

# مدل توصیه مکان‌های مورد علاقه با توجه به الگوی رفتاری افراد بر اساس لیست دوستان بر پایه یادگیری عمیق

صدف صفوی و مهرداد جلالی

مکان، علاوه بر این به کاربران این امکان را می‌دهند که علایق و رفتار ثبت خود را به اشتراک گذاشته و دوستان جدیدی پیدا کنند. شکل ۱ نمونه‌ای از شبکه اجتماعی مبتنی بر مکان است که تعاملات و روابط دوستی بین کاربران و همچنین تعامل بین کاربران و مکان‌های شخصی‌شده (به عنوان مثال، فعالیت‌های ثبت اطلاعات) را نشان می‌دهد. توصیه نقاط مورد علاقه به کاربران تلفن همراه در شبکه‌های اجتماعی مبتنی بر مکان، می‌تواند به عنوان یک وظیفه مهم در نظر گرفته شود و به کاربران اجازه می‌دهد مکان‌های جدیدی مطابق علایق خود در مناطق پرتقاضا پیدا کنند. معمولاً سیستم‌های پیشنهادی مکان، اطلاعات مکان و روابط اجتماعی کاربران را بررسی می‌کنند تا از آنها برای تهیه و دسته‌بندی لیستی از مکان‌های پیشنهادی استفاده کنند. مکان‌هایی که کاربران با احتمال بالایی قصد دارند از آنجا بازدید کنند و توسط دوستانشان ثبت شده است [۳]. سیستم‌های پیشنهادی مکان نه تنها علاقه کاربر به خدمات این شبکه‌ها را افزایش می‌دهد، بلکه به شرکت‌های تبلیغاتی در برنامه‌ریزی، راه‌اندازی و ارزیابی یک کمپین موفق بازاریابی نیز کمک می‌کنند [۴] و [۵].

برخی از چالش‌های این شبکه‌ها به شرح زیر است:

**داده‌های ناهمگن:** شبکه‌های اجتماعی مبتنی بر مکان انواع مختلفی از اطلاعات را شامل می‌شوند و نه تنها شامل اطلاعات جغرافیایی مکان‌ها، داده‌های ثبت و توضیحات مکان می‌باشند بلکه اطلاعات رسانه‌ای (به عنوان مثال، نظرات و توییت‌های کاربر) و اطلاعات ارتباطات اجتماعی کاربران را نیز ارائه می‌دهند. داده‌های ناهمگن، نشان‌دهنده تفاوت در تحرک و جابه‌جایی کاربر بوده که با تأثیر از انواعی از رویکردها و سیستم‌های پیشنهادی مکان، متفاوت می‌باشند [۶] و [۷]. تحقیقات گسترده علمی نشان می‌دهد که روابط اجتماعی عاملی اساسی در توصیه مکان مورد علاقه روابط اجتماعی بین کاربران است. در [۸] یک روش پیاده‌روی تصادفی ترکیبی<sup>۴</sup> بر اساس گراف با ساختار ستاره‌ای پیشنهاد شده که ساختارهای لینک ناهمگن پیچیده را با هم ادغام می‌کند. در [۸] تعداد ثبت کاربران یا امتیاز آنها به عنوان نمره آن توصیه در نظر گرفته می‌شود.

**محدودیت‌های فیزیکی:** فعالیت‌های ثبت کاربران در شبکه‌های اجتماعی مبتنی بر مکان در مقایسه با تماشای فیلم در Netflix و خرید آنلاین از Amazon، با محدودیت‌های فیزیکی همراه است. چنین محدودیت‌های فیزیکی باعث می‌شود فعالیت ثبت کاربران ویژگی‌های مکانی و زمانی قابل ملاحظه‌ای را داشته باشند. به عنوان مثال، معمولاً فروشگاه‌ها خدمات خود را در مدت زمان محدودی ارائه می‌دهند.

**چکیده:** رشد سریع شبکه‌های اجتماعی مبتنی بر مکان، فرصتی عالی برای ارائه خدمات توصیه مکان‌های مورد علاقه به صورت هدفمند می‌باشد. یک وظیفه مهم برای توصیه دقیق نقاط جذاب و مورد علاقه کاربران در شبکه‌های اجتماعی مبتنی بر مکان، با توجه به چالش‌های متون غنی و پراکندگی داده‌ها، بررسی ویژگی‌های معنادار کاربران و نقاط مورد علاقه است. در این مقاله، یک روش جدید برای توصیه ترتیب دقیق بهترین نقاط مورد علاقه کاربران ارائه شده که ترکیبی از رویکردهای شبکه عصبی کانولوشن، خوشه‌بندی و دوستی می‌باشد. برای یافتن شباهت در رفتار دوستان صمیمی، از روش خوشه‌بندی انتقال میانگین استفاده می‌کنیم و فقط تأثیر الگوی رفتاری شبیه‌ترین دوست را به نسبت همه دوستان کاربر در نظر می‌گیریم. چارچوب جدید شبکه عصبی کانولوشن پیشنهادی با ۱۰ لایه می‌تواند طول و عرض جغرافیایی و شناسه مکان‌های مناسب بعدی را پیش‌بینی کرده و سپس بر اساس کوتاه‌ترین فاصله از الگوی رفتاری دوست مشابه، مکان‌های پیشنهادی را انتخاب کند. این رویکرد ترکیبی، در دو مجموعه داده شبکه‌های اجتماعی مبتنی بر مکان ارزیابی شده و نتایج تجربی نشان می‌دهد که استراتژی ما از روش‌های پیشرفته توصیه نقاط مورد علاقه دقیق‌تر عمل می‌کند.

**کلیدواژه:** خوشه‌بندی انتقال میانگین، شبکه عصبی کانولوشن، شبکه‌های اجتماعی، نقاط مورد علاقه (POI).

## ۱- مقدمه

امروزه به دلیل توسعه زیرساخت شبکه‌های اینترنتی، تلفن‌های هوشمند و دسترسی اکثر کاربران، شبکه‌های اجتماعی مبتنی بر مکان<sup>۱</sup> مانند Gowalla، Brightkite، Foursquare و Yelp محبوبیت بیشتری پیدا کرده‌اند. این شبکه‌های اجتماعی مبتنی بر مکان، داده‌های ثبت<sup>۲</sup> کاربران مانند تجربیات آنها در مکان‌های مورد علاقه<sup>۳</sup> (POI) خود و اطلاعات جغرافیایی مکان‌های بازدیدشده (طول و عرض جغرافیایی) را جمع‌آوری می‌کنند [۱] و [۲]. به عنوان مثال در سال ۲۰۲۰، Foursquare ماهانه بیش از ۵۵ میلیون کاربر فعال و بیش از ۳ میلیارد بازدید از مکان‌های مختلف در سراسر جهان دارد. شبکه‌های اجتماعی مبتنی بر

این مقاله در تاریخ ۱۸ دی ماه ۱۳۹۹ دریافت و در تاریخ ۳۱ خرداد ماه ۱۴۰۰ بازنگری شد.

صدف صفوی، گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران، (email: sf.safavi@gmail.com).

مهرداد جلالی (نویسنده مسئول)، گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران، (email: mehrdad.jalali@kit.edu).

1. Location-Based Social Networks (LBSN)
2. Check-in
3. Point-of-Interest



شکل ۱: نمایش شمای پیشنهادی مبتنی بر کاربر.

در طی چند سال گذشته، استفاده از تکنیک‌های یادگیری عمیق در امور مرتبط با هوش مصنوعی مانند بینایی ماشین، پردازش زبان طبیعی و توصیه مکان مورد علاقه افزایش یافته و می‌توان ویژگی‌های کلیدی را به صورت عمیق و موفقیت‌آمیزی استخراج کرد [۱۴] و [۱۵]. یادگیری عمیق یک روش یادگیری بازنمایی<sup>۱</sup> است که توانایی یادگیری ارائه و نمایش داده‌ها را با چندین ماژول ساده دارد. هر ماژول نمایش سطح بالای ورودی از ماژول قبلی (از ماژول استخراج‌کننده ویژگی سطح پایین) را بررسی می‌کند [۱۶] و [۱۷]. بنابراین تکنیک‌های یادگیری عمیق غیر مشابه برای استخراج ویژگی‌های سطح بالا نتایج بسیار خوبی دارند که می‌توانند برای وظایف توصیه مفید باشند [۱۸].

یک شبکه عصبی عمیق که توسط [۵] پیاده‌سازی شده است، ترکیبی از ویژگی‌های مختلف در شبکه‌های اجتماعی مبتنی بر مکان بوده و این شبکه عصبی عمیق بر اساس تأثیر این ویژگی‌ها بر رفتار کاربر، آموزش دیده است. همچنین برای کاهش پراکندگی داده‌ها در سیستم‌های پیشنهادی نقاط مورد علاقه، تأثیرات دسته‌بندی، فاکتورهای زمانی، نقاط جغرافیایی و بازدید مشترک بررسی شده است. Doan و همکاران [۶] روش جدیدی در زمینه رفتار بازدید کاربر از مکان (ثبت کاربر) با توجه به جذابیت منطقه و رقابت موجود در محله‌ها ارائه کرده‌اند. He و همکاران [۱۷]، ساختاری برای توصیه نقاط مورد علاقه طراحی کرده‌اند که فاکتورهای زمانی، فاکتورهای جغرافیایی و فاکتورهای اجتماعی را ادغام می‌کند. استراتژی آنها بر اساس ترکیب وزن‌دهی خطی و آبشاری می‌باشد. مرجع [۱۶] از یک مدل یادگیری عمیق پالایشی سلسله‌مراتبی مبتنی بر موقعیت مکانی (SH-CDL) برای غلبه بر چالش‌های تنوع در ترجیحات کاربران در انتخاب مکان مورد علاقه، از یادگیری بازنمایی به صورت افزایشنده و سلسله‌مراتبی و با توجه به ویژگی‌های ناهمگن استفاده کرده است. یک الگوریتم پیشنهادی جدید مکان مورد علاقه توسط [۱۳] پیاده‌سازی شده که می‌تواند داده‌های زمان واقعی را تحلیل کند. برای آنالیز اطلاعات متنی نقاط مورد علاقه و یادگیری نمایش آنها، از یک

**روابط پیچیده:** برای ارائه خدمات شبکه‌های اجتماعی آنلاین مانند Facebook، Instagram و Twitter، مکان یک ویژگی جدید است که روابط جدیدی را بین مکان‌ها و همچنین بین مکان‌ها و کاربران ایجاد می‌کند. علاوه بر این، فعالیت‌های اشتراک مکان می‌تواند تغییری در روابط بین کاربران به وجود آورد و افراد می‌توانند با همسایگان جغرافیایی خود دوست شوند. به طور قابل توجهی، نزدیکی فاصله جغرافیایی بر رفتارهای ثبت کاربران در نقاط مورد علاقه تأثیر می‌گذارد. در شبکه‌های اجتماعی مبتنی بر مکان، کاربران به صورت فیزیکی با نقاط مورد علاقه خود در تعامل هستند و این یک پدیده منحصر به فرد است که از پیشنهاد‌های سنتی تشخیص داده می‌شود. زانگ و همکاران [۹] رویکرد تخمین تراکم کرنل را در زمینه توصیه مکان شخصی‌شده با توجه به ویژگی‌های اجتماعی و جغرافیایی (iGSLR) ارائه نموده‌اند و از این ساختار برای ترسیم نفوذ جغرافیایی و اجتماعی شخصی‌شده استفاده کرده‌اند. آنها توزیع فاصله بین هر جفت مکان را با برآورد تراکم کرنل اندازه‌گیری کردند.

مطالعات قبلی نشان می‌دهند که به طور قابل توجهی الگوریتم‌های توصیه مکان مورد علاقه توسط سه فاکتور اصلی مشخص می‌شوند: شباهت ثبت مکان [۱۰]، اهمیت دوست [۱۱] و ترجیحات کاربر [۱۲]. در مقایسه با یک منبع اطلاعاتی واحد، علایق مشترک در بین کاربران منجر به شکل‌گیری اعتماد و احتمال بالا در بازدید از مکان مشابه می‌شود. رفتار بشر، در بسیاری از جنبه‌ها با توجه به لینک‌های اجتماعی، نقاط مورد علاقه و ثبت مکان، شباهت خاصی را نشان می‌دهد. به عنوان مثال، کاربران تمایل دارند چندین مکان دیدنی را بازدید کرده یا با مسافت‌های کوتاه به مکان‌های اطراف خود بروند. فعالیت‌های ثبت کاربر (بازدید از مکان) توسط دوستان وی کنترل شده و کاربران معمولاً تمایل دارند مسافت کمتری را طی کرده و از مسیرهای آسان‌تری استفاده کنند. رویکردهای مبتنی بر دوستان، نفوذ یک دوست را در بازدید از یک مکان (شباهت تحرک بین دو دوست) ارزیابی می‌کند. تمایل کاربر، به معنای شباهت بین میل بالقوه کاربران به مکان‌های خاص در یک منطقه مورد

شبکه عصبی کانولوشن<sup>۱</sup> استفاده شده است.

مدل POIRA که در [۱۹] ارائه شده است، روشی محتواآگاه مبتنی بر شبکه عصبی کانولوشن می‌باشد که با کمک تکنیک تجزیه ماتریس، از متن نظرات و اطلاعات نقاط مورد علاقه، ویژگی‌های محتوایی را استخراج می‌کند. علاوه بر این، اطلاعات جغرافیایی و روابط اجتماعی کاربران را برای توصیه مکان مورد علاقه ادغام می‌کند اما تغییر ترجیحات کاربران را در طول زمان در نظر نگرفته و برای تحقیق آینده خود مشخص کرده است. در پژوهش [۲۰] روش جدید توصیه مکان مورد علاقه بعدی به نام DSPR ارائه شده که با ترکیب اطلاعات زمانی مانند زمان واقعی، فاصله زمانی و مکانی بین دو مکان مورد علاقه و انواع مکان‌ها و همچنین با کمک شبکه عصبی بازگشتی توصیه نهایی را انجام می‌دهد. آقای Zeng و همکاران [۲۱]، از مدلی به نام PR-RCUC برای توصیه مکان مورد علاقه با کمک فیلترینگ مشارکتی مبتنی بر منطقه و اطلاعات کاربر استفاده می‌کنند. این مدل، مناطق مختلف را خوشه‌بندی کرده و سپس اطلاعات مبتنی بر کاربر مانند فاصله جغرافیایی و دسته‌بندی منطقه را در نظر گرفته و مکان‌ها را امتیازبندی می‌کند. در این تحقیق زمان بررسی نشده است.

با توجه به ضرورت پیشنهاد نقاط مورد علاقه به کاربران در شبکه‌های اجتماعی مبتنی بر مکان و پیش‌بینی مکان‌های احتمالی بعدی کاربر با دقت بالاتر و پیشنهاد مکان‌هایی که مورد علاقه کاربر باشد، ما یک ساختار جدید یادگیری عمیق برای دستیابی به ترتیب دقیق  $k$  تا از بهترین مکان‌ها برای توصیه به هر کاربر پیشنهاد کرده‌ایم. این ساختار، ترکیبی از شبکه عصبی کانولوشن و روش خوشه‌بندی انتقال میانگین<sup>۲</sup> می‌باشد که در ابتدا با توجه به الگوی رفتاری ثبت مکان دوستان کاربر و تکنیک خوشه‌بندی، شبیه‌ترین دوست را مشخص نموده و دوم مدل پیشنهادی شبکه عصبی کانولوشن بر اساس شش ویژگی ورودی شامل شناسه کاربر، ماه، روز، ساعت، دقیقه و ثانیه و با توجه به موقعیت فعلی کاربر، مکان‌های مورد علاقه بعدی را برای بازدید پیش‌بینی می‌کند. در نهایت برای افزایش دقت مکان پیشنهادی، کوتاه‌ترین فاصله زمانی با الگوی ثبت دوست مشابه محاسبه شده و مکان بعدی به کاربر پیشنهاد می‌گردد. به طور خلاصه دستاوردهای این مقاله به شرح زیر می‌باشد:

- برای پیشنهاد مکان‌های دقیق بعدی کاربر بر اساس الگوی رفتاری ثبت دوستان مشابه وی، ما یک مدل جدید یادگیری عمیق مبتنی بر شبکه عصبی کانولوشن با ترکیب روش خوشه‌بندی و روابط دوستی برای توصیه مکان مورد علاقه ارائه کردیم.
- از روش خوشه‌بندی انتقال میانگین برای یافتن دوستان مشابه کاربر استفاده شده و در یک چارچوب جدید پیشنهادها را بر اساس تمام مکان‌های بازدیدشده و زمان مربوط ارائه داده‌ایم.
- معماری پیشنهادی یک گروه از کاربران را با توجه به ترجیحات گذشته مشابه با کاربر فعلی طبقه‌بندی می‌کند.
- به کمک ساختار جدید شبکه عصبی کانولوشن ارائه‌شده شناسه و طول و عرض جغرافیایی مکان‌های پیشنهادی بعدی پیش‌بینی می‌شود.
- برای بهبود دقت، کوتاه‌ترین فاصله زمانی بین این مکان پیش‌بینی شده و تمام مکان‌های ممکن مجاور مرتبط با بهترین دوست مشابه محاسبه می‌شود.

## Archive of SID

- آزمایش‌های گسترده بر روی دو مجموعه داده واقعی انجام گرفته که به وضوح نشان می‌دهد که مدل پیشنهادی در مقایسه با سایر روش‌های پیشرفته، دقت توصیه مکان مورد علاقه را بهبود بخشیده است.

این مقاله به صورت زیر سازماندهی می‌شود: در بخش ۱-۲ به بررسی رویکرد خوشه‌بندی نقاط مورد علاقه می‌پردازیم و مدل شبکه عصبی کانولوشن در قسمت ۲-۲ ارائه می‌شود. در قسمت ۲-۳ مدل پیشنهادی شبکه عصبی کانولوشن ما شرح داده شده و در بخش بعدی مجموعه داده‌ها معرفی می‌گردد و سپس معیارهای عملکرد بررسی می‌شوند. نتایج و سخنان نهایی در بخش ۳ توضیح داده شده است.

## ۲- اصول و روش‌ها

### ۲-۱ خوشه‌بندی نقاط مورد علاقه

رویکرد خوشه‌بندی، یک روش جداسازی داده بدون نظارت است که در هر خوشه بیشترین شباهت ویژگی‌ها وجود دارد [۱۵]. روش انتقال میانگین یک فرایند غیر پارامتریک است که تراکم همه مکان‌های هر محدوده را در نقشه تخمین می‌زند. این استراتژی برای اطمینان از این که مکان‌ها در هر خوشه بیشترین شباهت مکانی را داشته باشند، مکان‌ها را به صورت تکراری با روش بدون نظارت گروه‌بندی می‌کند. به علاوه، تعداد مکان‌ها برای یک مسئله خاص باید توسط کاربر تعریف شود یا بر اساس سایر اطلاعات موجود مانند دانش اولیه در مورد داده‌ها یا تعداد خوشه‌های تخمین زده شده، برآورد گردد. تکنیک انتقال میانگین، مزایایی را در تعیین تعداد پیش‌بینی شده هر بخش مانند کارایی و آزادی مقایسه‌ای ارائه می‌کند [۲۲] و [۲۳] و آزادی اندازه (یا پهنای باند) و شکل پنجره (یا کرنل<sup>۳</sup>) را که برای انتخاب مکان‌ها (داده‌ها) استفاده می‌شود، تعریف می‌نماید [۲۴].

تکنیک انتقال میانگین، ابتدا شیب تراکم مکان‌های مشابه را در یک ناحیه محلی محاسبه می‌کند که در داخل یک حلقه تکراری برای یافتن حداکثر تراکم در هر بخش (منطقه محلی) استفاده می‌شود. در کار ما روش انتقال میانگین شامل دو مرحله است. مرحله اول شامل انتخاب شکل و اندازه پنجره (یا پهنای باند) مناسب است که معیار فاصله بین مکان‌ها را تعریف می‌کند. اندازه و شکل پنجره را می‌توان با استفاده از روش آزمون و خطا تعریف کرد که نتایج قابل قبولی را برای برنامه‌های متعدد ارائه می‌دهد، اما این روش محدودیت عمده‌ای دارد. وقتی ویژگی‌های داده در مناطق مختلف در دامنه متفاوت باشد، تخمین بهترین پهنای باند در کل منطقه چالش‌برانگیز است. در نتیجه، چند مکان ناخواسته در نقشه تقسیم‌شده نهایی وجود دارد، در حالی که بسیاری از مکان‌های دقیق را می‌توان مشاهده کرد. برای انتخاب بهترین اندازه و شکل کرنل، از روش آزمون و خطا استفاده کردیم [۲۴].

برای رسیدن به یک نقطه ثابت با حداکثر شیب تابع چگالی، تخمین اولیه  $l$  باید به صورت تکراری به روز شود تا بهترین مکان با چگالی حداکثر ارزیابی شود. در نتیجه، مکان‌های دیگر با همان کرنل به سمت این نقطه ثابت حرکت می‌کنند تا یک بخش را تکمیل کنند [۲۳]، [۲۵] و [۲۶].


تابع کرنل توسط  $K(l_i - l)$  مشخص می‌شود، به طوری که  $l_i$  همه مکان‌های موجود در پنجره انتخاب‌شده را در نظر می‌گیرد و  $l$  نقطه اولیه

1. Convolutional Neural Network

2. Mean-Shift Clustering

3. Kernel

## Archive of SID



شکل ۳: نمایش محاسبه خوشه‌های همپوشان یک کاربر.

ذکر شده در مورد تعداد خوشه‌ها و برای بررسی بیشتر، ما آن دسته از خوشه‌های همپوشان که بیشترین سطح همپوشانی را دارند در نظر می‌گیریم. در نهایت، فقط ۱۵ درصد از بیشترین مکان‌های همپوشان از همه خوشه‌ها انتخاب شده است. ما تلاش می‌کنیم با پیاده‌سازی این تکنیک همراه با سایر استراتژی‌ها، دقت بیشتری را در پیش‌بینی مکان‌های ترجیحی نهایی به دست آوریم.

## ۲-۲ شبکه عصبی کانولوشن

توانایی تشخیص آرایش داده‌ها یا ویژگی‌ها، تشخیص الگو نامیده می‌شود. به عبارت دیگر، تشخیص الگو می‌تواند به عنوان یک روش طبقه‌بندی بر اساس دانش قبلی یا اطلاعات آماری استخراج‌شده از الگوها یا نمایش آنها دسته‌بندی گردد و در زمینه بینایی ماشین برای برنامه‌های بی‌شماری مانند سیستم‌های توصیه‌گر، داده‌کاوی و تصویربرداری بیولوژیکی اعمال می‌شود [۲۸] و [۲۹].

امروزه در استراتژی‌های تشخیص الگو و برنامه‌های آنها، ساختارهای شبکه عصبی کانولوشن در آنالیز و پردازش داده‌ها، موفقیت گسترده‌ای به دست آورده‌اند. مدل‌های کانولوشن رابطه بین برخی جزئیات اصلی و محتوای متنی را استنباط می‌کنند و در مرکز اصلی هر مدل از داده‌کاوی گرفته تا پیش‌بینی بازدید کاربران از مکان‌های جدید قرار می‌گیرند [۳۰].

ساختارهای کانولوشن دقیقاً مانند شبکه‌های عصبی مصنوعی مبتنی بر نورون بوده و یک توپولوژی شبکه‌ای دارند. این مدل‌ها با استفاده از یک سری لایه‌های کانولوشن با اندازه کرنل تعریف‌شده توسط کاربر، به ما این امکان را می‌دهند تا به طور مؤثری از اطلاعات و ویژگی‌های کلیدی نقاط مورد علاقه و دوستی‌ها بهره ببریم. این مدل بر پایه نورون، شامل بسیاری از وزن‌ها و بایاس‌های آموزش‌دیده است و می‌تواند برای کاربردهای طبقه‌بندی، استخراج ویژگی و پیش‌بینی استفاده شود. این وزن‌ها و بایاس‌ها در ابتدای آموزش به صورت تصادفی اعمال می‌شوند. بخش اصلی هر شبکه عصبی کانولوشن که به عنوان لایه کانولوشن مشخص شده است وظیفه محاسبه ضرب داخلی<sup>۱</sup> بین فیلترها (کرنل‌ها) و داده‌های ورودی (مانند دوستی‌ها و مکان‌های مورد علاقه) را دارد [۳۱] و [۳۲]. اغلب، اولین لایه شبکه عصبی کانولوشن با یک لایه کانولوشن آغاز می‌شود تا ورودی را ادغام کرده و نقش مهمی در استخراج ویژگی‌های کلیدی از داده‌های ورودی دارد [۳۳] و [۳۴].

علاوه بر این، لایه‌های کانولوشن می‌توانند وابستگی‌های مکانی و زمانی را با موفقیت به دست آورند. عملیات جبری مربوط به ضرب داخلی که بین مقادیر هر فیلتر و داده‌های ورودی مربوط به آن انجام می‌شود، می‌تواند به عنوان یک عمل کانولوشن مشخص شود [۳۰]، [۳۵] و [۳۶].



زمان بین ۱۶ ~ ۲۰



زمان بین ۰۰ ~ ۰۴

شکل ۴: نمایش گرافیکی به کارگیری روش خوشه‌بندی برای دو بازه زمانی متفاوت از یک کاربر.

آن پنجره را نشان می‌دهد. این معادله تعریف‌کننده وزن نقاط نزدیک مورد نیاز برای ارزیابی مجدد تراکم است [۲۳].

برای تعیین حداقل فاصله بین مکان‌ها توسط  $K(l_i - l) = e^{-c||l_i - l||}$  که یک هسته گاوسی داده‌شده است، میانگین وزنی تراکم محلی در پنجره را می‌توان با استفاده از (۱) مشخص کرد

$$m(l) = \frac{\sum_{l_i \in N(l)} K(l_i - l) l_i}{\sum_{l_i \in N(l)} K(l_i - l)} \quad (1)$$

که  $N(l)$  نشان‌دهنده یک نقطه همسایه  $l$  است. تفاوت بین  $l$  و  $m(l)$  انتقال میانگین نامیده می‌شود که توسط Hostetler و Fukunaga تعریف شده است [۲۷].

در مقاله پیشنهادی ما، در اولین مرحله، بازه زمانی را به ۶ بخش تقسیم می‌کنیم (۰۴ ~ ۰۰، ۰۴ ~ ۰۱، ۰۸ ~ ۰۱، ۱۲ ~ ۰۱، ۱۶ ~ ۰۱، ۲۰ ~ ۰۱، ۲۴ ~ ۰۱) و بر اساس هر بخش مکان بازدیدشده توسط هر کاربر و دوست وی انتخاب می‌شود. به عبارت دیگر، همه مکان‌های بازدیدشده بر اساس زمان بازدید دسته‌بندی می‌شوند (شکل ۲). با توجه به اعمال چنین تفاوتی در زمان مکان‌های بازدیدشده مربوط به دوستان کاربر، می‌توان در نتیجه نهایی پیش‌بینی موقعیت مناسب را به دست آورد. در مرحله بعد، همان طور که در شکل ۳ نشان داده شده است، کل مکان‌های بازدیدشده از هر کاربر در هر بخش با استفاده از روش انتقال میانگین تقسیم‌بندی می‌شوند. باید توجه داشت که در مقایسه با دیگر رویکردهای خوشه‌بندی مانند فازی c-means و k-means، در روش خوشه‌بندی انتقال میانگین نیازی به تعریف تعداد خوشه‌ها توسط کاربر نیست. این امر باعث می‌شود که وقتی در یک بازه زمانی خاص منطقه بازدیدشده تقسیم شود، برای هر کاربر تعداد مختلف خوشه وجود داشته باشد.

سپس برای هر کاربر، نسبت همپوشانی بین خوشه‌های دوستان وی و خوشه‌های کاربر محاسبه شده است. به عبارت دیگر، برای غلبه بر مشکل

1. Dot Product

## Archive of SID

و ثانیه مربوط به زمان بازدید هر کاربر استفاده می‌کند. همان طور که در شکل ۴ به وضوح نشان داده شده است، ۱۰ لایه کانولوشن با تعداد مختلف کرنل پیاده‌سازی شده است. در لایه اول از فیلترهای  $3 \times 3$  استفاده کردیم که به این معنی است که سه بانک فیلتر با اندازه  $2 \times 1$  وجود دارد. این اندازه  $2 \times 1$  مربوط به بانک فیلتر در تمام لایه‌های کانولوشن استفاده می‌شود. در لایه دوم، از ۸ فیلتر استفاده شده که در دو لایه بعدی با ۱۶ بانک فیلتر دنبال می‌شود. این لایه‌های ذکر شده مسئول استخراج ویژگی‌های سطح پایین هستند. سپس، همان طور که ملاحظه می‌شود ما از ۲ لایه با همان تعداد بانک فیلتر (۳۲ بانک فیلتر) برای استخراج ویژگی‌های سطح متوسط استفاده کردیم. ۴ لایه آخر کانولوشن برای استخراج ویژگی‌های سطح بالا به کار می‌رود و ۲ لایه با ۶۴ بانک فیلتر و ۲ لایه با ۱۲۸ بانک فیلتر اعمال می‌شود. برای بهبود آموزش و نرمالیزه کردن مقادیر داده‌ها در بین لایه‌ها از لایه نرمال‌سازی دسته‌ای استفاده می‌کنیم و خروجی آن به یک لایه فعال‌سازی وارد می‌شود که در کار ما تابع فعال‌سازی ReLU اعمال شده است. علاوه بر این، در انتها برای کاهش تأثیر بیش‌برازش<sup>۷</sup> و کنترل فرایند برازش<sup>۸</sup>، دو لایه رهاسازی<sup>۹</sup> [۳۹] با احتمال رهاسدن ۰.۰۱٪ به مدل کانولوشن اضافه شد تا نورون‌ها به طور مستقل آموزش دیده و کمتر به بقیه نورون‌ها وابسته باشند. مقدار ۰.۰۱ بر اساس آزمون و خطا در نظر گرفته شده است.

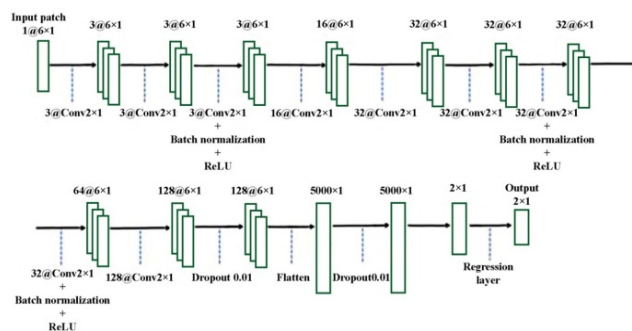
دو لایه کانولوشن نهایی توسط ۲ لایه مسطح<sup>۱۰</sup> دنبال می‌شود و سرانجام به دلیل این که پاسخ پیوسته است از لایه رگرسیون استفاده می‌کنیم. لایه رگرسیون مسئول ایجاد دو مقدار بوده که نشان‌دهنده طول و عرض جغرافیایی پیش‌بینی شده و شناسه مکان‌های پیشنهادی بر اساس داده‌های آموزشی می‌باشد. تعداد دوره‌ها<sup>۱۱</sup> برای فرایند آموزش ۸۰۰ و نرخ یادگیری<sup>۱۲</sup> ۰.۰۱ در نظر گرفته شده است.

ترتیب دقیق داده‌ها در مدل پیشنهادی ما ضروری نیست و با توجه به لایه‌های شبکه و پارامترهای آن، موقعیت فعلی کاربر در نظر گرفته می‌شود و نیازی به دانستن این که چند دقیقه قبل کجا حضور داشته است نمی‌باشد. مدل پیشنهادی در فاز یادگیری، آموزش‌های لازم را دیده است و داده‌ها به صورت تصادفی مرتب شده‌اند.

به دلیل اختلاف اندک در مقادیر خروجی و احتمال عدم ارائه مکان دقیق پیشنهادی توسط خروجی مدل پیش‌بینی شبکه عصبی کانولوشن، در این مرحله ما باید فاصله زمانی بین این مکان پیش‌بینی شده و تمام مکان‌های ممکن را که در نزدیکی کاربر قرار دارد بر اساس موقعیت شبیه‌ترین دوست فرد که در مرحله ۲-۱ بررسی شده محاسبه کنیم. این بدان معنی است که برای محاسبه فاصله، فقط مکان‌هایی در نظر گرفته می‌شود که مربوط به همان کاربر و دوست انتخاب‌شده وی است.

در ساختار شبکه عصبی کانولوشن، برای به حداقل رساندن زیان در (۳) از تکنیک RMSE [۴۰] استفاده کردیم که اختلاف بین مکان‌های واقعی و تخمینی (پیش‌بینی شده) را محاسبه می‌کند

$$RSME = \sqrt{\frac{1}{n} \sum_{i=1}^n (\text{predicted} - \text{True})^2} \quad (3)$$



شکل ۴: ساختار شبکه عصبی کانولوشن پیشنهادی ما.

همچنین باید توجه داشت که اولین لایه‌های کانولوشن مسئول استخراج ویژگی‌های سطح پایین هستند، در حالی که لایه کانولوشن عمیق‌تر، ویژگی‌های سطح بالاتر را تشخیص می‌دهد [۳۲].

یکی دیگر از لایه‌های مفیدی که مناسب مدل‌های با لایه‌های بسیار عمیق است، لایه نرمال‌سازی دسته‌ای<sup>۱</sup> می‌باشد. این تکنیک، روشی برای مقیاس‌گذاری و استانداردسازی خروجی هر لایه است و قبل از ارسال آن به عنوان ورودی به لایه بعدی برای هر دسته کوچک<sup>۲</sup>، اعمال می‌شود. از آنجا که پراکندگی منجر به محو گرادیان<sup>۳</sup> می‌شود و در استخراج ویژگی‌های مناسب اشکال ایجاد می‌کند، یک تابع فعال‌سازی دلخواه بر اساس داده‌های ورودی ما بر روی هر ویژگی اعمال می‌شود تا با کاهش پراکندگی، بازده محاسباتی را بهبود بخشد [۳۳]، [۳۷] و [۳۸].

در مقاله پیشنهادی ما، تابع فعال‌سازی ReLU که مبتنی بر پس‌انتشار خطاها<sup>۴</sup> است، برای تغییر اعداد منفی به مقادیر صفر اعمال شده است. معادله (۲) تابع فعال‌سازی ReLU را مشخص می‌کند [۳۳]

$$y = \max(0, x) \quad (2)$$

که  $x$  ورودی تابع فعال‌سازی ReLU و  $y$  خروجی آن را نشان می‌دهد. در لایه تمام متصل<sup>۵</sup> (FC) هر نود به همراه وزن قابل یادگیری خود در هر بردار ورودی ضرب شده تا به ویژگی‌های قوی سطح بالا در داده‌های ورودی دست یابد [۳۷]، [۳۹] و [۴۰]. لایه بعدی برای پیش‌بینی در معماری CNN، لایه رگرسیون است. این لایه وظیفه مدل‌سازی رابطه بین یک هدف ایده‌آل و داده ورودی را دارد [۳۸] و [۴۱].

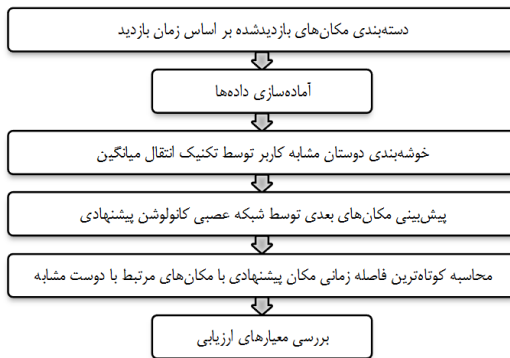
مدل کانولوشن پیشنهادی ما می‌تواند با استفاده از تکنیک کاهش گرادیان<sup>۶</sup> بهترین وزن‌ها و بایاس‌ها را در هر لایه یاد بگیرد تا یک تابع هزینه تعریف‌شده را به حداقل برساند [۳۷].

## ۲-۳ معماری پیشنهادی شبکه عصبی کانولوشن

همان طور که پیش از این ذکر شد، مدل‌های شبکه عصبی کانولوشن قادر به استخراج اطلاعات کلیدی از ورودی، ذخیره و آنالیز این داده‌ها می‌باشند و به تصمیم‌گیری دقیق‌تر کمک کرده و منجر به بهبود هدف نهایی می‌شوند. ما در این مقاله یک چارچوب جدید بر اساس همه مکان‌های بازدیدشده و زمان مربوط به آنها ارائه می‌دهیم. روش پیشنهادی از ۶ ویژگی ورودی شامل شناسه کاربر، ماه، روز، ساعت، دقیقه

7. Overfitting
8. Fitting
9. Dropout
10. Flatten
11. Epoch
12. Learning Rate

1. Batch Normalization
2. Mini-Batch
3. Vanishing Gradient
4. Backpropagation of Errors
5. Fully-Connected Layer
6. Gradient Descent



شکل ۵: چارچوب پیشنهادی نقاط مورد علاقه با توجه به اهمیت دوست.

به اشتراک بگذارند. مجموعه داده Gowalla (تاریخ دسترسی: فوریه ۲۰۰۹ تا اکتبر ۲۰۱۰) شامل ۱۸۷۳۷ کاربر، ۱۲۷۸۲۷۴ نظر و بررسی، ۸۶۹۸۵ رابطه اجتماعی و ۳۲۵۱۰ نقطه مورد علاقه است [۴۳].

### ۲-۵ معیارهای عملکرد

با مقایسه هر نتیجه مکان پیش‌بینی شده با مکان واقعی مربوط به آن، چندین معیار برای ارزیابی کارایی مدل پیشنهادی محاسبه شده تا ترتیب دقیق بهترین مکان‌های هر کاربر را به دست آورد. دقت قابل توجه مدل ما با استفاده از Precision و Recall ارزیابی شد که معیارها به شرح زیر تعریف می‌شوند [۴۴]

$$\text{precision}@k = \frac{1}{|P|} \times \sum_{j=1}^u \frac{|TopK(P_j) \cap L_j|}{|TopK(U_j)|} \quad (4)$$

$$\text{recall}@k = \frac{1}{|P|} \times \sum_{j=1}^u \frac{|TopK(U_j) \cap L_j|}{|L_j|}$$

که در آن  $TopK(U_j)$  با توجه به استراتژی‌های مشخص،  $K$  تا از بهترین نقاط مکان پیشنهاد شده را در نمونه‌های تست نشان می‌دهد.  $L_j$  مکان‌هایی را مشخص می‌کند که  $L_j$  کاربر در نمونه‌های آموزشی از آنها بازدید کرده و برای آنالیز کارایی مدل،  $K$  عدد متغیر (از ۵ تا ۵۰) مربوط به مکان‌های پیشنهادی را نشان می‌دهد.  $\text{recall}@k$  کسری از مکان‌های بازدید شده توسط کاربر مورد نظر است که به خوبی پیشنهاد شده است، در حالی که  $\text{precision}@k$  کسری از  $K$  تا بهترین مکان‌های پیشنهادی است که با موفقیت به کاربر هدف توصیه می‌شود. علاوه بر precision و recall، از امتداد اعتبارسنجی متقاطع  $K$  بخشی [۴۵] هم استفاده می‌شود. در اعتبارسنجی متقاطع  $K$  بخشی، داده‌ها به صورت تصادفی به  $k$  قسمت تقسیم شده و معیارها  $K$  بار تکرار می‌شوند. در هر زمان یکی از زیرمجموعه‌های  $K$  به عنوان مجموعه ارزیابی و مابقی به عنوان داده آموزشی به کار گرفته می‌شوند. با جابه‌جایی مجموعه‌های آموزش و تست، می‌توان کارایی مدل را افزایش داد. در این روش برای به دست آوردن اثربخشی کامل مدل، بر اساس تمام بررسی‌های  $K$  خطا برآورد می‌شود.

### ۳- نتیجه‌گیری و بحث

#### ۳-۱ نتایج تجربی

مدل پیشنهادی ما در Matlab ۲۰۱۹b پیاده‌سازی شده و تحقیقات

جدول ۱: شرح داده‌ها.

کاربران	نقاط جذاب	رکوردها	روابط اجتماعی	پراکندگی (%)
Yelp	۳۰۸۸۷	۱۸۹۹۵	۲۶۵۵۳۳	۹۹٫۸۶۰
Gowalla	۱۸۷۳۷	۳۲۵۱۰	۸۶۹۸۵	۹۹٫۸۶۵

به طوری که  $n$  تعداد تخمین زده شده یا مقدار واقعی (مکان) را مشخص می‌کند. معماری کلی شبکه یادگیری عمیق ارائه شده برای پیشنهاد نقاط مورد علاقه مناسب و دقیق به کاربران در شکل ۵ آمده است.

### ۲-۴ مجموعه داده‌ها

آنالیز مکانی بر روی مجموعه داده‌های واقعی Yelp و Gowalla انجام شده (اطلاعات بیشتر از این دو مجموعه داده در جدول ۱ آمده است) که شامل اطلاعات مختلف ثبت جغرافیایی است که با طول و عرض جغرافیایی مشخص می‌شوند. از این رو با بررسی فاصله بین جفت‌های ثبت، احتمال وقوع مکان مشترک توسط کاربر و کشف روابط معنادار بررسی شده است. تاریخچه ثبت ارتباط زیادی با ترجیحات ضمنی کاربر برای یک مکان دارد و می‌تواند به عنوان علاقه‌مندی مشترک بین همه کاربران در نظر گرفته شود. ما می‌توانیم شباهت ثبت‌ها را توسط مجاورت و نزدیکی جغرافیایی بررسی کنیم. در ادامه دو چالش اصلی موجود برای توصیه نقاط مورد علاقه شرح داده شده است:


#### ۱) متون غنی

اطلاعات متنی گوناگون در شبکه‌های مبتنی بر مکان، مانند روابط اجتماعی، نزدیکی کاربر و مختصات جغرافیایی نقاط مورد علاقه را می‌توان مشاهده کرد. اطلاعات متنی در این شبکه‌ها، ناکافی و نامفهوم است که توصیه نقاط مورد علاقه را دشوار می‌کند. به عنوان مثال، فاصله جغرافیایی مکان مورد علاقه به طور کامل می‌تواند بر مسیر حرکت و رفتار کاربر تأثیر گذارد. گاهی اوقات کاربران از برخی مکان‌ها مانند یک سینمای دلخواه نزدیک محل کار یا خانه بازدید کرده و سپس این مکان مورد علاقه را به دوستان خود معرفی می‌کنند.

#### ۲) پراکندگی داده

مشکل اصلی در سیستم توصیه‌گر نقاط مورد علاقه، پراکندگی داده است. به محض این که شخصی در یک مکان حضور داشته و ثبت مکان انجام دهد، زمان و مکان آن توسط برچسب ثبت شده و به سایر کاربران پیشنهاد بازدید از این مکان ارسال می‌شود. برای هر فرد تکرار بازدید از مکان‌های مختلف آیتمی در ماتریس کاربر-مکان می‌باشد. از آنجا که همه مکان‌ها توسط همه کاربران بازدید نمی‌شوند، می‌توان میزان پراکندگی قابل توجهی را در داخل ماتریس مشاهده کرد.

شرکت Yelp در شهر سانفرانسیسکو است که دارای یک شبکه اجتماعی بوده و وبسایت آن در سال ۲۰۰۴ راه‌اندازی شده و تا سال ۲۰۲۰ بیش از ۱۸۴ میلیون مرور در این وبسایت معروف صورت گرفته است. این وبسایت مکان‌های تجاری مختلفی مانند سینما، مراکز خرید و رستوران‌ها را پوشش می‌دهد. این مجموعه داده سری ۷ (تاریخ دسترسی: فوریه ۲۰۱۶) شامل ۸۶۰۸۸۸ نظر، ۲۶۵۵۳۳ رابطه اجتماعی، ۳۰۸۳۷ کاربر و ۱۸۹۹۵ نقطه مورد علاقه می‌باشد [۴۲]. Gowalla اولین برنامه تلفن همراه است که به کاربران خود اجازه می‌دهد مکان‌ها را ثبت کنند و مجموعه داده آن یک سرویس مبتنی بر مکان است. Gowalla به کاربران امکان می‌دهد آنچه را می‌شنوند و می‌بینند با خانواده و دوستانشان




شکل ۷: مقایسه بین الگوریتم پیشنهادی و سه روش دیگر بر روی مجموعه داده Gowalla.

شکل ۷: مقایسه بین الگوریتم پیشنهادی و سه روش دیگر بر روی مجموعه داده Gowalla. UFC، LFBCA و LORE به ترتیب ۰/۰۲، ۰/۰۲۵ و ۰/۰۳ بهبود عملکرد دارد. این برتری می‌تواند مشخص کند که الگوریتم پیشنهادی به خوبی از ترکیب روش خوشه‌بندی و روابط دوستی برای توصیه POIها استفاده کرده است. همان طور که در شکل ۶ و ۷ نشان داده شده است، قابل توجه است که وقتی  $K$  کوچک است، استراتژی ما هنوز هم می‌تواند به نتایج توصیه‌شده خوبی دست یابد. به خصوص در شکل ۶  $\text{recall}@5$  کوچک‌تر از  $\text{recall}@10$  است که اثربخشی روش پیشنهادی را ثابت می‌کند. روش LFBCA عملکرد بهتری نسبت به مدل ما ندارد اما همواره در تمام معیارهای ارزیابی از LORE بهتر عمل می‌کند. روش LORE در همه معیارهای ارزیابی در هر دو مجموعه داده عملکرد خوبی ندارد. این یافته تأیید می‌کند که یک عامل اصلی در توصیه مکان ارتباط زیاد مبتنی بر همپوشانی خوشه‌های به دست آمده است. محاسبه انحراف معیار و میانگین مجموعه داده‌ها نتایج اندازه‌گیری را نشان می‌دهند. جدول‌های ۲ و ۳ مقایسه کمی بین نتایج حاصل از روش پیشنهادی ما و سه روش دیگر را در دو مجموعه داده Yelp و Gowalla ارائه می‌کنند. روش پیشنهادی توصیه مکان مورد علاقه این پژوهش، میانگین و انحراف معیار بهتری را در اندازه‌گیری‌ها تخمین می‌زند. میانگین متد UFC تا حدی مشابه روش ما می‌باشد. بر اساس اطلاعات بالا، الگوریتم LORE ضعیف‌ترین عملکرد را در بین بقیه استراتژی‌ها نشان می‌دهد.

عامل پراکندگی داده‌ها در دو مجموعه داده ارزیابی شده متفاوت هستند. نتایج نشان می‌دهد که مدل ما بر روی داده‌های Gowalla بهتر از مجموعه داده Yelp عمل می‌کند و اهمیت و تأثیر دوستان در Gowalla بیشتر از Yelp می‌باشد. این بدان معناست که روابط اجتماعی ارزشمندتری در Gowalla وجود دارد و  $\text{check-in}$  دوستان، فاکتوری است که می‌تواند بر رفتار کاربران تأثیر داشته باشد.

علاوه بر موارد بالا، برای ارزیابی کارایی مدل پیشنهادی خود، متد اعتبارسنجی متقاطع  $K$  بخشی هم محاسبه گردید. در این پژوهش،  $k$  را ۵ در نظر می‌گیریم. در شکل ۸ این فرایند با جزئیات نشان داده شده است. برای تحلیل بیشتر نتایج، ما یک آزمون تی تست برای مقایسه تفاوت بین روش پیشنهادی و سایر تکنیک‌ها انجام دادیم و دریافتیم که بهبود روش ما در همه مجموعه داده‌ها از نظر آماری قابل توجه است  $(p\text{-value} < 0.01)$ .



شکل ۸: مقایسه بین الگوریتم پیشنهادی و سه روش دیگر بر روی مجموعه داده Yelp.

روی کامپیوتری مجهز به ۶ GB با GTX ۱۰۶۰ ۴۵۷۰ با  $\text{id}$  انجام شد. در این مقاله، سه مدل پیشرفته برای اعتبارسنجی عملکرد تکنیک پیشنهادی انتخاب شده است:

UFC [۴۴]: یک استراتژی گروهی را نشان می‌دهد که از اهمیت دوست، ترجیحات کاربر و شباهت ثبت مکان استفاده می‌کند. UFC سه فاکتور اصلی را ترکیب کرده و ترجیحات کاربر بر اساس پالایش مشارکتی<sup>۱</sup> ارائه می‌شود.

LORE [۴۶]: برای بررسی تأثیر ترتیب بازدید بر توصیه مکان، یک گراف انتقال جستجوی موقعیت مکانی-مکانی توسط زنجیره افزودنی مارکوف<sup>۲</sup> توسط LORE [۴۶] ارائه شده تا الگوی متوالی مربوط به ترتیب ثبت کاربر استخراج شود.

LFBCA [۴۷]: متد LFBCA تأثیر روابط اجتماعی را برای هر کاربر در مورد توصیه مکان مورد علاقه بررسی می‌کند. برای مشخص کردن شباهت ثبت، مکان‌ها و کاربران در گراف لینک داده می‌شوند. احتمال هر کاربر به یک مکان بر اساس یک استراتژی مبتنی بر گراف مشخص شده است.

هدف از تحقیقات ما در این مقاله، دستیابی به ترتیب دقیق  $K$  تا از بهترین مکان‌ها برای هر کاربر می‌باشد. ما عملکرد تکنیک‌های متفاوت را در هر دو مجموعه داده Yelp و Gowalla با توجه به تعداد  $K$  مربوط به مکان توصیه‌شده با حداکثر مقدار توصیه بررسی می‌کنیم. در شکل‌های ۶ و ۷ نتایج ساختار پیشنهادی ما در مجموعه داده‌های Gowalla و Yelp گزارش شده است.

### ۳-۲ تحلیل عملکرد

همان طور که به وضوح نشان داده شده است، استراتژی پیشنهادی ما در هر دو مجموعه داده همواره با توجه به دو معیار،  $\text{recall}@k$  و  $\text{precision}@k$ ، بهتر از UFC، LORE و LFBCA عمل می‌کند. به عنوان مثال در Yelp، روش پیشنهادی ما از نظر  $\text{precision}@5$ ،  $\text{precision}@15$  و  $\text{precision}@25$  به ترتیب ۰/۰۳۸، ۰/۰۳۱ و ۰/۰۲۷ به دست می‌آوریم. این بدان معنی است که روش ما در مقایسه با

1. Collaboration Filtering
2. Additive Markov Chain

جدول ۲: نتایج مقایسه کمی بین روش پیشنهادی و سه روش دیگر مربوط به مجموعه داده YELP.

روش	K = ۱۵		K = ۱۰		K = ۵	
	Recall	Precision	Recall	Precision	Recall	Precision
UFC	۰٫۰۶۰ ± ۰٫۰۰۳	۰٫۰۲۲ ± ۰٫۰۰۱	۰٫۰۴۲ ± ۰٫۰۰۴	۰٫۰۲۴ ± ۰٫۰۰۳	۰٫۰۲۷ ± ۰٫۰۰۵	۰٫۰۲۷ ± ۰٫۰۰۳
LFBCA	۰٫۰۴۷ ± ۰٫۰۰۴	۰٫۰۱۹ ± ۰٫۰۰۲	۰٫۰۳۷ ± ۰٫۰۰۴	۰٫۰۲۰ ± ۰٫۰۰۱	۰٫۰۲۰ ± ۰٫۰۰۴	۰٫۰۲۲ ± ۰٫۰۰۲
LORE	۰٫۰۲۶ ± ۰٫۰۰۶	۰٫۰۱۴ ± ۰٫۰۰۱	۰٫۰۲۰ ± ۰٫۰۰۳	۰٫۰۱۵ ± ۰٫۰۰۲	۰٫۰۱۷ ± ۰٫۰۰۲	۰٫۰۱۷ ± ۰٫۰۰۱
پیشنهادی	۰٫۰۷۷ ± ۰٫۰۰۵	۰٫۰۳۱ ± ۰٫۰۰۲	۰٫۰۵۸ ± ۰٫۰۰۳	۰٫۰۳۳ ± ۰٫۰۰۱	۰٫۰۳۵ ± ۰٫۰۰۲	۰٫۰۳۸ ± ۰٫۰۰۲

جدول ۳: نتایج مقایسه کمی بین روش پیشنهادی و سه روش دیگر مربوط به مجموعه داده GOWALLA.

روش	K = ۱۵		K = ۱۰		K = ۵	
	Recall	Precision	Recall	Precision	Recall	Precision
UFC	۰٫۰۸۶ ± ۰٫۰۰۶	۰٫۰۵۱ ± ۰٫۰۰۲	۰٫۰۷۱ ± ۰٫۰۰۵	۰٫۰۵۵ ± ۰٫۰۰۴	۰٫۰۴۳ ± ۰٫۰۰۶	۰٫۰۶۲ ± ۰٫۰۰۵
LFBCA	۰٫۰۷۸ ± ۰٫۰۰۴	۰٫۰۴۹ ± ۰٫۰۰۳	۰٫۰۶۲ ± ۰٫۰۰۳	۰٫۰۵۳ ± ۰٫۰۰۳	۰٫۰۴۰ ± ۰٫۰۰۴	۰٫۰۵۷ ± ۰٫۰۰۷
LORE	۰٫۰۵۰ ± ۰٫۰۰۷	۰٫۰۳۱ ± ۰٫۰۰۱	۰٫۰۴۲ ± ۰٫۰۰۲	۰٫۰۳۷ ± ۰٫۰۰۶	۰٫۰۲۹ ± ۰٫۰۰۳	۰٫۰۴۸ ± ۰٫۰۰۶
پیشنهادی	۰٫۱۰۰ ± ۰٫۰۰۵	۰٫۰۵۸ ± ۰٫۰۰۳	۰٫۰۸۰ ± ۰٫۰۰۲	۰٫۰۶۳ ± ۰٫۰۰۵	۰٫۰۵۵ ± ۰٫۰۰۳	۰٫۰۷۰ ± ۰٫۰۰۴

جدول ۴: مقایسه زمان اجرایی تکنیک‌های مختلف بر روی دو مجموعه داده YELP و GOWALLA در توصیه مکان مورد علاقه.

متد	[۴۴] UFC	[۴۷] LFBCA	[۴۶] LORE	متد پیشنهادی
زمان - Yelp	۹۲ ثانیه	۱۰۱ ثانیه	۳۱۴ ثانیه	۸۷ ثانیه
زمان - Gowalla	۸۶ ثانیه	۹۳ ثانیه	۳۰۲ ثانیه	۸۰ ثانیه

الگوریتم اشتباه کند و همه آنها را در یک خوشه قرار دهد. برای کارهای آینده، قصد داریم به بررسی مجموعه داده‌های دیگری نیز بپردازیم و همچنین یادگیری تقویتی را به جای شبکه کانولوشن در نظر بگیریم زیرا یادگیری را با داده‌های کمتری انجام می‌دهد.

## مراجع

- [1] T. Qian, B. Liu, Q. V. H. Nguyen, and H. Yin, "Spatiotemporal representation learning for translation-based POI recommendation," *ACM Trans. Inf. Syst.*, vol. 37, no. 2, pp. 1-24, Jan. 2019.
- [2] X. Li, D. Han, J. He, L. Liao, and M. Wang, "Next and next new POI recommendation via latent behavior pattern inference," *ACM Trans. Inf. Syst.*, vol. 37, no. 4, pp. 1-28, Sept. 2019.
- [3] W. Liu, H. Lai, J. Wang, G. Ke, W. Yang, and J. Yin, "Mix geographical information into local collaborative ranking for POI recommendation," *World Wide Web*, vol. 23, no. 1, pp. 131-152, Jan. 2020.
- [4] Y. Wu, G. Zhao, K. Li, and X. Qian, "Long-and short-term preference learning for next POI recommendation," in *Int. Conf. Inf. Knowl. Manag. Proc., Association for Computing Machinery, New York, NY, USA*, pp. 2301-2304, Beijing, China, 3-7 Nov. 2019.
- [5] R. Ding and Z. Chen, "RecNet: a deep neural network for personalized POI recommendation in location-based social networks," *Int. J. Geogr. Inf. Sci.*, vol. 32, no. 8, pp. 1631-1648, Aug. 2018.
- [6] T. N. Doan and E. P. Lim, "Modeling location-based social network data with area attraction and neighborhood competition," *Data Min. Knowl. Discov.*, vol. 33, no. 1, pp. 58-95, Jan. 2019.
- [7] D. Lian, K. Zheng, Y. Ge, L. Cao, E. Chen, and X. Xie, "GeoMF++: scalable location recommendation via joint geographical modeling and matrix factorization," *ACM Trans. Inf. Syst.*, vol. 36, no. 3, pp. 1-29, Mar. 2018.
- [8] M. Ye, P. Yin, W. C. Lee, and D. L. Lee, "Exploiting geographical influence for collaborative point-of-interest recommendation," in *SIGIR'11-Proc. 34th Int. ACM SIGIR Conf. Res. Dev. Inf. Retr., Association for Computing Machinery*, pp. 325-334, Beijing, China, 24-28 Jul. 2011.
- [9] Z. Zhang, C. Li, Z. Wu, A. Sun, D. Ye, and X. Luo, "NEXT: a neural network framework for next POI recommendation," *Front. Comput. Sci.*, vol. 14, no. 2, pp. 314-333, Apr. 2020.
- [10] Y. Gao, Z. Duan, W. Shi, J. Feng, and Y. Y. Chiang, "Personalized recommendation method of POI based on deep neural network," in *Proc. Int. Conf. on Behavioral, Economic and Socio-Cultural*

مقایسه زمان اجرایی متد پیشنهادی و سه روش دیگر در توصیه مکان مورد علاقه به کاربر برای ۲ مجموعه داده Yelp و Gowalla در جدول ۴ نشان داده شده است. همان طور که مشاهده می‌شود همپوشانی خوشه‌ها و بررسی روابط دوستی کاربران در پیشنهاد مکان مؤثر می‌باشند. در مجموع، در این مقاله روش جدیدی از یادگیری عمیق در مورد پیشنهاد متوالی مکان‌های مورد علاقه کاربران به صورت دقیق ارائه شده که الگوی رفتاری دوستان مشابه را در نظر می‌گیرد. مدل پیشنهادی دقت توصیه مکان مورد علاقه را در مقایسه با سایر روش‌های پیشنهادی بهبود داده است.

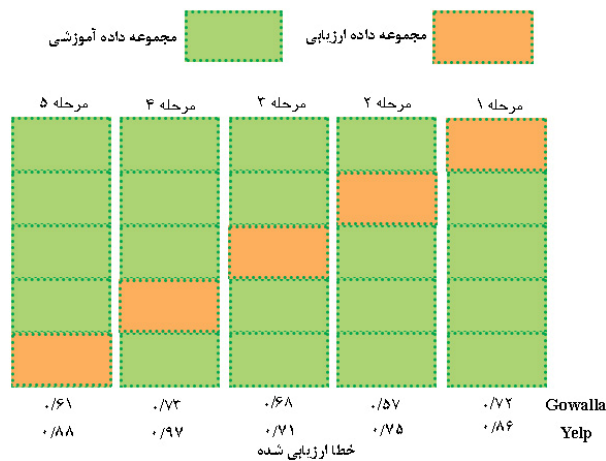
## ۴- نتیجه‌گیری و کارهای آینده

در این مطالعه، چارچوبی جدید و مؤثر برای پیشنهاد مکان شخصی‌شده با ترکیب اهمیت دوست، شباهت ثابت مکان و ترجیحات کاربر ارائه شده است. از استراتژی خوشه‌بندی انتقال میانگین برای یافتن مهم‌ترین روابط دوستی و استفاده از یک رابطه قدرتمند جهت بررسی ترجیحات کاربر استفاده شده است. آنالیز ما نشان می‌دهد که در مقایسه با الگوریتم‌های مبتنی بر مکان، ساختار پیشنهادی شبکه عصبی کانولوشن که از تجربیات کاربران دیگر استفاده می‌کند، می‌تواند توصیه‌های مناسب‌تر مکان مورد علاقه را ارائه دهد. ما همچنین نشان می‌دهیم که در نظر گرفتن تنها تجربیات کاربر که دارای بیشترین الگوی مشابه در بازدید از مکان هستند (با استفاده از روش خوشه‌بندی) می‌تواند در بهبود عملکرد پیش‌بینی مفید باشد. یک آزمایش جامع در مجموعه داده‌های واقعی Gowalla و Yelp انجام شده است. تحقیقات جامع نشان می‌دهد که مدل پیشنهادی از سایر تکنیک‌های پیشرفته بهتر عمل می‌کند. محدودیت‌های این تحقیق، مقدار داده‌های مورد نیاز برای یادگیری شبکه بوده و همچنین به دلیل استفاده از روش خوشه‌بندی، ممکن است محدودیت‌هایی در خوشه‌ها وجود داشته باشد. به عنوان مثال در یک منطقه، ما می‌خواهیم چندین رستوران را به شما پیشنهاد دهیم. اگر رستوران‌ها خیلی نزدیک باشند، ممکن است



## Archiva of SID

- [26] J. Michel, D. Youssefi, and M. Grizonnet, "Stable mean-shift algorithm and its application to the segmentation of arbitrarily large remote sensing images," *IEEE Trans. Geosci. Remote Sens.*, vol. 53, no. 2, pp. 952-964, Jul. 2015.
- [27] K. Fukunaga and L. D. Hostetler, "The estimation of the gradient of a density function, with applications in pattern recognition," *IEEE Trans. Inf. Theory*, vol. 21, no. 1, pp. 32-40, Jan. 1975.
- [28] N. Karimi, R. Ranjbarzadeh Kondrood, and T. Alizadeh, "An intelligent system for quality measurement of Golden Bleached raisins using two comparative machine learning algorithms," *Meas. J. Int. Meas. Confed.*, vol. 107, pp. 68-76, 1 Sept. 2017.
- [29] P. J. Sudharshan, C. Petitjean, F. Spanhol, L. E. Oliveira, L. Heutte, and P. Honeine, "Multiple instance learning for histopathological breast cancer image classification," *Expert Syst. Appl.*, vol. 117, pp. 103-111, 1 Mar. 2019.
- [30] F. Ozyurt, T. Tuncer, E. Avci, M. Koc, and I. Serhatlioglu, "A novel liver image classification method using perceptual hash-based convolutional neural network," *Arab. J. Sci. Eng.*, vol. 44, no. 4, pp. 3173-3182, Apr. 2019.
- [31] Y. Bengio, "Practical recommendations for gradient-based training of deep architectures," in *Neural Networks: Tricks of the Trade*, pp. 437-478, Springer, Berlin, Heidelberg, 2012.
- [32] J. Dolz, C. Desrosiers, and I. Ben Ayed, "3D fully convolutional networks for subcortical segmentation in MRI: a large-scale study," *Neuroimage*, vol. 170, pp. 456-470, 15 Apr. 2018.
- [33] X. Glorot, A. Bordes, and Y. Bengio, "Deep sparse rectifier neural networks," in *Proc. of the 14th. Int. Conf. on Artificial Intelligence and Statistics*, vol. 15, pp. 315-323, Fort Lauderdale, FL, USA, 11-13 Apr. 2011.
- [34] W. Shang, K. Sohn, D. Almeida, and H. Lee, "Understanding and improving convolutional neural networks via concatenated rectified linear units," in *Proc. 33rd. Int. Conf. on Machine Learning*, vol. 48, pp. 2217-2225, New York, NY, USA, 19-24 Jun. 2016.
- [35] F. C. Morabito, M. Campolo, C. Ieracitano, and N. Mammone, "Deep learning approaches to electrophysiological multivariate time-series analysis," in *Artificial Intelligence in the Age of Neural Networks and Brain Computing*, ch. 11, pp. 219-243, Academic Press, 2018.
- [36] W. Yin, H. Schutze, S. Schutze, B. Xiang, and B. Zhou, *ABCNN: Attention-Based Convolutional Neural Network for Modeling Sentence Pairs*, 2016. <https://github.com/> (accessed January 4, 2021).
- [37] F. Husain, B. Dellen, and C. Torras, "Scene understanding using deep learning," in *Handbook of Neural Computation*, ch. 20, pp. 373-382, Academic Press, 2017.
- [38] M. Havaei, et al., "Brain tumor segmentation with deep neural networks," *Med. Image Anal.*, vol. 35, pp. 18-31, Jan. 2017.
- [39] N. Srivastava, G. Hinton, A. Krizhevsky, and R. Salakhutdinov, "Dropout: a simple way to prevent neural networks from overfitting," vol. 15, no. 56, pp. 1929-1958, 2014.
- [40] T. Y. Kim and S. B. Cho, "Predicting residential energy consumption using CNN-LSTM neural networks," *Energy*, vol. 182, pp. 72-81, Sept. 2019.
- [41] J. Chen, Z. Liu, H. Wang, A. Nunez, and Z. Han, "Automatic defect detection of fasteners on the catenary support device using deep convolutional neural network," *IEEE Trans. Instrum. Meas.*, vol. 67, pp. 257-269, Dec. 2017.
- [42] Yelp Dataset. Available online: (n.d.). <https://www.yelp.com/dataset>.
- [43] E. Cho, S. A. Myers, and J. Leskovec, "Friendship and mobility: user movement in location-based social networks," in *Proc. ACM SIGKDD Int. Conf. Knowl. Discov. Data Min.*, pp. 1082-1090, San Diego, CA, USA, 21-24 Aug. 2011.
- [44] J. Zhou, B. Liu, Y. Chen, and F. Lin, "UFC: a unified POI recommendation framework," *Arab. J. Sci. Eng.*, vol. 44, no. 11, pp. 9321-9332, Nov. 2019.
- [45] I. Rahman, et al., "Ergothioneine inhibits oxidative stress- and TNF- $\alpha$ -induced NF- $\kappa$ B activation and interleukin-8 release in alveolar epithelial cells," *Biochem. Biophys. Res. Commun.*, vol. 302, no. 4, pp. 860-864, Mar. 2003.
- [46] J. D. Zhang, C. Y. Chow, and Y. Li, "LORE: exploiting sequential influence for location recommendations," in *Proc. 22nd. ACM Int. Symp. Adv. Geogr. Inf. Syst., Association for Computing Machinery*, pp. 103-112, Dallas, TX, NY, USA, 3-7 Nov. 2014.
- [47] H. Wang, M. Terrovitis, and N. Mamoulis, "Location recommendation in location-based social networks using user check-in data," in *Proc. 21nd. ACM Int. Symp. Adv. Geogr. Inf. Syst., Association for Computing Machinery*, pp. 364-373, Orlando, FL, USA, 5-8 Nov. 2013.



خطای نهایی برابر است با میانگین خطای مراحل انجام شده

شکل ۸: ارزیابی متد اعتبارسنجی متقاطع  $K$  بخشی.

Computing, 6 pp., Beijing, China, 28-30 Oct. 2019.

- [11] M. A. Sit, C. Koylu, and I. Demir, "Identifying disaster-related tweets and their semantic, spatial and temporal context using deep learning, natural language processing and spatial analysis: a case study of Hurricane Irma," *Int. J. Digit. Earth*, vol. 12, no. 11, pp. 1205-1229, Jan. 2019.
- [12] J. Zhang, Y. Xie, Q. Wu, and Y. Xia, "Medical image classification using synergic deep learning," *Med. Image Anal.*, vol. 54, no. 1, pp. 10-19, May 2019.
- [13] P. Y. Hao, W. H. Cheang, and J. H. Chiang, "Real-time event embedding for POI recommendation," *Neurocomputing*, vol. 349, pp. 1-11, 15 Jul. 2019.
- [14] J. Yuan, X. Hou, Y. Xiao, D. Cao, W. Guan, and L. Nie, "Multi-criteria active deep learning for image classification," *Knowledge-Based Syst.*, vol. 172, pp. 86-94, 15 May. 2019.
- [15] R. Ranjbarzadeh and S. B. Saadi, "Automated liver and tumor segmentation based on concave and convex points using fuzzy c-means and mean shift clustering," *Meas. J. Int. Meas. Confed.*, vol. 150, pp. 230-269, Jan. 2020.
- [16] H. Yin, W. Wang, H. Wang, L. Chen, and X. Zhou, "Spatial-aware hierarchical collaborative deep learning for POI recommendation," *IEEE Trans. Knowl. Data Eng.*, vol. 29, no. 8, pp. 2537-2551, Aug. 2017.
- [17] F. He and P. Wei, "Research on comprehensive point of interest (POI) recommendation based on spark," *Cluster Comput.*, vol. 22, no. 4, pp. 9049-9057, Jul. 2019.
- [18] L. Huang, Y. Ma, S. Wang, and Y. Liu, "An attention-based spatiotemporal LSTM network for next POI recommendation," *IEEE Trans. Serv. Comput.*, vol. 12, no. 1, pp. 1-1, May 2019.
- [19] L. Sun, "POI recommendation method based on multi-source information fusion using deep learning in location-based social networks," *J. Inf. Process. Syst.*, vol. 17, no. 2, pp. 352-368, Apr. 2021.
- [20] H. Wang, P. Li, Y. Liu, and J. Shao, "Towards real-time demand-aware sequential POI recommendation," *Inf. Sci. (Nij)*, vol. 547, pp. 482-497, 8 Feb. 2021.
- [21] J. Zeng, H. Tang, Y. Zhao, M. Gao, and J. Wen, "PR-RCUC: a POI recommendation model using region-based collaborative filtering and user-based mobile context," *Mob. Networks Appl.*, vol. 26, no. 3, pp. 1-11, Jan. 2021.
- [22] A. Ellahyani and M. El Ansari, "Mean shift and log-polar transform for road sign detection," *Multimed. Tools Appl.*, vol. 76, no. 22, pp. 24495-24513, Nov. 2017.
- [23] Q. Mahmood, A. Chodorowski, and M. Persson, "Automated MRI brain tissue segmentation based on mean shift and fuzzy c-means using a priori tissue probability maps," *IRBM*, vol. 36, no. 3, pp. 185-196, Jun. 2015.
- [24] D. Comaniciu and P. Meer, "Mean shift: a robust approach toward feature space analysis," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 24, no. 5, pp. 603-619, Aug. 2002.
- [25] Z. Liu, J. Liu, X. Xiao, H. Yuan, X. Li, J. Chang, and C. Zheng, "Segmentation of white blood cells through nucleus mark watershed operations and mean shift clustering," *Sensors*, vol. 15, no. 9, pp. 22561-22586, Sept. 2015.

*Archive of SID*

**مهرداد جلالی** تحصیلات خود را در مقطع کارشناسی مهندسی نرم‌افزار از دانشگاه آزاد اسلامی واحد مشهد در سال ۱۳۷۷ و مدرک کارشناسی ارشد هوش مصنوعی و رباتیک را در سال ۱۳۸۰ از دانشگاه آزاد اسلامی واحد علوم و تحقیقات و دکترای هوش محاسباتی از دانشگاه یو پی ام مالزی در سال ۱۳۸۸ به اتمام رسانیده و از سال ۱۳۸۱ عضو هیأت علمی گروه کامپیوتر دانشگاه آزاد اسلامی واحد مشهد است و از سال ۱۳۹۷ دانشیار این گروه می‌باشد. ایشان از سال ۱۳۹۸ پژوهشگر علم داده در انستیتو فناوری کارلسروهه آلمان و عضو سازمان موسسه استاندارد سازی آلمان هستند. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: علم داده، یادگیری ماشین، وب معنایی و مهندسی آنتولوژی، سیستم‌های توصیه‌گر، تحلیل مواد و تحلیل شبکه‌های اجتماعی.

**صدف صفوی** در سال ۱۳۸۹ مدرک کارشناسی ارشد مهندسی فناوری اطلاعات خود را از دانشگاه شیراز دریافت نمود. هم‌اکنون دانشجوی دکتری مهندسی نرم‌افزار کامپیوتر در دانشگاه آزاد مشهد است. وی از سال ۱۳۸۹ به تدریس در دانشگاه می‌پردازد و به عنوان مشاور فنی در شرکت‌های دانش بنیان فعالیت دارد. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: شبکه‌های عصبی، سیستم‌های توصیه‌گر، تحلیل شبکه‌های اجتماعی می‌باشد.