگوریتم‌های مختلف یادگیری عمیق در توصیه POI

۲-۶ مجموعه داده‌ها در توصیه POI

بررسی و ارزیابی فراوانی استفاده از مجموعه داده‌های مختلف تحقیقات توصیه POI در شکل ۳ ارائه شده است.




شکل ۳- مقایسه فراوانی به‌کارگیری مجموعه داده‌ها در توصیه POI

ستون‌ها در شکل ۳ نشان دهنده تعداد دفعه استفاده از مجموعه داده در تحقیق و سطرها نام مجموعه داده‌ها است. در برخی از تحقیق‌ها از بیش از یک مجموعه داده استفاده شده است. به طور کلی مجموعه داده Foursquare با ۱۸ بار استفاده بالاترین مجموعه داده بررسی شده و با توجه به این که تعداد کل تحقیق‌ها ۲۱ تحقیق است می‌توان گفت که این مجموعه داده در اکثر

تحقیق‌ها استفاده شده است. مجموعه داده Gowalla با ۱۱ بار تکرار و Yelp با ۵ تکرار و Brightkite با ۴ تکرار سایر مجموعه داده‌های مورد استفاده قرار گرفته شده هستند. از سایر مجموعه داده‌ها نیز تنها در یک تحقیق استفاده شده است.

۳-۶ معیارهای ارزیابی در توصیه POI

بررسی و ارزیابی فراوانی معیارهای ارزیابی درسیستم‌های توصیه POI در شکل ۴ ارائه شده است.




شکل ۴. فراوانی معیارهای ارزیابی درسیستم‌های توصیه POI

در اکثر تحقیق‌ها از بیش از یک معیار ارزیابی استفاده شده است. در شکل ۴ مشاهده می‌شود که معیارهای Recall و Precision با ۱۶ و ۱۴ بار تکرار بیشترین استفاده را نسبت به سایر معیارها داشته‌اند و سایر معیارها کمتر از ۸ بار تکرار را دارند.

۴-۶ ابزارهای پیاده‌سازی در توصیه POI

بررسی و ارزیابی فراوانی ابزارهای پیاده‌سازی در توصیه POI در شکل ۵ ارائه شده است.



شکل ۵- فراوانی ابزارهای پیاده سازی در POI

از بین ۲۱ تحقیق تنها ۹ تحقیق ابزار پیاده سازی خود را معرفی کرده‌اند. از میان این ۹ تحقیق پایتون با استفاده در ۴۳ درصد تحقیق‌ها و Tensorflow با ۲۹ درصد تحقیق‌ها بیشترین استفاده را دارند.

۷- نتیجه‌گیری و کارهای آینده

در این تحقیق مروری بر الگوریتم‌های یادگیری عمیق به کار برده شده در مدل‌های پیشنهاد POI انجام شد. ۲۱ کار تحقیقاتی جدید از نظر الگوریتم یادگیری عمیق استفاده شده، مجموعه داده‌ها، معیارهای ارزیابی و ابزارهای پیاده سازی مورد بررسی قرار گرفتند. علاوه بر این، این تحقیق مروری روندها و جهت‌گیری‌های جدید در این حوزه را نشان می‌دهد. در این حوزه در اکثر تحقیق‌ها از یک مجموعه داده و معیار ثابت استفاده شده است. برای کارهای آینده پیشنهاد می‌شود که مدل‌های پیشنهادی بر روی سایر مجموعه داده‌ها نیز اعمال و از سایر مدل‌های ارزیابی نیز استفاده شود.

مراجع

- [1] Q. Yuan, G. Cong, Z. Ma, A. Sun, and N. Magnenat-Thalmann, "Time-aware point-of-interest recommendation," *SIGIR 2013 - Proceedings of the 36th International ACM SIGIR Conference on Research and Development in Information Retrieval*, pp. 363–372, 2013, doi: 10.1145/2484028.2484030.
- [2] H. Werneck, N. Silva, M. C. Viana, F. Mourão, A. C. M. Pereira, and L. Rocha, "A Survey of Point-of-interest Recommendation in Location-based Social Networks," *ACM International Conference Proceeding Series*, pp. 185–192, Jul. 2016, doi: 10.1145/3428658.3430970.
- [3] J. Guo, W. Zhang, W. Fan, and W. Li, "Combining Geographical and Social Influences with Deep Learning for Personalized Point-of-Interest Recommendation,"

- <https://doi.org/10.1080/07421222.2018.1523564>, vol. 35, no. 4, pp. 1121–1153, Oct. 2018, doi: 10.1080/07421222.2018.1523564.
- [4] A. Mathew, P. Amudha, and S. Sivakumari, “Deep learning techniques: an overview,” *Advances in Intelligent Systems and Computing*, vol. 1141, pp. 599–608, 2021, doi: 10.1007/978-981-15-3383-9_54/COVER.
- [5] Y. Lecun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature* 2015 521:7553, vol. 521, no. 7553, pp. 436–444, May 2015, doi: 10.1038/nature14539.
- [6] L. Deng and D. Yu, “Deep Learning: Methods and Applications,” *Foundations and Trends® in Signal Processing*, vol. 7, no. 3–4, pp. 197–387, 2014, doi: 10.1561/20000000039.
- [7] Y. Chen *et al.*, “Points-of-Interest Relationship Inference with Spatial-enriched Graph Neural Networks,” *Points-of-Interest Relationship Inference with Spatial-enriched Graph Neural Networks. PVLDB*, vol. 15, no. 3, Feb. 2022, Accessed: Jul. 07, 2023. [Online]. Available: <https://arxiv.org/abs/2202.13686v1>
- [8] Y. Liu *et al.*, “Interaction-Enhanced and Time-Aware Graph Convolutional Network for Successive Point-of-Interest Recommendation in Traveling Enterprises,” *IEEE Trans Industr Inform*, vol. 19, no. 1, pp. 635–643, Jan. 2023, doi: 10.1109/TII.2022.3200067.
- [9] G. Van Houdt, C. Mosquera, and G. Nápoles, “A review on the long short-term memory model,” *Artif Intell Rev*, vol. 53, no. 8, pp. 5929–5955, Dec. 2020, doi: 10.1007/S10462-020-09838-1/METRICS.
- [10] M. Chen, W. Z. Li, L. Qian, S. L. Lu, and D. X. Chen, “Next POI Recommendation Based on Location Interest Mining with Recurrent Neural Networks,” *J Comput Sci Technol*, vol. 35, no. 3, pp. 603–616, May 2020, doi: 10.1007/S11390-020-9107-3/METRICS.
- [11] Y. Ma and M. Gan, “Exploring multiple spatio-temporal information for point-of-interest recommendation,” *Soft comput*, vol. 24, no. 24, pp. 18733–18747, Dec. 2020, doi: 10.1007/S00500-020-05107-Z/METRICS.
- [12] Y. LeCun *et al.*, “Handwritten Digit Recognition with a Back-Propagation Network,” *Adv Neural Inf Process Syst*, vol. 2, 1989.
- [13] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, “Gradient-based learning applied to document recognition,” *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2323, 1998, doi: 10.1109/5.726791.
- [14] J. Gu *et al.*, “Recent advances in convolutional neural networks,” *Pattern Recognit*, vol. 77, pp. 354–377, May 2018, doi: 10.1016/J.PATCOG.2017.10.013.
- [15] A. Khan, A. Sohail, U. Zahoor, and A. S. Qureshi, “A survey of the recent architectures of deep convolutional neural networks,” *Artificial Intelligence Review 2020 53:8*, vol. 53, no. 8, pp. 5455–5516, Apr. 2020, doi: 10.1007/S10462-020-09825-6.
- [16] S. Xing, F. Liu, X. Zhao, and T. Li, “Points-of-interest recommendation based on convolution matrix factorization,” *Applied Intelligence*, vol. 48, no. 8, pp. 2458–2469, Aug. 2018, doi: 10.1007/S10489-017-1103-0/METRICS.

- [17] C. Laroussi and R. Ayachi, "A deep meta-level spatio-categorical POI recommender system," *Int J Data Sci Anal*, pp. 1–15, Mar. 2023, doi: 10.1007/S41060-023-00385-W/METRICS.
- [18] GaoChen *et al.*, "A Survey of Graph Neural Networks for Recommender Systems: Challenges, Methods, and Directions," *ACM Transactions on Recommender Systems*, vol. 1, no. 1, pp. 1–51, Mar. 2023, doi: 10.1145/3568022.
- [19] S. Wu, F. Sun, W. Zhang, X. Xie, and B. Cui, "Graph Neural Networks in Recommender Systems: A Survey," *ACM Comput Surv*, vol. 55, no. 5, p. 97, Dec. 2022, doi: 10.1145/3535101.
- [20] D. Wang, X. Wang, Z. Xiang, D. Yu, S. Deng, and G. Xu, "Attentive sequential model based on graph neural network for next poi recommendation," *World Wide Web*, vol. 24, no. 6, pp. 2161–2184, Nov. 2021, doi: 10.1007/S11280-021-00961-9/METRICS.
- [21] Q. Li, X. Xu, X. Liu, and Q. Chen, "An Attention-Based Spatiotemporal GGNN for Next POI Recommendation," *IEEE Access*, vol. 10, pp. 26471–26480, 2022, doi: 10.1109/ACCESS.2022.3156618.
- [22] J. Zhang, X. Liu, X. Zhou, and X. Chu, "Leveraging graph neural networks for point-of-interest recommendations," *Neurocomputing*, vol. 462, pp. 1–13, Oct. 2021, doi: 10.1016/J.NEUCOM.2021.07.063.
- [23] G. Shen, Q. Tan, H. Zhang, P. Zeng, and J. Xu, "Deep Learning with Gated Recurrent Unit Networks for Financial Sequence Predictions," *Procedia Comput Sci*, vol. 131, pp. 895–903, Jan. 2018, doi: 10.1016/J.PROCS.2018.04.298.
- [24] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Comput*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: 10.1162/NECO.1997.9.8.1735.
- [25] K. Cho *et al.*, "Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation," *EMNLP 2014 - 2014 Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference*, pp. 1724–1734, Jun. 2014, doi: 10.3115/v1/d14-1179.
- [26] Y. Wang, W. Liao, and Y. Chang, "Gated Recurrent Unit Network-Based Short-Term Photovoltaic Forecasting," *Energies 2018, Vol. 11, Page 2163*, vol. 11, no. 8, p. 2163, Aug. 2018, doi: 10.3390/EN11082163.
- [27] C. Liu, J. Liu, J. Wang, S. Xu, H. Han, and Y. Chen, "An Attention-Based Spatiotemporal Gated Recurrent Unit Network for Point-of-Interest Recommendation," *ISPRS Int J Geoinf*, vol. 8, no. 8, Aug. 2019, doi: 10.3390/ijgi8080355.
- [28] A. Preprint, G. A. Abandah, A. Suyyagh, and M. Z. Khedher, "Correcting Arabic Soft Spelling Mistakes using BiLSTM-based Machine Learning," Aug. 2021, Accessed: Sep. 11, 2023. [Online]. Available: <https://arxiv.org/abs/2108.01141v1>
- [29] M. Gan and Y. Ma, "Mapping user interest into hyper-spherical space: A novel POI recommendation method," *Inf Process Manag*, vol. 60, no. 2, p. 103169, Mar. 2023, doi: 10.1016/J.IPM.2022.103169.
- [30] Y. Bao, Z. Huang, L. Li, Y. Wang, and Y. Liu, "A BiLSTM-CNN model for predicting users' next locations based on geotagged social media,"

- <https://doi.org/10.1080/13658816.2020.1808896>, vol. 35, no. 4, pp. 639–660, 2020, doi: 10.1080/13658816.2020.1808896.
- [31] R. Ding and Z. Chen, “RecNet: a deep neural network for personalized POI recommendation in location-based social networks,” <https://doi.org/10.1080/13658816.2018.1447671>, vol. 32, no. 8, pp. 1631–1648, Aug. 2018, doi: 10.1080/13658816.2018.1447671.
- [32] M. Gan and C. Tan, “Mining multiple sequential patterns through multi-graph representation for next point-of-interest recommendation,” *World Wide Web*, pp. 1–26, Aug. 2022, doi: 10.1007/S11280-022-01094-3/METRICS.
- [33] T. Shu, L. Shi, C. Zhu, and X. Liu, “A graph neural network framework based on preference-aware graph diffusion for recommendation,” *Front Psychiatry*, vol. 13, p. 2235, Oct. 2022, doi: 10.3389/FPSYT.2022.1012980/BIBTEX.
- [34] J. Wang, B. Yang, H. Liu, and D. Li, “Global spatio-temporal aware graph neural network for next point-of-interest recommendation,” *Applied Intelligence*, pp. 1–14, Dec. 2022, doi: 10.1007/S10489-022-04377-4/METRICS.
- [35] WangTing-Yun, ChenChiao-Ting, HuangJu-Chun, and HuangSzu-Hao, “Modeling Cross-session Information with Multi-interest Graph Neural Networks for the Next-item Recommendation,” *ACM Trans Knowl Discov Data*, vol. 17, no. 1, pp. 1–28, Feb. 2023, doi: 10.1145/3532192.
- [36] Z. Wang, Y. Zhu, Q. Zhang, H. Liu, C. Wang, and T. Liu, “Graph-Enhanced Spatial-Temporal Network for Next POI Recommendation,” *ACM Transactions on Knowledge Discovery from Data (TKDD)*, vol. 16, no. 6, Jul. 2022, doi: 10.1145/3513092.
- [37] J. Wu, S. Jiang, and L. Shi, “A Next POI Recommendation Based on Graph Convolutional Network by Adaptive Time Patterns,” *Electronics 2023, Vol. 12, Page 1241*, vol. 12, no. 5, p. 1241, Mar. 2023, doi: 10.3390/ELECTRONICS12051241.
- [38] Z. Wu and N. Xu, “Point-of-Interest Recommendation Model Based on Graph Convolutional Neural Network,” *Wirel Commun Mob Comput*, vol. 2022, 2022, doi: 10.1155/2022/7638117.
- [39] S. Dai, Y. Yu, H. Fan, and J. Dong, “Spatio-Temporal Representation Learning with Social Tie for Personalized POI Recommendation,” *Data Sci Eng*, vol. 7, no. 1, pp. 44–56, Mar. 2022, doi: 10.1007/S41019-022-00180-W/TABLES/5.
- [40] J. Fang, X. Meng, and X. Qi, “A top-k POI recommendation approach based on LBSN and multi-graph fusion,” *Neurocomputing*, vol. 518, pp. 219–230, Jan. 2023, doi: 10.1016/J.NEUCOM.2022.10.048.
- [41] K. U. Kala and M. Nandhini, “Context-Category Specific sequence aware Point-Of-Interest Recommender System with Multi-Gated Recurrent Unit,” *J Ambient Intell Humaniz Comput*, pp. 1–11, Dec. 2019, doi: 10.1007/S12652-019-01583-W/METRICS.
- [42] M. Li, R. Westerholt, H. Fan, and A. Zipf, “Assessing spatiotemporal predictability of LBSN: a case study of three Foursquare datasets,” *Geoinformatica*, vol. 22, no. 3, pp. 541–561, Jul. 2018, doi: 10.1007/S10707-016-0279-5/METRICS.

- [43] “Dingqi YANG’s Homepage - Foursquare Dataset.” <https://sites.google.com/site/yangdingqi/home/foursquare-dataset> (accessed May 30, 2023).
- [44] E. Cho, S. A. Myers, and J. Leskovec, “Friendship and mobility: User movement in location-based social networks,” *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 1082–1090, 2011, doi: 10.1145/2020408.2020579.
- [45] “SNAP: Network datasets: Gowalla.” <https://snap.stanford.edu/data/loc-gowalla.html> (accessed Jun. 05, 2023).
- [46] “SNAP: Network datasets: Brightkite.” <https://snap.stanford.edu/data/loc-Brightkite.html> (accessed Jun. 05, 2023).
- [47] “Yelp Dataset.” <https://www.yelp.com/dataset/documentation/main> (accessed Jun. 05, 2023).
- [48] E. Asani, H. Vahdat-Nejad, and J. Sadri, “Restaurant recommender system based on sentiment analysis,” *Machine Learning with Applications*, vol. 6, p. 100114, Dec. 2021, doi: 10.1016/J.MLWA.2021.100114.
- [49] Y. Zhang, C. Yang, and Z. Niu, “A research of job recommendation system based on collaborative filtering,” *Proceedings - 2014 7th International Symposium on Computational Intelligence and Design, ISCID 2014*, vol. 1, pp. 533–538, Mar. 2015, doi: 10.1109/ISCID.2014.228.