



رویکردی نوین جهت انتخاب و پیشنهاد مکان مورد علاقه بر پایه شبکه عصبی کانولوشن عمیق

صدف صفوی^(۱) مهرداد جلالی*^{(۱) (۲)} محبوبه هوشمند^(۱)

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

2) Institute of Functional Interfaces (IFG), Karlsruhe Institute of Technology (KIT), Hermann-von Helmholtz 4 Platz 1, Eggenstein-Leopoldshafen, 76344, Germany*

تاریخ پذیرش: ۱۴۰۱/۴/۱۴

تاریخ دریافت: ۱۴۰۱/۱/۱۷

چکیده

فعالیت در شبکه‌های اجتماعی مبتنی بر مکان مانند Yelp و Gowalla به بخشی اساسی از زندگی روزمره کاربران تبدیل شده است و به راحتی می‌توانند از رفتارهای دوستان خود و نقاط جذاب بازدید شده توسط آنان اطلاع یافته و تحت تأثیر آنها قرار گیرند. در نتیجه، وجود توصیه‌های هدفمند و استخراج ویژگی‌های کلیدی نقاط مورد علاقه و کاربران از اهمیت بالایی برخوردار است. در این مقاله، یک روش جدید برای توصیه نقاط مورد علاقه مبتنی بر شبکه عصبی کانولوشن پیشنهاد شده است، که با توجه به الگوی رفتاری شبیه‌ترین دوست کاربر عمل می‌کند. برای یافتن شباهت، از روش خوشه‌بندی فازی C-Means استفاده می‌کنیم و مکان‌های نزدیک به مرکز یک خوشه از میزان وابستگی بالاتری برخوردار خواهند بود. چارچوب پیشنهادی شبکه عصبی کانولوشن ارائه شده به عنوان ورودی، شش ویژگی شامل شناسه کاربر، ماه، روز، ساعت، دقیقه و ثانیه که زمان بازدید هر کاربر می‌باشد را در نظر می‌گیرد و با ۹ 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 دقیق را توصیه کند. تکنیک ما در دو مجموعه داده شبکه‌های اجتماعی مبتنی بر مکان ارزیابی شده و نتایج تجربی نشان می‌دهد که روش پیشنهادی دقت بالاتری نسبت به رویکردهای پیشرفته برای توصیه مکان‌های مورد علاقه دارد.

واژه‌های کلیدی: شبکه‌های اجتماعی، نقاط مورد علاقه، روابط دوستی، خوشه‌بندی فازی C-Means، شبکه عصبی کانولوشن

* عهده‌دار مکاتبات:

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

تلفن: پست الکترونیکی: mehrdad.jalali@kit.edu

امروزه به دلیل افزایش چشمگیر تلفن‌های هوشمند، سرویس‌ها و شبکه‌های اجتماعی مبتنی بر مکان^۱ مانند Foursquare، Gowalla، Brightkite و Yelp محبوب هستند. Foursquare در سال ۲۰۲۰، ماهانه بیش از ۵۵ میلیون کاربر فعال دارد و به طور متوسط روزانه ۹ میلیون check-in ثبت می‌کند و ماهانه بیش از ۳ میلیارد بازدید از مکان‌های مختلف در سراسر جهان از طریق آن صورت می‌گیرد. همچنین شبکه‌های اجتماعی مبتنی بر مکان به کاربران این امکان را می‌دهند تا اطلاعات را به اشتراک گذاشته و با یکدیگر دوست شوند.

این شبکه‌های اجتماعی مبتنی بر مکان، اطلاعات ثبت^۲ سیستم کاربران را مانند تجربیات کاربران و اطلاعات جغرافیایی مکان بازدید شده (طول و عرض جغرافیایی) جمع‌آوری می‌کنند [۱] [۲]. شکل ۱ نمونه‌ای از شبکه اجتماعی مبتنی بر مکان است که تعاملات و روابط دوستی بین کاربران و تعامل بین مکان‌های مورد علاقه^۳ و کاربران (به عنوان مثال، فعالیت‌های ثبت) را نشان می‌دهد. برای افزایش تجربه کاربر در شبکه‌های اجتماعی مبتنی بر مکان و با کمک تحلیل روابط اجتماعی و رکوردهای ثبت آنها، توصیه گر مکان مورد علاقه، به کاربران مکان‌های جدید را برای بازدید پیشنهاد می‌دهد.

توصیه مکان جذاب و مورد علاقه وظیفه‌ای مهم است که مهمترین نتایج را در شبکه‌های اجتماعی مبتنی بر مکان بدست می‌آورد و به کاربران این امکان را می‌دهد که مکان‌های جالب جدیدی را در این شبکه‌های اجتماعی کشف کنند. معمولاً توصیه گر مکان، اطلاعات خاصی در مورد مکان‌های جذاب و روابط اجتماعی کاربران و دسته‌بندی آنها ارائه می‌دهد و لیستی از مکان‌هایی که کاربران به احتمال زیاد از آنها بازدید خواهند کرد؛ به دلیل اینکه این مکانها توسط دوستان آنها بازدید شده است را توصیه می‌کند. پیشنهاد مکان جذاب نه تنها علاقه کاربر به خدمات شبکه‌های اجتماعی مبتنی بر مکان را بهبود می‌بخشد بلکه به شرکت‌های تبلیغاتی نیز برای برنامه ریزی، راه اندازی و تجزیه و تحلیل یک کمپین بازاریابی موفق سود می‌رساند. به طور خاص در Foursquare، کاربران قادرند مراکز خرید و رستوران‌های نزدیک خود را شناسایی کنند. کیفیت خدمات شبکه‌های اجتماعی مبتنی بر مکان و مزایای آن، برای هر دو صاحبان مکان‌ها و کاربران می‌تواند با توصیه شخصی مکان مورد علاقه بهبود یابد. به عنوان مثال، کاربران قادر به کشف مکان‌های جذابی هستند که به طور بالقوه متناسب با ویژگی آنها توصیه می‌شود [۳] [۴] [۵].

1- LBSNs

2- check-in

3- Point-of-Interest(POI)



شکل ۱. نمایش سیستم توصیه شده مبتنی بر کاربر.

در مطالعات قبلی نشان داده شده است که توصیه مکان مورد علاقه به طور قابل توجهی توسط سه فاکتور مهم کنترل می شود: اهمیت دوست [۶]، شباهت ثبت اطلاعات [۷] و ترجیحات کاربر [۸]. اهمیت دوست، نفوذ و تأثیر یک دوست را در بازدید از یک مکان ارزیابی می کند. ترجیحات کاربر تشابه بین تمایلات کاربران به مکان های خاص در یک منطقه مورد علاقه را تشریح می کند. علایق مشترک در بین کاربران، منجر به احتمال بازدید مکان های مورد علاقه مشابه هم می شود. رفتار کاربران مرتبط با مکان های بازدید شده و ثبت آنها می باشد. به عنوان مثال، کاربران تمایل دارند چندین مکان دیدنی را سفر کنند یا با مسافت های کوتاه به مکان های اطراف خود بروند. از آنجایی که بشر تمایل به زندگی در گروه و اجتماع را دارد، اهمیت دوست یک فاکتور اساسی در سیستم های توصیه مکان مورد علاقه است. فعالیت های ثبت یک کاربر بسیار تحت تأثیر دوستان خود قرار می گیرد [۹] [۸].

در طی چند سال گذشته، استفاده مداوم از یادگیری عمیق در امور مرتبط با هوش مصنوعی مانند توصیه مکان مورد علاقه، پردازش زبان طبیعی و بینایی ماشین افزایش یافته است و می توان ویژگی های کلیدی را به صورت عمیق و مؤثر استخراج کرد [۱۰] [۱۱] [۱۲] [۱۳]. یادگیری عمیق یک روش یادگیری بازنمایی^۱ است که توانایی یادگیری ارائه و نمایش داده ها را با چندین ماژول ساده دارد. هر ماژول سطح بالاتر ورودی (ماژول سابق) از داده های سطح پایین را نمایش می دهد [۱۴] [۱۵]. از این رو، ساختارهای مختلف یادگیری عمیق در استخراج ویژگی های اصلی سطح بالا، که مناسب سیستم های توصیه گر می باشند، بسیار مناسب هستند.

Yin و همکارانش [۱۶]، یک مدل یادگیری عمیق مشارکتی سلسله مراتبی مبتنی بر مکان (SH-CDL) ارائه کردند که یادگیری بازنمایی به صورت افزایشی و سلسله مراتبی بوده و با توجه به ویژگی های ناهمگن به بررسی ترجیحات شخصی کاربران با توجه به فاکتور مکان می پردازند. روش جدید توصیه مکان مورد علاقه که توسط [۹] بکار گرفته شده است؛ قابلیت تحلیل اطلاعات را در آن واحد دارد. برای تحلیل اطلاعات متنی مکان ها و یادگیری بازنمایی آنها، از شبکه عصبی کانولوشن استفاده شده است. همچنین، برای بهبود دقت، آن ها امبدینگ^۲ مربوط به مکان های مورد علاقه در زمان فعلی را با رویکرد فاکتورسازی

1- representation

2- POI embedding

ماتریس ترکیب می‌کنند. Doan و همکارانش [۶]، مدل‌سازی جدیدی در مورد رفتار ثبت کاربر بر اساس تمرکز بر رقابت محله‌ها و جذابیت منطقه ارائه داده‌اند. سپس بازدید براساس مدل جذابیت منطقه و رقابت محله (VAN) با ترکیب فاکتورهای رقابت همسایه و جذابیت منطقه پیاده سازی شده است. He و همکارانش [۱۷]، یک مدل توصیه مکان مورد علاقه را براساس ادغام فاکتورهای زمانی، فاکتورهای جغرافیایی و فاکتورهای اجتماعی ارائه کرده است. رویکرد آنها بر اساس ترکیب وزن دهی خطی و آشناری می‌باشد. شبکه عصبی عمیق که توسط [۵] پیشنهاد شده است چندین ویژگی را در شبکه‌های اجتماعی مبتنی بر مکان ترکیب کرده و تأثیر آنها را بر رفتار کاربران بررسی کرده است. علاوه بر این، برای کاهش پراکندگی داده‌ها در سیستم‌های توصیه مکان مورد علاقه، از تأثیرات طبقه بندی جغرافیایی و بازدیدهای مشترک استفاده شده است.

با توجه به اهمیت پیشنهاد مکان 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 جدید، ترکیبی از شبکه عصبی کانولوشن^۱ و روش خوشه‌بندی فازی c -means^۲ می‌باشد که در ابتدا براساس الگوی رفتاری ثبت مکان‌ها توسط دوستان کاربر، شبیه‌ترین دوست را مشخص نموده و همچنین مدل پیشنهادی شبکه عصبی کانولوشن براساس 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 با الگوی دوست مشابه محاسبه شده و مکان بعدی به کاربر پیشنهاد می‌گردد. به طور خلاصه دستاوردهای این مقاله به شرح زیر می‌باشد:

- 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 که مکان‌های دقیق بعدی کاربر را براساس الگوی رفتاری ثبت دوستان مشابه وی پیشنهاد می‌دهد،
- از روش خوشه‌بندی فازی c -means برای یافتن دوستان مشابه کاربر استفاده شده و در یک چارچوب جدید پیشنهادها را براساس تمام مکان‌های بازدید شده و زمان مربوطه ارائه داده‌ایم،
- معماری پیشنهادی یک گروه از کاربران را با توجه به ترجیحات گذشته مشابه با کاربر فعلی طبقه بندی می‌کند،
- برای بهبود دقت، کوتاه‌ترین فاصله بین این مکان پیش‌بینی شده و تمام مکان‌های ممکن مجاور مرتبط با بهترین دوست مشابه محاسبه می‌شود،
- 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.

۲. اصول و روش‌ها

ساختار این مقاله به شرح زیر است. در بخش ۱-۲، رویکرد خوشه‌بندی برای مکان مورد علاقه توضیح داده شده است. در قسمت ۲-۲، معماری شبکه عصبی کانولوشن مشخص می‌شود. در قسمت ۳-۲، مدل پیشنهادی شبکه عصبی کانولوشن را ارائه می‌دهیم. نتایج و سخنان نهایی در بخش ۳ شرح داده شده است.

1- Convolution Neural Network(CNN)

2- C-Means Clustering

۱-۲. خوشه‌بندی مکان‌های مورد علاقه

خوشه‌بندی یک استراتژی جداسازی / بخش بندی داده‌های بدون نظارت است، که در آن هر خوشه دارای بیشترین شباهت ویژگی‌ها می‌باشد [۱۸]. روش فازی c-means به طور تکراری پیکسل‌ها را بر اساس معیارهای خاصی از جمله تفاوت در زمان، بزرگی و مکان گروه بندی می‌کند. در این روش، داده‌ها بر اساس دانش پیشین به خوشه‌های (n خوشه) از قبل تعریف شده تقسیم شده و یا بر اساس سایر اطلاعات موجود محاسبه می‌شوند به طوری که هر نقطه خاص در مجموعه داده (مکان در مجموعه داده ما) حداقل به دو خوشه بدون توجه به وزن آنها تعلق دارد. علاوه بر این، رویکرد خوشه‌بندی می‌تواند از اطلاعات پنهان یا روابط قبلی کشف نشده در داده‌های ورودی پرده بردارد [۱۹] [۲۰].

در خوشه‌بندی غیر فازی، هر مکان از داده‌ها فقط به یک خوشه تعلق دارد. در مقابل، در تکنیک فازی c-means، مکان‌های نزدیک به مرکز یک خوشه از میزان وابستگی بالاتری برخوردار هستند یا به آن خوشه تعلق دارند، در حالی که مکان‌هایی با فاصله دورتر از مرکز خوشه، وابستگی کمتری به آن خوشه دارند. در این روش فازی، مرکز خوشه هر بخش با به روزرسانی تکراری سطح عضویت هر مکان جستجو می‌شود. این روند با به حداقل رساندن تابع هدف زیر انجام می‌شود [۱۸]:

$$E = \sum_{k=1}^k \sum_{i=1}^N \beta_{ki} \|location_i - center_c\|^2 \quad (1)$$

$$\beta_{ki} = 1 / \left(\sum_{j=1}^k \left(\frac{location_i - center_c}{location_i - center_j} \right)^t \right) \quad (2)$$

$$\sum_{k=1}^m \beta_{ki} = 1, \beta_{ki} \in [0,1] \quad (3)$$

در اینجا β_{ki} ارزش عضویت مکان i_{th} با توجه به خوشه را نشان می‌دهد، N تعداد مکان‌های بازدید شده توسط هر کاربر را مشخص می‌کند، k و U ، تعداد خوشه‌ها را نمایش می‌دهند، $center_c$ مرکز خوشه C_{th} را نشان می‌دهد و $location_i$ مکان i_{th} را مشخص می‌کند.

در مقاله پیشنهادی ما، ابتدا، بازه زمانی را به ۴ بخش تقسیم می‌کنیم (۰۶~۰۰، ۰۶~۰۱، ۰۱~۱۲، ۱۲~۰۱، ۰۱~۱۸، ۱۸~۰۱، ۰۱~۲۴). و هر کاربر و دوستان مربوط به او انتخاب می‌گردند. به عبارت دیگر، همه مکان‌های بازدید شده براساس زمان بازدید دسته‌بندی می‌شوند (شکل ۲). با توجه به اعمال چنین تفاوتی در زمان مکان‌های بازدید شده مربوط به دوستان کاربر، می‌توان پیش‌بینی موقعیت مناسب را در نتیجه نهایی بدست آورد. همچنین، همانطور که در شکل ۳ نشان داده شده است، کل مکان‌های بازدید شده هر کاربر در هر بخش در ۵ خوشه جمع شده است. براساس آزمون و خطا به این نتیجه رسیدیم که تعداد ۵ خوشه می‌تواند بهترین نتیجه را در مجموعه داده‌های ما بدست آورد.



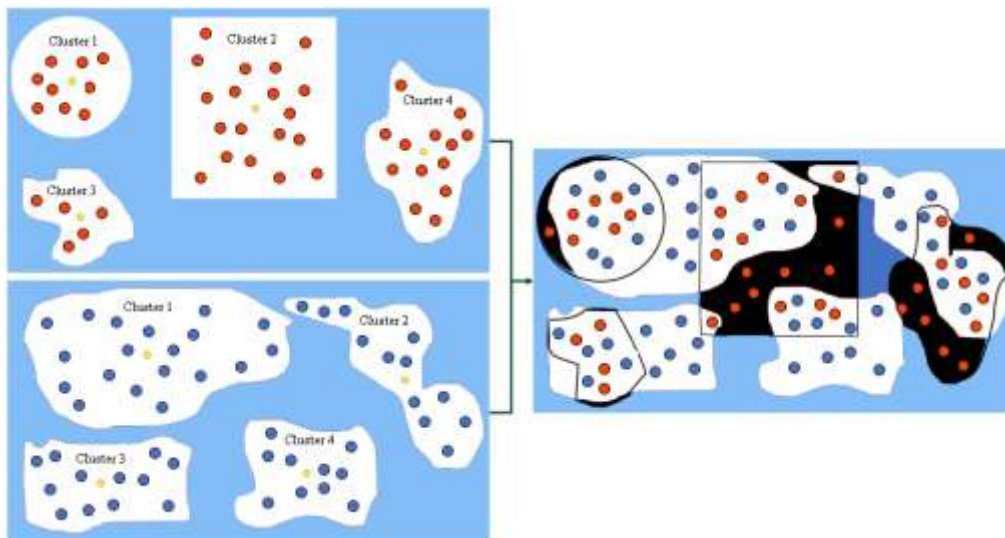
زمان بین ۱۸ - ۲۴ (۶ ساعت)



زمان بین ۰۰ - ۰۶ (۶ ساعت)

شکل ۲. تصویری از کاربرد رویکرد خوشه‌بندی برای دو بازه زمانی متفاوت از یک کاربر.

سپس، برای هر کاربر، درصد همپوشانی بین خوشه‌های کاربر و خوشه‌های دوستان وی محاسبه شده است. در نهایت، فقط ۱۰ درصد از بیشترین خوشه‌های همپوشانی انتخاب شده‌اند. ما تلاش می‌کنیم تا بتوانیم با پیاده سازی این استراتژی همراه با دیگر الگوریتم‌ها، مکان‌های ترجیحی نهایی را با دقت بیشتری بدست آوریم.



شکل ۳. نمایش محاسبه خوشه‌های همپوشان.

۲-۲. شبکه عصبی کانولوشن

تشخیص الگو، دانش تفاوت بین الگوهای مختلف توسط کامپیوترها است و ارتباط نزدیکی با یادگیری ماشین و هوش مصنوعی دارد و در زمینه بینایی ماشین برای برنامه‌های بشمارای مانند داده کاوی، سیستم‌های توصیه گر و تصویربرداری بیولوژیکی مورد استفاده قرار می‌گیرد [۲۱][۲۲].

امروزه در روش‌های تشخیص الگو و برنامه‌های آنها، مدل‌های شبکه عصبی کانولوشن موفقیتی بزرگ در تجزیه و تحلیل داده‌ها است. معماری شبکه عصبی کانولوشن عمدتاً از رابطه بین برخی ویژگی‌ها یا محتوای ساختاری استفاده کرده و در مرکز همه تکنیک‌ها از داده کاوی گرفته تا پیش‌بینی بازدید از مکان‌های جدید توسط افراد قرار دارد [۲۳].

این شبکه که مبتنی بر نورون است دارای یک توپولوژی مشابه شبکه است که به ما این امکان را می‌دهد که با عبور از یک سری لایه‌های کانولوشن با اندازه کرنل از پیش تعیین شده، به طور موثری بتوانیم ویژگی‌ها و اطلاعات کلیدی را از نقاط مورد علاقه و رابطه‌های دوستی استخراج کنیم. این مدل بر پایه نورون، شامل بسیاری از وزن‌ها و بایاس‌های آموزش دیده است و برای استخراج، طبقه بندی و پیش‌بینی ویژگی‌ها به کار گرفته می‌شود. این وزن‌ها و بایاس‌ها در ابتدای آموزش به صورت تصادفی اعمال می‌شوند. بخش کلیدی و حیاتی هر شبکه عصبی کانولوشن که به عنوان لایه کانولوشن مشخص شده است به محاسبه ضرب داخلی^۱ بین فیلترها (آرایه‌های دو بعدی برای تصویر و یک بعدی در کار ما) و داده‌های ورودی (مانند مکان‌های مورد علاقه و دوستی‌ها) می‌پردازد [۲۴][۲۵][۲۶][۲۷]. به طور منظم، اولین لایه شبکه عصبی کانولوشن با یک لایه کانولوشن آغاز می‌شود و برای استخراج ویژگی‌ها از داده‌های ورودی نقش حیاتی دارد [۲۳][۲۸].

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 [۲۹]. فیلتر (کرنل) با هر اندازه از پیش تعریف شده، ماتریسی است که هم عمق داده‌های ورودی می‌باشد. به عنوان مثال، اگر اندازه داده‌های ورودی $3 \times 1 \times 6$ باشد، اندازه کرنل به ترتیب $3 \times 3 \times \sim$ مشخص می‌شود. بطوریکه \sim یک عدد فرد است [۲۴][۲۳]. 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 [۲۵].

استراتژی نرمال سازی دسته‌ای^۲ وقتی مفید است که با لایه‌های بسیار عمیقی روبرو هستیم که خروجی هر لایه را برای ورودی لایه بعدی برای هر دسته کوچک^۳ مقیاس بندی و استاندارد می‌کند. این فرآیند استاندارد سازی با جمع آوری مجدد داده‌ها برای داشتن یک انحراف معیار^۴ و میانگین صفر و واریانس یک^۵ انجام می‌شود.

از آنجایی که تأثیرات محو گرادیان^۶ مشکل ساز است، یک تابع فعال سازی دلخواه بر اساس داده‌های ورودی ما بر روی هر ویژگی اعمال می‌شود تا با کاهش پراکندگی، بازده محاسباتی را بهبود بخشد [۳۰][۳۱]. معمولاً، خروجی لایه کانولوشن یا لایه نرمال دسته‌ای به یک لایه فعال سازی وارد می‌شود [۲۶].

1- dot product

2- Batch normalization

3- mini-batch

4- standard deviation

5- mean of zero of one

6- vanishing gradient

در مقاله پیشنهادی ما، تابع فعال سازی ReLU که مبتنی بر پس انتشار خطاها^۱ است، برای تغییر اعداد منفی به مقادیر صفر اعمال شده است. معادله (۴) تابع فعال سازی ReLU را مشخص می‌کند [۳۰].

$$y = \max(0, x) \quad (4)$$

که در آن x ورودی تابع فعال سازی ReLU و y خروجی آن را نشان می‌دهد. از یک لایه تمام متصل^۲ نیز برای دستیابی به ویژگی‌های قوی سطح بالا در داده‌های ورودی استفاده شده است. در این لایه، هر نود به همراه وزن قابل یادگیری خود در هر بردار ورودی ضرب می‌شود [۲۴]. همچنین، قبل از اعمال خروجی لایه کانولوشن یا لایه فعال سازی روی لایه تمام متصل، همه ویژگی‌ها باید به یک بردار عمودی تبدیل شوند [۳۲] [۳۳]. برخلاف لایه‌های کانولوشن، لایه‌های تمام متصل پارامترهای بیشتری را تشکیل می‌دهند که آموزش آنها دشوارتر است [۳۴]. آخرین لایه برای پیش‌بینی در معماری شبکه عصبی کانولوشن، لایه رگرسیون است که رابطه بین یک هدف ایده آل و یک یا چند متغیر مستقل (داده‌های ورودی) را مدل سازی می‌کند [۳۵] [۲۶]. آموزش شبکه عصبی کانولوشن به این معنی است که برای به حداقل رساندن تابع هزینه تعریف شده، مدل باید بهترین وزن‌ها و بایاس‌ها را در هر لایه یاد بگیرد. روند به حداقل رساندن یک تابع هزینه با استفاده از یک تکنیک کاهش گرادینت^۳ به صورت تکراری که شامل محاسبه مشتقات تابع هزینه است، انجام می‌شود [۳۴].

۳-۲. معماری پیشنهادی شبکه عصبی کانولوشن


همانطور که در قسمت قبلی عنوان شد، مدل‌های شبکه عصبی کانولوشن قادر به استخراج اطلاعات اصلی از ماتریس ورودی هستند. بنابراین، ما در این مقاله یک چارچوب جدید براساس همه مکان‌های بازدید شده و زمان مربوط به آنها ارائه می‌دهیم. ساختار مدل پیشنهادی در شکل ۴ نشان داده شده است. روش ما از ۶ ویژگی ورودی شامل شناسه کاربر، ماه، روز، ساعت، دقیقه و ثانیه مربوط به زمان بازدید هر کاربر استفاده می‌کند. همانطور که در شکل ۴ به وضوح نشان داده شده است، ۹ لایه کانولوشن با تعداد مختلف فیلتر وجود دارد. ما ۳ فیلتر با اندازه 2×1 در ۳ لایه اول اعمال کردیم. برای بهبود آموزش و نرمالیزه کردن مقادیر داده‌ها از لایه نرمال سازی دسته‌ای استفاده می‌کنیم و خروجی آن به یک لایه فعال سازی وارد می‌شود، همانطور که در بخش ۲-۲ گفته شد تابع فعال سازی ReLU اعمال شده است. لایه بعدی دارای ۱۶ فیلتر برای استخراج ویژگی‌هایی است که به دنبال آن ۳ لایه و ۳۲ فیلتر مربوط به آنها وجود دارد. مجدد از لایه نرمال سازی دسته‌ای و لایه فعال سازی استفاده می‌کنیم. سپس در لایه بعدی، ۶۴ فیلتر با ابعاد یکسان قرار دارند و برای حفظ مقادیر خروجی لایه‌ها در محدوده نرمال و جلوگیری از بیش برآش^۴ لایه نرمال سازی دسته‌ای و تابع ReLU بکارگرفته می‌شود. لایه‌های کانولوشن نهایی شامل ۲ لایه با ۱۲۸ فیلتر است که توسط ۲ لایه مسطح^۵ دنبال می‌شود. علاوه بر این، برای کاهش تأثیر بیش برآش با استفاده از کنترل فرآیند برآش^۶، دو لایه رهاسازی^۷ [۳۶] با احتمال رهاسازی ۰.۰۱٪ به مدل شبکه عصبی کانولوشن ما اضافه شد تا نرون‌ها به طور مستقل آموزش دیده و کمتر به بقیه نرون‌ها وابسته باشند. مقدار ۰.۰۱ براساس آزمون و خطا در نظر گرفته شده است. سپس

1- backpropagation of errors
 2- Fully-Connected layer (FC)
 3- gradient descent
 4- overfitting
 5- flatten
 6- fitting
 7- dropout

برای دستیابی به ویژگی‌های قوی سطح بالا از دو لایه تمام متصل استفاده می‌شود. سرانجام به دلیل اینکه 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^۱ برای فرآیند آموزش ۸۰۰ و نرخ یادگیری^۲ ۰.۰۱ در نظر گرفته شده است.

در مدل پیشنهادی نیازی نیست که داده‌ها پشت سر هم باشند با توجه به لایه‌های شبکه و پارامترهای آن، موقعیت فعلی کاربر در نظر گرفته می‌شود و ضرورتی ندارد که بدانند چند دقیقه قبل کجا حضور داشته است. در فاز یادگیری، آموزش‌های لازم را دیده است و داده‌ها به صورت تصادفی مرتب شده‌اند.

دو خروجی لایه رگرسیون دقیقاً مکان پیشنهادی را به ما ارائه نمی‌دهند، بنابراین در این مرحله ما باید فاصله زمانی بین این مکان پیش‌بینی شده و تمام مکان‌های ممکن را که در نزدیکی کاربر قرار دارد براساس موقعیت شبیه‌ترین دوست فرد که در مرحله ۱-۲ 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 انتخاب شده وی است. ایده اصلی معماری پیشنهادی، دسته‌بندی کردن گروهی از کاربران با ترجیحات همانند کاربر جاری است که دارای ترجیحات گذشته مشابه می‌باشند.



شکل ۴. مدل شبکه عصبی کانولوشن پیشنهادی ما.

ساختار کانولوشن پیشنهادی ما برای به حداقل رساندن زیان در معادله ۴ از تکنیک RMSE [۳۷] استفاده کرده است، که اختلاف بین مکان‌های واقعی و تخمینی (پیش‌بینی شده) را محاسبه می‌کند.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (estimated - actual)^2} \quad (5)$$

بطوریکه n تعداد پیش‌بینی شده یا مقدار واقعی (طول جغرافیایی و مکان) را مشخص می‌کند.

معماری کلی شبکه یادگیری عمیق ارائه شده برای پیشنهاد نقاط مورد علاقه مناسب و دقیق به کاربران، در شکل ۵ نشان داده شده است.

- 1- epoch
- 2- learning rate



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

۳. آزمایش‌ها

۳-۱. مجموعه داده‌ها

آنالیز مکانی بر روی ثبت کاربران در مجموعه داده‌های واقعی Yelp و Gowalla انجام شده است که اطلاعات جغرافیایی زیادی را در بر می‌گیرد. بنابراین، با بررسی فاصله بین جفت‌های مکان‌های ثبت شده، احتمال وقوع مکان مشترک توسط کاربر بررسی شده است. تاریخچه ثبت ارتباط زیادی با ترجیحات ضمنی کاربر برای یک مکان دارد و می‌تواند به عنوان علائق مرسوم کاربر در نظر گرفته شود. ما می‌توانیم شباهت ثبت‌ها را توسط مجاورت و نزدیکی جغرافیایی بررسی کنیم. همانطور که در [۳۸] ذکر شده رفتارهای ثبت یک کاربر، یک پدیده خوشه‌بندی جغرافیایی را نشان می‌دهد که برای توصیه مکان مورد علاقه مناسب است. اطلاعات بیشتر از این دو مجموعه داده در جدول ۱ شرح داده شده است.

وب سایت Yelp که در سال ۲۰۰۴ تأسیس شد وب سایت معروف تجاری است و تجار زیادی مانند هتل‌ها، مراکز خرید و رستوران‌ها را در بر می‌گیرد. کاربران در Yelp فروشندگان متنوع را ثبت کرده، در مورد این مکان‌های بازدید شده نظر و امتیاز می‌دهند. این مجموعه داده شامل ۳۰۸۳۷ کاربر، ۸۶۰۸۸۸ نظر، ۲۶۵۵۳۳ روابط اجتماعی و ۱۸۹۹۵ مکان مورد علاقه می‌باشد. مجموعه داده Gowalla یک سرویس مبتنی بر مکان است که به کاربران امکان می‌دهد آنچه را می‌شنوند و می‌بینند با خانواده و دوستانشان به اشتراک بگذارند. مجموعه داده Gowalla شامل ۱۸۷۳۷ کاربر، ۱۲۷۸۲۷۴ نظر و بررسی، ۸۶۹۸۵ روابط اجتماعی و ۳۲۵۱۰ مکان مورد علاقه می‌باشد.

جدول ۱. شرح داده‌ها

کاربران	مکان	رکوردها	روابط اجتماعی	پراکندگی (%)
Yelp	۳۰۸۸۷	۱۸۹۹۵	۲۶۵۵۳۳	۸۶۰۸۸۸
Gowalla	۱۸۷۳۷	۳۲۵۱۰	۸۶۹۸۵	۱۲۷۸۲۷۴

۲-۳. معیارهای عملکرد

با مقایسه هر نتیجه مکان پیش‌بینی شده با مکان واقعی مربوط به آن، دو معیار زیر محاسبه شده است تا ترتیب دقیق بهترین مکان‌های جذاب هر کاربر را بدست آورد. دقت قابل توجه مدل ما با استفاده از Precision و Recall ارزیابی شد که معیارها به شرح زیر تعریف می‌شوند [۳۸]:

$$\begin{cases} Precision @k = \frac{1}{|U|} \times \sum_{i=1}^U \frac{|TopK(U_i) \cap L_i|}{|TopK(U_i)|} \\ Recall @k = \frac{1}{|U|} \times \sum_{i=1}^U \frac{|TopK(U_i) \cap L_i|}{|L_i|} \end{cases} \quad (6)$$

که در آن $TopK(U_i)$ با توجه به استراتژیهای مشخص، K تا از بهترین مکان‌های پیشنهاد شده را در نمونه‌های تست نشان می‌دهد، L_i مکان‌هایی را مشخص می‌کند که i امین کاربر در نمونه‌های آموزشی از آنها بازدید کرده است و برای آنالیز کارایی مدل‌ها K تعداد متغیر (از ۵ تا ۵۰) مربوط به مکان‌های پیشنهادی را نشان می‌دهد. $Recall@K$ کسری از مکان‌های بازدید شده توسط کاربر مورد نظر است که به خوبی پیشنهاد شده، در حالیکه $Precision@K$ کسری از k تا بهترین مکان‌های پیشنهادی است که با موفقیت به کاربر هدف توصیه می‌شود.

۳-۳. نتایج تجربی

پروژه پیشنهادی ما در Matlab 2019b پیاده‌سازی شده است و آزمایش‌ها بر روی کامپیوتر مجهز به Core i7- 3.4 GHz، GTX، 1050 Ti GPU و ۸ گیگابایت RAM انجام شد. در این مقاله، سه الگوریتم پیشرفته برای اعتبارسنجی عملکرد مدل پیشنهادی انتخاب شده است.

UFC [۳۸]: UFC یک الگوریتم ترکیبی است که شامل ترجیحات کاربر، اهمیت دوست و شباهت ثبت کاربران می‌باشد. UFC سه فاکتور اساسی را ترکیب کرده و ترجیحات کاربر بر اساس پالایش مشارکتی^۱ شخصی سازی می‌شود.

LFBCA [۳۹]: LFBCA نفوذ روابط اجتماعی را برای هر کاربر در مورد توصیه مکان مورد علاقه بررسی می‌کند. برای مشخص کردن رابطه ثبت، مکان‌ها و کاربران در گراف لینک داده می‌شوند. احتمال هر کاربر به یک مکان بر اساس یک روش مبتنی بر گراف توصیف شده است.


LORE [۴۰]: برای تحلیل تأثیر ترتیب بر پیشنهاد مکان، یک گراف پویای انتقال مکان - مکان توسط زنجیره افزودنی مارکوف^۲ توسط LORE [۴۰] ارائه شده است تا الگوی متوالی مربوط به ترتیب ثبت کاربر استخراج شود.

در مقاله پیشنهادی ما، هدف، دستیابی به ترتیب دقیق k تا از بهترین مکان‌ها برای هر کاربر می‌باشد. ما عملکرد مدل‌های متفاوت را در هر دو مجموعه داده Yelp و Gowalla با توجه به تعداد K مکان توصیه شده با حداکثر مقدار توصیه بررسی می‌کنیم. نتایج ساختار پیش‌بینی ما در مجموعه داده‌های Gowalla و Yelp ارزیابی شده و گزارش آن در شکل‌های ۶ و ۷ ارائه شده است. همانطور که به وضوح نشان داده شده، الگوریتم پیشنهادی ما در هر دو مجموعه داده همواره با توجه به دو معیار، $Recall@K$ و $Precision@K$ ، بهتر از UFC، LFBCA و LORE عمل می‌کند. به عنوان مثال، در Yelp، ما از نظر $Precision@5$ و


1- collaboration filtering

2- additive Markov chain

Precision@10 به ترتیب ۰.۰۳۷ و ۰.۰۳۲ بدست می‌آوریم. این بدان معنی است که روش ما در مقایسه با UFC، LFBCA و LORE به ترتیب ۰.۰۱، ۰.۰۱۵ و ۰.۰۲ بهبود عملکرد دارد. این برتری می‌تواند مشخص کند که الگوریتم پیشنهادی به خوبی از ترکیب روش خوشه‌بندی و روابط دوستی برای توصیه مکان‌ها استفاده کرده است. همانطور که در شکل‌های ۶ و ۷ نشان داده شده، قابل توجه است که وقتی K کوچک است، استراتژی ما هنوز هم می‌تواند به نتایج توصیه شده خوبی دست یابد. به خصوص در شکل ۶، Recall@5 کوچک‌تر از 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 بدست آمده 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 ۶. مقایسه بین الگوریتم پیشنهادی و سه روش دیگر.



شکل ۷. مقایسه بین الگوریتم پیشنهادی و سه روش دیگر.

۴. نتیجه گیری

در این مطالعه، یک چارچوب جدید برای پیشنهاد مکان مورد علاقه با ترکیب شباهت ثبت مکان، اهمیت دوست و ترجیحات کاربر ارائه شده است. جهت بررسی ترجیحات کاربر از یک روش خوشه‌بندی فازی برای یافتن مهمترین روابط دوستی و استفاده از یک رابطه قدرتمند استفاده شده است. این آزمایش نشان می‌دهد که در مقایسه با الگوریتم‌های مبتنی بر مکان، ساختار پیشنهادی شبکه عصبی کانولوشن، که از تجربه‌های کاربران دیگر استفاده می‌کند، می‌تواند توصیه‌های مناسب‌تر مکان‌های مورد علاقه را ارائه دهد. ما همچنین نشان می‌دهیم که در نظر گرفتن تنها تجربه‌های 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. نتایج تجربی نشان می‌دهد که ساختار پیشنهادی از سایر تکنیک‌های پیشرفته بهتر عمل می‌کند.

- [1] T. Qian, B. Liu, Q. V. H. Nguyen and H. Yin, "Spatiotemporal Representation Learning for Translation-Based POI Recommendation," *ACM Transactions on Information Systems*, vol. 37, no. 2, pp. 1-24, 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 Transactions on Information Systems*, vol. 37, no. 4, pp. 1-28, 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, p. pages 131–152, 2020.
- [4] Y. Wu, K. Li, G. Zhao and X. Qian, "Long- and Short-term Preference Learning for Next POI Recommendation," in *Proceedings of the 28th ACM International Conference on Information and Knowledge Management*, 2019.
- [5] R. Ding and Z. Chen, "RecNet: a deep neural network for personalized POI recommendation in location-based social networks," *International Journal of Geographical Information Science*, vol. 32, no. 8, pp. 1631-1648, 2018.
- [6] T.-N. Doan and E.-P. Lim, "Modeling location-based social network data with area attraction and neighborhood competition," *Data Mining and Knowledge Discovery*, vol. 33, no. 1, pp. 58-95, 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 Transactions on Information Systems*, vol. 36, no. 3, pp. 1-29, 2018.
- [8] M. Ye, P. Yin, W.-C. Lee and D.-L. Lee, "Exploiting geographical influence for collaborative point-of-interest recommendation," in *Proceedings of the 34th international ACM SIGIR conference on Research and development in Information Retrieval*, 2011.
- [9] H. Pei-Yi, C. Weng-Hang and C. Jung-Hsien, "Real-time event embedding for POI recommendation," *Neurocomputing*, vol. 349, pp. 1-11, 2019.
- [10] Z. Zhang, C. Li, Z. Wu, A. Sun, D. Ye and X. Luo, "NEXT: a neural network framework for next POI recommendation," *Frontiers of Computer Science*, vol. 14, no. 2, p. 314–333, 2020.
- [11] Y. Gao, Z. Duan, W. Shi, J. Feng and Y.-Y. Chiang, "Personalized Recommendation Method of POI Based on Deep Neural Network," in *2019 6th International Conference on Behavioral, Economic and Socio-Cultural Computing (BESCC)*, Beijing, China, 2019.

- [12] 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," *International Journal of Digital Earth*, vol. 12, no. 11, pp. 1205-1229, 2019.
- [13] S. Safavi and M. Jalali, "Toward Point-of-Interest Recommendation Systems : A Critical Review on Deep-Learning Approaches," 2022.
- [14] L. Huang, Y. Ma, S. Wang and Y. Liu, "An Attention-based Spatiotemporal LSTM Network for Next POI Recommendation," *IEEE Transactions on Services Computing*, 2019.
- [15] J. Yuan, X. Hou, Y. Xiao, D. Cao, W. Guan and L. Nie, "Multi-criteria active deep learning for image classification," *Knowledge-Based Systems*, vol. 172, pp. 86-94, 2019.
- [16] H. Yin, W. Wang, H. Wang, L. Chen and X. Zhou, "Spatial-Aware Hierarchical Collaborative Deep Learning for POI Recommendation," *IEEE Transactions on Knowledge and Data Engineering*, vol. 22, no. 11, pp. 2537 - 2551, 2017.
- [17] F. He and P. Wei, "Research on comprehensive point of interest (POI) recommendation based on spark," *Cluster Computing*, vol. 22, no. 4, p. 9049-9057, 2019.
- [18] R. Ranjbarzadeh and S. S. Baseri, "Automated liver and tumor segmentation based on concave and convex points using fuzzy c-means and mean shift clustering," *Measurement*, vol. 150, no. 107086, 2020.
- [19] T. Yiming, H. Xianghui, W. Pedrycz and S. Xiaocheng, "Possibilistic fuzzy clustering with high-density viewpoint," *Neurocomputing*, vol. 329, pp. 407-423, 2019.
- [20] T. Ren, H. Wang, H. Feng, C. Xu, G. Liu and P. Ding, "Study on the improved fuzzy clustering algorithm and its application in brain image segmentation," *Applied Soft Computing*, vol. 81, p. 105503, 2019.
- [21] N. Karimi, R. Ranjbarzadeh Kondrood and T. Alizadeh, "An intelligent system for quality measurement of Golden Bleached raisins using two comparative machine learning algorithms," *Measurement*, vol. 107, pp. 68-76, 2017.
- [22] P. Sudharshan, C. Petitjean, F. Spanhol, L. Eduardo Oliveira, L. Heutte and P. Honeine, "Multiple instance learning for histopathological breast cancer image classification," *Expert Systems with Applications*, vol. 117, pp. 103-111, 2019.
- [23] A. Mahmood, M. Bennamoun, S. An, F. Sohel, F. Boussaid, R. Hovey, G. Kendrick and R. B. Fisher, "Deep Learning for Coral Classification," in *Handbook of Neural Computation*, Academic Press, 2017, pp. 383-401.
- [24] A. D. Torres, H. Yan, A. H. Aboutaleb, A. Das, L. Duan and P. Rad, "Patient Facial Emotion Recognition and Sentiment Analysis Using Secure Cloud With Hardware Acceleration," in

- Computational Intelligence for Multimedia Big Data on the Cloud with Engineering Applications , Academic Press ,2018, pp. 61-89.
- [25] J. Zhong, Z. Liu, Z. Han, Y. Han and W. Zhang, "A CNN-Based Defect Inspection Method for Catenary Split Pins in High-Speed Railway," IEEE Transactions on Instrumentation and Measurement, vol. 68, no. 8, pp. 2849 - 2860, 2019.
- [26] J. Chen, Z. Liu, H. Wang, A. Núñez and Z. Han, "Automatic Defect Detection of Fasteners on the Catenary Support Device Using Deep Convolutional Neural Network," IEEE Transactions on Instrumentation and Measurement, vol. 67, no. 2, pp. 257-269, 2017.
- [27] F. Özyurt, T. Tuncer, E. Avci, M. Koç and İ. Serhatlioğlu, "A Novel Liver Image Classification Method Using Perceptual Hash-Based Convolutional Neural Network," Arabian Journal for Science and Engineering, vol. 44, no. 4, p. 3173–3182, 2019.
- [28] Y. Bengio, "Practical Recommendations for Gradient-Based Training of Deep Architectures," in Neural Networks: Tricks of the Trade, Berlin, Heidelberg, Springer, 2012, pp. 437-478.
- [29] 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, 2018.
- [30] X. Glorot, A. Bordes and Y. Bengio, "Deep Sparse Rectifier Neural Networks," in Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics, 2011.
- [31] 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, Academic Press, 2019, pp. 219-243.
- [32] W. Shang, K. Sohn, D. Almeida and H. Lee, "Understanding and improving convolutional neural networks via concatenated rectified linear units," in international conference on machine learning, 2016.
- [33] W. Yin, H. Schütze, B. Xiang and B. Zhou, "ABCNN: Attention-Based Convolutional Neural Network for Modeling Sentence Pairs," Transactions of the Association for Computational Linguistics, vol. 4, pp. 259-272, 2016.
- [34] F. Husain, B. Dellen and C. Torras, "Scene Understanding Using Deep Learning," in Handbook of Neural Computation, Academic Press, 2017, pp. 373-382.
- [35] M. Havaei, A. Davy, D. Warde-Farley, A. Biard, A. Courville, Y. Bengio, C. Pal, P.-M. Jodoin and H. Larochelle, "Brain tumor segmentation with Deep Neural Networks," Medical Image Analysis, vol. 35, pp. 18-31, 2017.

- [36] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever and R. Salakhutdinov, "Dropout: a simple way to prevent neural networks from overfitting," The journal of machine learning research, vol. 15, no. 1, pp. 1929-1958, 2014.
- [37] T.-Y. Kim and S.-B. Cho, "Predicting residential energy consumption using CNN-LSTM neural networks," Energy, vol. 182, pp. 72-81, 2019.
- [38] J. Zhou, B. Liu, Y. Chen and F. Lin, "UFC: A Unified POI Recommendation Framework," Arabian Journal for Science and Engineering, vol. 44, p. 9321-9332, 2019.
- [39] H. Wang, M. Terrovitis and N. Mamoulis, "Location recommendation in location-based social networks using user check-in data," in SIGSPATIAL'13: Proceedings of the 21st ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems, 2013.
- [40] J.-D. Zhang, C.-Y. Chow and Y. Li, "LORE: exploiting sequential influence for location recommendations," in Proceedings of the 22nd ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems., 2014.