Information Technology Innovations and Applied Communication

Vol. 3, No. 4, Winter, 2025, Serial No. 8,PP.21-37

Effect of Regularized Autoencoder in Deep Neural Networks based Indoor Localization System in Presence of Adversarial Attack

Ali Karimi[1] , Meysam Raees Danaee*[2]

* Assistant Professor, Imam Hossein University, Tehran, Iran

(**Received:** 28 October 2025, **Revised:** 16 December 2025, **Accepted:** 02 January 2026, **Published:** 21 January 2026)

Abstract

In recent years, extensive research efforts have been devoted to developing high-accuracy and reliable indoor localization techniques. Among the various approaches, Wi-Fi fingerprinting has gained widespread adoption due to the ubiquity and availability of Wi-Fi hardware. In this paper, we propose an indoor positioning system that operates in two stages: an offline training phase and an online position estimation phase. In the offline phase, Received Signal Strength (RSS) data are collected from multiple access points (APs) across different locations within the building. These measurements are then processed by a deep learning network based on an autoencoder equipped with non-smooth regularizers. The autoencoder extracts low-dimensional representations of the RSS data and builds a fingerprint database that stores the mapping between learned representations and their corresponding physical locations. During the online estimation phase, RSS values are measured at an unknown location and passed through the trained autoencoder to obtain their low-dimensional representation. The system then searches for the nearest match within the fingerprint database, and the associated location is returned as the estimated position. To enhance localization accuracy, different types of regularizers are incorporated into the autoencoder structure. Simulation results demonstrate that the proposed deep learning-based indoor localization system with non-smooth regularizers significantly outperforms baseline methods without regularization or with smooth regularizers. For example, when the regularization parameter is set to 0.0003, the Root Mean Square Error (RMSE) decreases from 44.82 m (without regularization) to 24.03 m with smooth regularizers, and further to 7.09 m with non-smooth regularizers, validating the superiority of the proposed framework.

Keywords: Deep neural network, indoor localization, autoencoder, non-smooth regularization.

* Corresponding Author E-mail: mraeesdanaee@ihu.ac.ir

«نوآوری‌های فناوری اطلاعات و ارتباطات کاربردی»
سال سوم، شماره ۴، فصل زمستان، ۱۴۰۴؛ ص ۳۷-۲۱.

علمی- پژوهشی

بهبود موقعیت‌یابی تک کاربر در شبکه WiFi مبتنی بر شبکه یادگیری عمیق با ساختار خود کدگذار دارای رگولاریزاتورهای غیر هموار

علی کریمی[۱]، میثم رئیس‌دانایی[۲*]

۱- دانشجوی دکتری، ۲- استادیار دانشگاه جامع امام حسین (ع)، تهران، ایران

(دریافت: ۰۶ آبان ۱۴۰۴ بازنگری: ۲۵ آذر ۱۴۰۴ پذیرش: ۱۲ دی ۱۴۰۴ انتشار: ۰۱ بهمن ۱۴۰۴)

چکیده

در سال‌های اخیر، پژوهشگران تلاش‌های گسترده‌ای برای توسعه روش‌های مکان‌یابی داخلی بادقت و صحت بالا انجام داده‌اند. در میان رویکردهای مختلف، روش اثر انگشت مبتنی بر Wi-Fi به دلیل دردسترس‌بودن سخت‌افزارهای متعدد Wi-Fi به طور وسیع مورداستفاده قرار گرفته است. در این مقاله، یک سامانه مکان‌یاب داخلی پیشنهادی معرفی می‌شود که فرایند مکان‌یابی را در دو مرحله آموزش آفلاین و تخمین موقعیت آنلاین انجام می‌دهد. در مرحله آموزش آفلاین، داده‌های RSS از چندین نقطه دسترسی (AP) در مکان‌های مختلف ساختمان جمع‌آوری‌شده و سپس یک شبکه یادگیری عمیق با ساختار خود کدگذار و رگولاریزاتورهای غیر هموار به کار گرفته می‌شود. هدف این مرحله، استخراج نمایش کم‌بعد داده‌های RSS و ایجاد پایگاه‌داده اثر انگشت است که نگاشت بین نمایش به‌دست‌آمده و مکان مربوطه را ذخیره می‌کند. در مرحله تخمین موقعیت آنلاین، داده‌های RSS در یک مکان ناشناخته اندازه‌گیری شده و به خود کدگذار آموزش‌دیده وارد می‌شوند تا نمایش کم‌بعد متناظر به دست آید. سپس با جست‌وجو در پایگاه‌داده، نزدیک‌ترین تطابق تعیین و مکان مرتبط به‌عنوان خروجی سیستم گزارش می‌گردد. برای افزایش دقت، از انواع رگولاریزاتورها در ساختار خود کدگذار استفاده‌شده است. نتایج شبیه‌سازی‌ها نشان می‌دهد سامانه مکان‌یاب داخلی مبتنی بر خود کدگذار با رگولاریزاتورهای غیر هموار عملکرد بهتری نسبت به روش‌های بدون رگولاریزاسیون یا دارای رگولاریزاتورهای هموار دارد. به‌عنوان نمونه، در حالتی که مقدار رگولاریزاسیون برابر ۰.۰۰۰۳ انتخاب شد، RMSE شبکه از مقدار ۴۴.۸۲ متر (بدون رگولاریزاتور) به ۲۴.۰۳ متر با رگولاریزاتور هموار و به ۷.۰۹ متر با رگولاریزاتور غیر هموار کاهش یافت.

کلیدواژه‌ها: شبکه عصبی عمیق، مکان‌یابی داخلی، خود کدگذار، رگولاریزاسیون غیر هموار

* رایانامه نویسنده مسئول E-mail: mraeesdanaee@ihu.ac.ir

۱. مقدمه

در سال‌های اخیر، پژوهش درزمینهٔ مکان‌یابی داخل ساختمان به‌خاطر کاربردهای فراوان در اینترنت اشیا، رباتیک، مدیریت انرژی، خدمات اضطراری و محیط‌های هوشمند، بسیار موردتوجه قرار گرفته است. اما این حوزه با چالش‌های مهمی روبروست که در عمل دقت و کارایی روش‌ها را به‌شدت محدود می‌کند. سامانه موقعیت‌یابی جهانی[1] به طور گسترده برای مکان‌یابی در فضاهای باز استفاده می‌شود؛ ولی تجربیات استفاده از GPS در محیط‌های داخلی و محدود تاکنون رضایت‌بخش نبوده است. برخلاف فضاهای باز، محیط‌های داخلی باتوجه‌به اشکال، اندازه‌های مختلف یا وجود اشیای ثابت و متحرک در آن‌ها (مانند مبلمان و افراد) بسیار پیچیده هستند. این عوامل به طور قابل‌توجهی بر روی سیگنال‌های رادیویی خط دید مستقیم و غیرخطی دید مستقیم اثر می‌گذارند و باعث تضعیف‌های غیرقابل‌پیش‌بینی، پراکندگی، سایه‌افکنی و ایجاد نقاط کور می‌شوند که درمجموع به طور قابل‌توجهی دقت مکان‌یابی داخلی را کاهش می‌دهند. یکی از مهم‌ترین چالش‌ها مسئله چند مسیر است، امواج رادیویی داخل ساختمان از راه‌های مختلف (بازتاب، شکست، نفوذ و پراکندگی) عبور می‌کنند و چند مسیر متفاوت را تجربه می‌کنند که درنهایت در گیرنده با تأخیرها و تلفات مختلف ترکیب می‌شوند، این موضوع باعث مشکل در تخمین موقعیت دقیق کاربر می‌شود[۱].

چالش دوم، نویز محیطی و تغییرات زمانی محیط است. به‌عنوان‌مثال، روشن و خاموش‌شدن تجهیزات الکترونیکی، حرکت افراد، تغییر دما یا رطوبت و تداخل سیگنال‌های رادیویی، موجب می‌شوند که ویژگی‌های سیگنال مثل قدرت سیگنال دریافتی[2] یا سایر ویژگی‌ها به طور ناگهانی تغییر کند. این نوسانات باعث کاهش دقت می‌شوند؛ بنابراین سامانه‌های مکان‌یابی غالباً تحت‌تأثیر نوسانات زمانی، تداخل و شرایط محیطی قرار می‌گیرند[۲] چالش سوم، ناهمگونی دستگاه‌ها[3] است. انواع گوشی‌ها دارای دستگاه‌های گیرنده با سخت‌افزار متفاوت برای دریافت سیگنال، قدرت آنتن متفاوت، تفاوت در حساسیت گیرنده و روش‌های متفاوت در پردازش سیگنال هستند. این تفاوت‌ها منجر می‌شوند که برای یک مکان مشخص، دو دستگاه مختلف مقادیر متفاوت RSSI گزارش دهند. در مرجع[۳] نشان‌داده‌شده است که این ناهمگونی به شکل قابل‌توجهی دقت را کاهش می‌دهد.

همچنین مقاله مروری Yang و همکاران[۴]و همچنین مرجع[۵] نشان می‌دهد که بسیاری از روش‌های مکان‌یابی مبتنی بر اثر انگشت نیاز به جمع‌آوری داده توسط کاربران دارند.

در این مقاله قصد بر این است که از یادگیری عمیق با ساختار خود کدگذار دارای رگولاریزاتورهای غیر هموار برای بهبود موقعیت‌یابی کاربر در سمت شبکه و بدون نیاز به همکاری کاربر بر اساس مشاهدات قدرت سیگنال دریافتی استفاده کنیم. یادگیری عمیق یک فن یادگیری ماشینی است که می‌تواند روابط غیرخطی پیچیده را از داده‌های با ابعاد بالا مدل کند و ویژگی‌های ذاتی داده‌ها را به‌صورت خودکار استخراج کند.

در این مقاله از پایگاه‌داده UJIIndoorLoc به سبب ویژگی‌های خوب زیر استفاده گردیده است:

- شامل ۲۱۰۴۸ رکورد اندازه‌گیری RSSI از Wi-Fi است.
- داده‌ها در ۳ ساختمان و ۴ طبقه دانشگاه Jaume I اسپانیا جمع‌آوری‌شده‌اند.
- توسط ۲۰ کاربر مختلف و با استفاده از ۲۵ گوشی هوشمند ناهمگون ثبت‌شده است.
- شدت سیگنال‌های Wi-Fi بین ۱۰۴ dBm- تا ۰dBm متغیر است.
- به طور متوسط هر شاخصه اثر انگشت شامل ۵۲۰ ویژگی Wi-Fi است که بیشترشان نویزی یا خالی‌اند.

داده‌های این پایگاه‌داده توسط ۲۰ کاربر و ۲۵ گوشی متفاوت جمع‌آوری‌شده‌اند که سبب ناهمگونی دستگاه‌ها می‌شود؛ بنابراین، برای یک موقعیت مکانی یکسان، بسته به نوع دستگاه، مقادیر RSSI می‌توانند متفاوت ثبت شوند. این ناهمگونی به همراه نویز محیطی می‌تواند خطای مکان‌یابی را تا چند متر افزایش دهد، مگر آنکه روش‌های مقاوم در برابر تنوع سخت‌افزار به کار گرفته شوند. بر همین اساس، هدف مقاله حاضر ارائه رویکردی است که با استفاده از رگولاریزاتوری و طراحی معماری شبکه مقاوم، بتواند اثرات عوامل فوق را کاهش داده و دقت مکان‌یابی را در پایگاه‌داده UJIIndoorLoc افزایش دهد.

باتوجه‌به پوشش گسترده Wi-Fi و پشتیبانی از استاندارد IEEE 802. 11 توسط اکثر دستگاه‌های تلفن همراه، بیشتر سامانه‌های موقعیت‌یابی داخل اتاق پیشنهادی مبتنی بر Wi-Fi ازجمله فن‌های مبتنی بر انتشار و اثر انگشت هستند. هدف فن‌های مبتنی بر انتشار مدل‌سازی رابطه بین سیگنال دریافتی و فاصله بدون بررسی وبگاه و چینش ایستگاه‌های پایه است. علی‌رغم سهولت استقرار آن‌ها بدون نیاز به کالیبراسیون قبلی، این فن‌ها با تلفن‌های ناهمگن به‌خوبی کار نمی‌کنند و دقت آن‌ها معمولاً کمتر از فن‌های مبتنی بر اثر انگشت است.

اما استفاده از روش‌های اثر انگشتی باتوجه‌به مدل‌کردن آشفتگی‌ها و پیچیدگی‌های ناشی از پراکندگی‌های در طول مسیر به‌عنوان ویژگی‌های سیگنال دریافتی، برای محیط‌های غیر دید

[1] Global Positioning System (GPS)
[2] Received Signal Strength (RSS)
[3] Device heterogeneity

مستقیم[1] بسیار کارآمد هستند. روش‌های انگشت‌نگاری در سامانه اولیه خود دارای یک اشکال بزرگ هستند و آن نیاز به جدول‌های بزرگ جستجو برای ذخیره داده‌های Wi-Fi است که از نقاط دسترسی مختلف در بسیاری از نقاط مرجع جمع‌آوری می‌شود. همچنین درون‌یابی برای یافتن نقطه دقیق درون آن مشکل است و ممکن است که محیط دچار تغییرات گسترده شود و یا شاید موقع تشکیل جدول جستجو اطلاعات بادقت بالا ذخیره نشده باشند و یا دارای آلودگی و یا انحرافات زیادی باشند.

فن‌های موقعیت‌یابی وای‌فای مبتنی بر اثر انگشت معمولی در دو مرحله کار می‌کنند: مرحله اول، مرحله آفلاین است که در طی آن RSS دریافتی از نقطه دسترسی‌های نصب‌شده در ناحیه موردنظر ثبت می‌شود. سپس، در مرحله آنلاین، اندازه‌گیری‌های RSS از APهای شناسایی‌شده در یک مکان ناشناخته با اثر انگشت‌های ذخیره‌شده مطابقت داده می‌شوند تا بهترین تطابق مکان را ازنظر احتمالی تخمین بزنند. فن‌های مبتنی بر اثر انگشت به دلیل دقت نسبتاً خوب به طور گسترده مورداستفاده قرار می‌گیرند. بااین‌حال، در عمل، به‌کارگیری چنین فن‌هایی به دلیل وجود محوشدگی چند مسیری در سیگنال‌های بی‌سیم که بر دقت موقعیت‌یابی تأثیر می‌گذارد، با چالش‌های عمده‌ای روبرو است؛ بنابراین، سامانه‌های زیادی برای رفع این چالش‌ها در طول سال‌ها پیشنهادشده است. در این مقاله، به دنبال پیشنهاد یک سامانه موقعیت‌یابی داخل اتاق بر اساس اثر انگشت مبتنی بر Wi-Fi هستیم که می‌تواند در حضور ناهمگونی دستگاه و نوسان سیگنال‌های دریافتی در مرحله آفلاین به ردیابی قوی و بادقت بالادست یابد. شبکه‌های عمیق از نوع خود کدگذار برای این مقصود بسیار مناسب هستند. خود کدگذارها نوعی شبکه عصبی هستند که می‌توانند فشرده‌سازی و بازسازی داده‌ها را به شیوه‌ای بدون نظارت یاد بگیرند و هنگامی‌که RSS مورداستفاده جهت آموزش‌دادن در مرحله آفلاین دارای نویز و نوسان باشند، این خود کدگذارها بهترین انتخاب برای موقعیت‌یابی داخل اتاق بر اساس اثر انگشت هستند، زیرا می‌توانند به مزایای زیردست یابند:

- ابعاد و افزونگی داده‌ها را کاهش می‌دهند که می‌تواند کارایی و دقت فرایند مکان‌یابی را بهبود بخشد.
- با یادگیری استخراج مرتبط‌ترین ویژگی‌ها و نادیده‌گرفتن موارد نامربوط، داده‌های بیهوده را حذف می‌کنند که می‌تواند استحکام و پایداری سامانه مکان‌یابی را افزایش دهد.
- با یادگیری ساختار نهفته‌ای که ساختار و الگوهای اساسی داده‌ها را در برمی‌گیرد، به‌خوبی ساختار خود را به داده‌های جدید تعمیم می‌دهند، به‌نحوی که می‌تواند با تغییرات پویا محیط داخل اتاق سازگار شود.

در ادامه، در بخش‌های متفاوت این مقاله به مباحث زیر پرداخته خواهد شد: بخش دوم کارهای مرتبط در زمینه سامانه‌های مکان‌یابی داخلی و کاربردهای خود کدگذارها را بررسی می‌کند. بخش سوم معماری مدل پیشنهادی و ساختار سامانه مکان‌یاب مبتنی بر شبکه یادگیری عمیق با ساختار خود کدگذار دارای رگولاریزاتورهای غیر هموار را توضیح می‌دهد. بخش چهارم مبانی ریاضی و معیارهای ارزیابی بکار گرفته‌شده را تشریح می‌کند. در بخش پنجم با بیان نتایج عددی و شبیه‌سازی‌ها، به صحت سنجی روابط و مدل ارائه‌شده خواهیم پرداخت و درنهایت، بخش ششم مقاله با بیان نتایج و جهت‌های بالقوه برای افزایش دقت سامانه‌های مکان‌یابی مبتنی بر شبکه‌های عصبی به پایان می‌رسد.

۲. پیشینه تحقیق

در ادبیات فناوری مکان‌یابی داخل اتاق بی‌سیم، فن‌ها و سامانه‌های مختلفی پیشنهادشده است. این فن‌ها و سامانه‌ها را می‌توان به دو گروه روش‌های هندسی و روش انگشت‌نگاری یا اثر انگشتی طبقه‌بندی کرد. روش‌های هندسی شامل روش‌های چند لایه‌بندی، سه لایه‌بندی و مثلث‌سازی هستند که می‌توانند برای پارامترهای اندازه‌گیری مختلف مانند زاویه ورود[2]، زمان ورود[3] و مانند آن استفاده شوند. این روش‌ها دقت کافی برای ارائه خدمات در فضای داخل اتاق در حضور سیگنال‌های NLOS و مشکلات چند مسیری را ندارند[۶].

روش دوم روش‌های انگشت‌نگاری هستند. مفهوم انگشت‌نگاری شناسایی مکان‌های فضایی داخلی بر اساس ویژگی‌های قابل‌اندازه‌گیری وابسته به مکان (اثر انگشت مکان) است. مشکل این نوع سامانه‌ها داده‌های با ابعاد بالا است. برای تعیین مکان دقیق شخص یا شیء موردنظر در محیط داخل اتاق، سامانه نیاز به تجزیه‌وتحلیل سیگنال‌های صدها نقطه دسترسی Wi-Fi مجاور دارد. روش‌های سنتی یادگیری ماشینی در برخورد با چنین مجموعه داده‌ای با ابعاد بالا کند هستند. بااین‌حال، سامانه‌های اخیر با استفاده از یادگیری عمیق، یک رویکرد یادگیری ماشینی نسبتاً جدید برای ارائه نمایش جدیدی از داده‌های ورودی، از این داده‌های بزرگ استفاده می‌کنند. ماهیت یادگیری عمیق آن را برای مقابله با حجم عظیمی از داده‌های با ابعاد بالا مناسب می‌کند. به‌غیراز قابلیت استخراج اطلاعات سلسله‌مراتبی از داده‌های ورودی، یادگیری عمیق می‌تواند تخمین موقعیت دقیق را نیز به طور مستقیم ایجاد کند.

استفاده از یادگیری عمیق سبب پیشرفت شگرفی در آموزش معماری‌های شبکه‌های عمیق سامانه‌های مکان‌یابی داخلی شده است. ولی همچنان دقت، قابلیت اطمینان، پایداری و سازگاری در

[1] Non Line Of Side (NLOS)

[2] Angle of Arrival (AoA)

[3] Time of Arrival (ToA)

محیط‌های داخلی به‌عنوان چالش باقی‌مانده است، زیرا محیط‌های داخلی دارای موقعیت پیچیده، انتشار سیگنال NLoS، موانع و نوسان سیگنال هستند؛ بنابراین، دستیابی به‌دقت مکان‌یابی زیاد هنوز موضوعی گشوده است[۷].

مکان‌یابی فضای داخلی با استفاده از اثر انگشت و یادگیری عمیق یک حوزه تحقیقاتی فعال در سال‌های اخیر بوده است. رویکردهای یادگیری ماشین طی سال‌های اخیر، برای غلبه بر این چالش‌ها به طور گسترده مورداستفاده قرار گرفته است. مزیت اصلی رویکردهای یادگیری عمیق توانایی آن‌ها در تصمیم‌گیری مؤثر با استفاده از داده‌های مشاهده‌شده بدون فرمول‌بندی دقیق ریاضی است[۸ و ۹] و [۱۰].

برای مثال، در مرجع[۱۱] یک الگوریتم مکان‌یابی داخلی نیمه‌نظارتی پیشنهاد می‌دهد که خطاهای پیش‌بینی را با مدل‌سازی توزیع‌های متغیر به‌جای فرض گاوسی ثابت کاهش می‌دهد. در این چارچوب با استفاده از معماری ترنسفورمر روی‌دادن‌ها و انتخاب داده‌هایی که عدم قطعیت کمتری دارند به‌عنوان برچسب کاذب، مجموعه آموزشی گسترش می‌یابد. نتایج آزمایش نشان می‌دهد این روش در شرایط کمبود داده عملکرد دقیق‌تر و پایدارتری نسبت به رویکردهای مرسوم دارد.

مرجع[۱۲] چارچوبی سه‌بعدی برای مکان‌یابی در محیط‌هایی با چند ساختمان معرفی می‌کند که در ابتدا داده‌های ناقص RSSI را بر اساس ویژگی‌های محیطی تکرارشونده تکمیل کرده و سپس موقعیت کاربر را در سطح ساختمان، طبقه و مختصات تخمین می‌زند. این ترکیب باعث افزایش دقت، کاهش مصرف انرژی و بهبود مقاومت در برابر نویز در مقایسه با روش‌های قبلی می‌شود. نتایج برای تخمین موقعیت مکانی با استفاده از این روش، خطای مکان‌یابی حدود m ۷/۹۱ را نشان می‌دهد.

مرجع[۱۳] یک رویکرد نوین برای مکان‌یابی داخلی مبتنی بر WiFi معرفی می‌کند که با ترکیب یادگیری انتقالی برای استخراج ویژگی‌های مشترک بین محیط‌ها و یادگیری تقویتی عمیق برای سازگاری پویا با تغییرات محیطی عمل می‌کند. این روش نیاز به جمع‌آوری داده برچسب خورده در هر محیط را کاهش داده و توانایی انطباق مدل در شرایط متغیر را افزایش می‌دهد. نتایج آزمایش‌ها نشان می‌دهد که چارچوب پیشنهادی هم ازنظر دقت و هم پایداری بر روش‌های سنتی و یادگیری ماشین معمولی برتری دارد.

در مرجع[۱۴] یک چارچوب برای مکان‌یابی داخلی مبتنی بر ویژگی‌های WiFi ارائه‌شده است که از ترکیب شبکه‌های عصبی کانولوشنی و خود کدگذار کانولوشنی استفاده می‌کند. در این روش، خود کدگذار کانولوشنی برای کاهش ابعاد و استخراج ویژگی‌های غنی از داده‌های RSSI به کار گرفته می‌شود و سپس شبکه عصبی کانولوشنی موقعیت کاربر را بادقت بالاتر تخمین می‌زند. نتایج نشان می‌دهد که این چارچوب در محیط‌های واقعی دقت بالاتری نسبت به روش‌های سنتی داشته و با اجرای لبه‌ای (Edge-based) توانسته کارایی و زمان پاسخ‌گویی سامانه را بهبود دهد. همچنین میانگین خطای موقعیت‌یابی با پایگاه‌داده UJIIndoorLoc برابر با m ۹/۵ گزارش گردیده است.

البته این نکته را نیز باید در نظر داشت که استفاده از روش‌های اثر انگشت RSSI مبتنی بر یادگیری ماشین می‌تواند پیچیدگی سامانه را افزایش دهد. هنگامی‌که روش‌های انگشت‌نگاری RSSI مبتنی بر یادگیری ماشین در محیط محوشونده چندمسیره استفاده می‌شود، باید از داده‌های بزرگ برای مقابله با محوشدگی چندمسیره و نوسانات سیگنال یا خرابی‌های سخت‌افزاری استفاده شود[۱۵] به طور خلاصه، مکان‌یابی فضای داخل اتاق مبتنی بر یادگیری ماشین با استفاده از اثر انگشت Wi-Fi RSSI یک روش برای مکان‌یابی داخلی است که می‌تواند دقت قابل‌قبولی را در برخی از خدمات مکان‌یابی حتی با سخت‌افزارهای ساده ارائه دهد.

نویسندگان در مرجع[۱۶] از یک خود کدگذار پشته‌ای[1] و به دنبال آن‌یک شبکه کاملاً متصل[2] برای طبقه‌بندی چند ساختمان و چندطبقه استفاده کردند. آن‌ها نشان دادند که رویکردهای قبلی مبتنی بر پردازش سلسله‌مراتبی[۱۷] دارای پیچیدگی بالایی هستند که به انتخاب دقیق ویژگی و یک الگوریتم جداگانه برای هر سطح از کلاس‌بندی (به‌عنوان‌مثال، ساختمان و سپس شناسایی طبقه) نیاز دارند. هدف SAE کاهش ابعاد است که مهم است؛ زیرا اثر انگشت Wi-Fi باید برای همه APهای شناسایی‌شده در یک محیط کامل در دسترس باشد، اما تنها زیرمجموعه‌ای از این APها برای مکان‌های مختلف مشاهده می‌شود (به علت وجود قطعی). این امر به‌خصوص برای محیط‌های با مقیاس بزرگ صادق است. شبکه FC نمایش فشرده را در کلاس مربوطه خود ترسیم می‌کند، جایی که یک کلاس نشان‌دهنده یک برچسب از ترکیب ساختمان طبقه است (به‌عنوان‌مثال طبقه پنجم و ساختمان دوم). کار آن‌ها دقت طبقه‌بندی ۹۲ درصدی را برای مجموعه‌داده مرجع و بسیار مهم UJIIndoorLoc به دست می‌آورد.

کیم در[۱۸] و [۱۹] با الهام از[۱۶] از SAE برای کاهش ابعاد استفاده کردند که به دنبال آن‌یک شبکه FC برای کلاسه‌بندی سلسله‌مراتبی و چند برچسبی استفاده کردند. برای شبکه FC از یک تابع هزینه وزن‌دار استفاده شد. نتایج در مجموعه‌داده UJIIndoorLoc آزمایش‌شده است. مجموعه‌داده دارای ۹۳۳ اتاق مجزا است که به ۹۳۳ گره خروجی برای

[1] Stack Auto Encoder (SAE)

[2] Fully Connected (FC)

طبقه‌بندی چند رده‌بندی‌شده نیاز دارد. بااین‌حال، نویسندگان با راه‌حلی خلاقانه این عدد را به ۱۱۸ کاهش دادند. نتایج ارزیابی‌شده خطای موقعیت‌یابی ۹. ۲۹ متر را گزارش دادند.

برای کاهش اثرات نویز در اثر انگشت RSS، در مرجع[۲۰] استفاده از خود کدگذار حذف نویز پشته‌ای پیشنهادشده است. رویکرد نویسندگان شامل یک استراتژی آموزشی دومرحله‌ای (آموزش بدون نظارت و به دنبال آن آموزش تحت نظارت) بود. برخلاف راه‌حل‌های موقعیت‌یابی مبتنی بر AE که قبلاً مورد بحث قرار گرفت، وانگ در[۲۱] موقعیت‌یابی داخل اتاق را به‌عنوان یک مسئله رگرسیون و نه یک مسئله کلاسه‌بندی، در نظر گرفت. قابل‌توجه‌ترین ویژگی مدل آن‌ها توانایی آن در تولید تخمین‌های موقعیت‌یابی دقیق است حتی زمانی که فاصله زمانی زیادی بین مجموعه‌داده‌های آموزشی و آزمایشی گذشته است (مثلاً داده‌های مورداستفاده برای آموزش شبکه عمیق در زمان‌های دورتری از محیط اخذشده باشند). ارزیابی با استفاده از سه مجموعه‌داده با فواصل زمانی متفاوت که از ۰ تا ۵۲ روز متغیر بود، انجام شد. نتایج تجربی نشان داد که مدل نویسندگان عملکرد قابل‌قبول به دست می‌آورد. بااین‌حال، در فواصل زمانی طولانی، مدل نویسندگان، خطای موقعیت‌یابی را تا ۱۴/۷ درصد نسبت به مدل‌های معروف کلاسه‌بندی نیز کاهش می‌داد.

در منبع[۲۲] نویسندگان یک سامانه مکان‌یابی داخلی برای چند ساختمان چندطبقه مبتنی بر یک سامانه یادگیری عمیق با استفاده از ویژگی اثر انگشت Wi-Fi ارائه داده‌اند و نام آن را CNNLoc گذاشته‌اند. در این مقاله با ترکیب SAE با یک شبکه یک‌بعدی کانولوشنی، CNNLoc ساخته‌شده است که این روش پیشنهادی می‌تواند ویژگی‌های کلیدی را از اثر انگشت‌های تنک Wi-Fi استخراج کند و به نرخ موفقیت بالایی در مکان‌یابی دست یابد. همچنین نویسندگان CNNLoc را بر روی دو مجموعه‌داده منبع‌باز، UJIIndoorLoc و Tampere ارزیابی کرده‌اند که به میزان موفقیت به ترتیب ٪۹۵/۹۲ و ٪۹۴/۱۳ دست‌یافته‌اند.

مقاله تحقیقاتی دیگری[۲۳] بررسی رویکردهای یادگیری عمیق برای موقعیت‌یابی داخلی مبتنی بر Wi-Fi را ارائه می‌دهد. این مقاله چالش‌های مختلفی مانند کمبود داده‌های برچسب‌گذاری شده، پیچیدگی مدل‌های یادگیری عمیق، و نیاز به پردازش بلادرنگ را مورد بحث قرار می‌دهد.

در مطالعه دیگری[۲۴] نویسندگان یک رویکرد مکان‌یابی Wi-Fi با استفاده از شبکه‌های عصبی عمیق پیشنهاد کردند. در سامانه آن‌ها، از یک مدل یادگیری عمیق چهارلایه برای استخراج ویژگی‌ها از داده‌های Wi-Fi RSS استفاده می‌شود. نویسندگان از خود کدگذار حذف نویز پشته‌ای و پس انتشار برای مراحل آموزش شبکه استفاده می‌کنند. در مرحله تعیین موقعیت آنلاین، موقعیت تخمین زده‌شده بر اساس شبکه عصبی عمیق توسط یک جزء مدل مارکوف پنهان پالایش می‌شود. آزمایش‌های آن‌ها نشان می‌دهد که تعداد لایه‌های پنهان و نورون‌ها تأثیر مستقیمی بر دقت مکان‌یابی دارند. افزایش لایه‌ها منجر به نتایج بهتری می‌شود، اما در نقطه‌ای که شبکه عمیق‌تر می‌شود، نتایج شروع یک افت عملکرد را نمایش می‌دهد. نتیجه آن‌ها نشان می‌دهد که هنگام استفاده از سه‌لایه پنهان با ۲۰۰ نورون برای هر لایه، مدل به بهترین دقت دست می‌یابد.

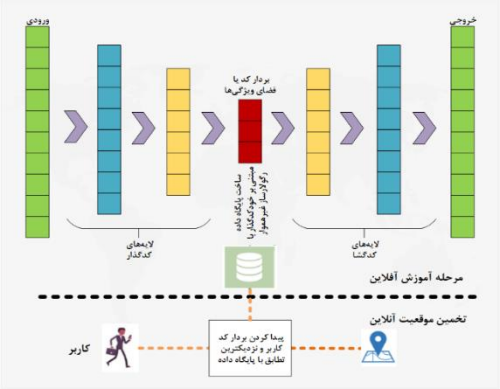
۳. مدل سامانه پیشنهادی

مدل سامانه مکان‌یاب داخلی پیشنهادی در دو مرحله آموزش آفلاین و تخمین موقعیت آنلاین عملیات مکان‌یابی را انجام می‌دهد. در مرحله آموزش آفلاین، داده‌های RSS را از چندین AP در مکان‌های مختلف ساختمان جمع‌آوری می‌شود و سپس از یک شبکه یادگیری عمیق با ساختار خود کدگذار دارای رگولاریزاتورهای غیر هموار برای آموزش یک خود کدگذار با فن‌های رگولاریزاتوری غیر هموار برای یادگیری نمایش داده‌های RSS ابعاد پایین استفاده می‌کنیم. سپس یک پایگاه‌داده اثر انگشت می‌سازیم که نگاشت بین نمایش آموخته‌شده و مکان مربوطه را ذخیره می‌کند.

در مرحله تخمین موقعیت آنلاین، داده‌های RSS را از چندین AP در یک مکان ناشناخته اندازه‌گیری می‌کنیم. سپس داده‌های RSS را به خود کدگذار آموزش‌دیده می‌دهیم تا نمایش کم‌بعد آن را به دست آوریم. سپس این نمایش را با پایگاه‌داده اثر انگشت با استفاده از فاصله اقلیدسی مقایسه می‌کنیم و نزدیک‌ترین تطابق را پیدا می‌کنیم و درنتیجه مکان مرتبط با این داده به‌عنوان مکان تخمینی ارائه می‌شود. اما به دلیل این‌که معمولاً اثر انگشت وای‌فای اخذشده نویزی است و بازمان، محیط و ویژگی‌های دستگاه در نوسان است؛ بنابراین، استفاده از خود کدگذار برای کاهش نویز و گرفتن اطلاعات ارزشمند به‌عنوان اثر انگشت، یک فن رایج در انگشت‌نگاری Wi-Fi است. همان‌طور که قبلاً توضیح داده شد، خود کدگذار نوعی شبکه عصبی است که یاد می‌گیرد ورودی خود را از یک نمایش با ابعاد پایین‌تر بازسازی کند و از دو بخش تشکیل‌شده است: یک کدگذار که ورودی را به یک کد پنهان نگاشت می‌کند و یک کدگشا که ورودی را از کد پنهان بازسازی می‌کند. کد پنهان را می‌توان به‌عنوان یک نسخه فشرده‌شده و از افزونه‌های بی‌محتوای ورودی حذف‌شده مشاهده کرد که مرتبط‌ترین ویژگی‌ها را برای یک کار خاص حفظ می‌کند.

به‌طورکلی در سامانه مکان‌یابی پیشنهادی وظیفه خود کدگذار استخراج ویژگی‌های اساسی از سیگنال‌های خام وای‌فای است، به‌طوری که خروجی لایه پنهان یا کدگذار دارای ابعاد پایین و با نویز کمتر باشد. کدگذار می‌تواند یاد بگیرد که نویز و

تداخل سیگنال‌ها را فیلتر کند و کدگشا می‌تواند اطمینان حاصل کند که کد پنهان می‌تواند به سیگنال‌های اصلی بازگردد. سپس این کد پنهان به‌عنوان اثر انگشت برای موقعیت‌یابی داخل اتاق سامانه پیشنهادی استفاده می‌گردد. شبکه خود کدگذار طراحی‌شده در این مقاله دارای ورودی با اندازه ۵۲۰ است که وظیفه دارد الگوهای نهفته در داده‌ها را استخراج و بازسازی کند.



شکل (۱). ساختار شبکه خود کدگذار ارائه‌شده با رگولاریزاتورهای غیرهموار

این شبکه شامل دولایه کدگذار و دولایه کدگشا است، به‌طوری که در مرحله کدگذاری ابتدا داده‌ها از بعد ۵۲۰ به ۳۰۰ ویژگی کاهش‌یافته و سپس در لایه دوم به ۱۵۰ ویژگی فشرده می‌شوند. این فشرده‌سازی تدریجی باعث می‌شود که شبکه بتواند نمایش بهینه‌تری از داده‌ها در فضای کم‌بعد به دست آورد. در فرایند آموزش از الگوریتم بهینه‌سازی Adam برای به‌روزرسانی وزن‌ها استفاده‌شده و تابع فعال‌ساز **Relu** انتخاب گردیده است تا هم سرعت همگرایی افزایش یابد و هم ویژگی‌های غیرخطی داده‌ها بهتر استخراج شوند. در لایه نهایی کدگشا از تابع فعال‌ساز Sigmoid استفاده‌شده است تا بازسازی داده‌ها در محدوده‌ای نرمال و قابل‌تفسیر قرار گیرد.

برای ارزیابی عملکرد، داده‌ها به دو بخش آموزش و آزمایش تقسیم شدند؛ به‌طوری که ۸۰ درصد نمونه‌ها برای آموزش شبکه و ۲۰ درصد باقی‌مانده برای آزمون مدل مورداستفاده قرار گرفتند. این تقسیم‌بندی باعث می‌شود مدل علاوه بر یادگیری مؤثر، توانایی تعمیم‌پذیری خود را نیز نشان دهد. در بخش کدگشایی، دولایه متناظر با کدگذار طراحی‌شده‌اند تا ویژگی‌های فشرده‌شده مجدداً بازسازی شوند. بدین ترتیب، شبکه خود کدگذار قادر خواهد بود با فشرده‌سازی داده‌های ورودی و بازسازی آن‌ها، هم ویژگی‌های کلیدی را استخراج کند و هم امکان استفاده از آن‌ها در کاربردهایی همچون کاهش ابعاد، تجزیه‌وتحلیل داده و طبقه‌بندی فراهم کند.

۳-۱. استفاده از فن رگولاریزاتوری غیر هموار جهت مقابله با مشکل برازش بیش از حد در خود کدگذارهای عمیق

خود کدگذارهای عمیق نیازمند بهره‌گیری از روش‌هایی کارآمد جهت جلوگیری از بیش برازش و نیز پرهیز از یادگیری نمایش‌های سطحی و غیرکاربردی هستند. بروز بیش برازش، توانایی تعمیم مدل به داده‌های نادیده را به‌شدت تضعیف کرده و از کارآمدی آن در محیط‌های واقعی می‌کاهد. هرچند هدف اصلی در فرایند آموزش این مدل‌ها بازسازی ورودی در قالب خروجی است، اما در صورت برخورداری از ظرفیت بالا، مدل به‌جای استخراج ویژگی‌های بنیادی و معنادار، صرفاً داده‌ها را حفظ می‌کند. برای مقابله با این پدیده، به‌کارگیری روش‌های رگولاریزاسیون با افزودن نویز کنترل‌شده یا اعمال پراکندگی در بازنمایی‌های نهفته، به‌عنوان راهکاری اثربخش مطرح می‌شود. این رویکرد علاوه بر محدودسازی ظرفیت مدل، بهبود تعمیم‌پذیری و ارتقای پایداری عملکرد خود کدگذارهای عمیق را نیز تضمین می‌نماید[۲۵].

رگولاریزاتوری برای خود کدگذارهای عمیق به معنای افزودن برخی محدودیت‌ها یا جریمه‌ها به تابع هدف مدل است که معمولاً همان خطای بازسازی بین ورودی اصلی و خروجی است. انواع مختلفی از رگولاریزاتوری برای خود کدگذارهای عمیق وجود دارد[۲۶] مانند:

- رگولاریزاتور تنک: به این معنی است که مدل را به استفاده از کسر کوچکی از واحدهای نمایش و صفر کردن بیشتر آن‌ها وادار می‌نماید. این می‌تواند نمایش را فشرده‌تر و انتخابی‌تر کند و افزونگی را کاهش دهد.
- رگولاریزاتور حذف نویز: که به معنای افزودن مقداری نویز یا آشفتگی به ورودی، و مجبور کردن مدل به بازسازی ورودی تمیز یا اصلی است. این امر می‌تواند مدل را در برابر نویز و تغییرات مقاوم‌تر کند و باعث می‌شود که مدل ویژگی‌های ضروری بیشتری را بیاموزد.
- رگولاریزاتور انقباضی: یعنی جریمه‌کردن مدل به دلیل حساس‌بودن به تغییرات کوچک در ورودی. این امر می‌تواند مدل را نسبت به اغتشاشات اندک مقاوم‌تر کند و ویژگی‌های پایدارتری را بیاموزد.
- رگولاریزاتور متغیر: که به معنای وفق‌دادن یک توزیع احتمالی مانند گاوسی یا برنولی بر روی نمایش داده‌ها است و باعث می‌شود که مدل یک فضای بازنمایی هموار و پیوسته را بیاموزد و نمونه‌برداری یا درون‌یابی را فعال کند.
- رگولاریزاتورهای غیر هموار، از فن‌های رگولاریزاتوری هستند که از توابع غیر هموار برای جریمه‌کردن پیچیدگی یک مدل استفاده می‌کنند[۲۷] و [۲۸] توابع غیر هموار

آن‌هایی هستند که در همه نقاط قابل مشتق‌گیری نیستند، مانند تابع قدرمطلق یا نرم $\ell 1$. رگولاریزاتورهای غیر هموار می‌تواند باعث ایجاد تنکی یا مقاومت نسبت به مقادیر ثبت‌شده غیردقیق در پارامترها یا ویژگی‌های مدل شوند که این امر به‌خودی‌خود می‌تواند تفسیرپذیری و تعمیم مدل را بهبود بخشد[۲۸].

رگولاریزاتورهای غیر هموار در خود کدگذارهای عمیق مجموعه‌ای از مزایای عملکردی و ساختاری را فراهم می‌آورند. این رگولاریزاتورها امکان اعمال تنکی بر واحدهای پنهان و وزن‌های مدل را فراهم می‌کنند، به‌گونه‌ای که تنها بخشی محدود از آن‌ها فعال یا غیرصفر باقی می‌ماند؛ این ویژگی ضمن کاهش پیچیدگی و افزونگی شبکه، قابلیت تفسیر و انتخاب ویژگی‌های مؤثر را بهبود می‌بخشد[۲۸] علاوه بر این، با فیلترکردن نویز و اختلالات ورودی، مقاومت خود کدگذار در برابر تغییرات محیطی و اغتشاشات داده‌ای افزایش‌یافته و درنتیجه، کیفیت و ثبات فرایند بازسازی بهبود می‌یابد[۲۸] همچنین، این رگولاریزاتورها با محدودسازی بیش برازش یا کم برازش، تعمیم‌پذیری مدل را تقویت نموده و کارایی خود کدگذار را در مواجهه با مجموعه‌داده‌ها و وظایف متنوع به نحو قابل‌توجهی ارتقا می‌دهند[۲۷].

به‌طورکلی، استفاده از خود کدگذارها همراه با رگولاریزاسیون‌های کلاسیک نظیر $\ell 1$ و $\ell 2$ در ادبیات یادگیری ماشین به طور گسترده بررسی و به‌کارگرفته‌شده است. بااین‌حال، تا جایی که جستجوهای انجام‌شده نشان می‌دهد، بهره‌گیری از خود کدگذارهای عمیق مجهز به رگولاریزاسیون‌های غیر هموار در حوزه‌ی مکان‌یابی درون ساختمانی مبتنی بر اثر انگشت Wi-Fi تاکنون گزارش نشده است؛ هرچند چنین رویکردی، باتوجه‌به مزایای بالقوه‌ای که در بخش‌های پیشین مورد بحث قرار گرفت، می‌تواند نویدبخش بهبود چشمگیر در تعمیم‌پذیری و استحکام سامانه باشد. باید توجه داشت که گنجاندن رگولاریزاسیون غیر هموار، فرایند بهینه‌سازی را به طور ذاتی پیچیده‌تر می‌سازد، چراکه این دسته از توابع در همه نقاط مشتق‌پذیر نبوده و نیازمند الگوریتم‌های بهینه‌سازی پیشرفته‌تری هستند. افزون بر این، رگولاریزاسیون‌های غیر هموار مستلزم تنظیم و انتخاب دقیق فرا پارامترها هستند؛ فرا پارامترهایی که برخلاف پارامترهای درونی مدل همچون وزن‌ها و بایاس‌ها در جریان یادگیری به‌روز نمی‌شوند، بلکه پیش از آغاز فرایند آموزش تعیین گردیده و نقشی تعیین‌کننده در عملکرد نهایی مدل ایفا می‌کنند.

پیش از ارائه جزئیات روش پیشنهادی برای آموزش خود کدگذارهای عمیق، مروری بر فن‌های رگولاریزاسیون در این شبکه‌ها ارائه می‌شود. رگولاریزاتورهای هموار و غیر هموار ازجمله روش‌های متداول هستند که با افزودن عبارتی جریمه‌ای به تابع ضرر مبتنی بر بزرگی وزن‌ها عمل می‌کنند. رگولاریزاتور $\ell 1$ با جریمه‌کردن قدرمطلق پارامترهای مدل، پارامترهای بزرگ یا غیرصفر را تنبیه می‌کند؛ این فرایند منجر به صفرشدن برخی پارامترها و حذف مؤثر آن‌ها از مدل می‌شود و بدین ترتیب، مدل تنک و تفسیرپذیر شکل می‌گیرد که قابلیت انتخاب ویژگی‌های مهم را بهبود می‌بخشد.

در مقابل، رگولاریزاتور $\ell 2$ مجذور پارامترها را به‌عنوان جریمه اضافه می‌کند. این رویکرد اگرچه پارامترهای بزرگ را کاهش می‌دهد، اما آن‌ها را به طور کامل حذف نمی‌کند و درنتیجه، مدلی پایدار و مقاوم در برابر نویز ایجاد می‌شود. بهره‌گیری از این رگولاریزاتورها در ترکیب با خود کدگذارهای عمیق، علاوه بر کنترل پیچیدگی مدل، موجب ارتقای توان تعمیم و بهبود کیفیت بازسازی داده‌ها می‌شود.

انتخاب بهینه فن رگولاریزاسیون برای مکان‌یابی درون ساختمانی مبتنی بر اثر انگشت Wi-Fi تابعی از چندین عامل کلیدی است و پاسخ قطعی برای آن وجود ندارد. یکی از این عوامل، اندازه، کیفیت و پیچیدگی مجموعه‌داده‌ها است. در مجموعه‌داده‌های بزرگ و متنوع، نیاز به اعمال رگولاریزاسیون شدید کمتر است، زیرا مدل قادر به یادگیری الگوها از نمونه‌های متعدد است. در مقابل، مجموعه‌داده‌های کوچک یا دارای آشفتگی بالا نیازمند رگولاریزاسیون بیشتر هستند تا از بروز بیش برازش جلوگیری شود.

عامل مهم دیگر، تعداد و میزان همبستگی بین ویژگی‌های اثر انگشت Wi-Fi است. درصورتی‌که تعداد زیادی ویژگی در دسترس باشد که ارتباط محدودی با متغیر هدف‌دارند، اعمال رگولاریزاسیون بیشتر برای کاهش ابعاد و پیچیدگی مدل ضروری است. در مقابل، زمانی که تعداد ویژگی‌ها اندک اما بسیار آموزنده و پیش‌بینی‌کننده باشد، رگولاریزاسیون شدید می‌تواند سهم این ویژگی‌ها را کاهش دهد و کارایی مدل را تضعیف کند، بنابراین تنظیم ملایم‌تر آن‌ها مطلوب است.

عامل سوم به مصالحه میان بایاس و واریانس مربوط می‌شود. بایاس نشان‌دهنده فاصله میان پیش‌بینی موردانتظار مدل و مقادیر واقعی داده‌هاست، درحالی‌که واریانس بیانگر تغییرپذیری پیش‌بینی مدل در نمونه‌های مختلف است. مدل‌های پیچیده، مانند خود کدگذارهای عمیق با لایه‌ها و واحدهای زیاد، معمولاً بایاس پایین اما واریانس بالایی دارند، زیرا قادر به تطبیق دقیق داده‌ها و ثبت الگوهای زیرین هستند، ولی ممکن است نویز و جزئیات غیرقابل‌تعمیم را نیز یاد بگیرند. در مقابل، مدل‌های ساده‌تر با ظرفیت محدود، واریانس کمتری دارند و از بیش برازش جلوگیری می‌کنند، اما بایاس بالاتری دارند و ممکن است برخی ویژگی‌ها یا روابط مهم داده‌ها را از دست بدهند[۲۹] و[۳۰].

۴. بیان ریاضی مسئله

در این بخش، ما یک بیان ریاضی برای سامانه مکان‌یاب داخلی مبتنی بر موقعیت‌یابی تک کاربر در شبکه WiFi مبتنی بر شبکه یادگیری عمیق با ساختار خود کدگذار دارای رگولاریزاتورهای غیر هموار بر اساس مقادیر RSSI دریافتی از Wi-Fi ارائه می‌کنیم.

توان سیگنال حقیقی دریافتی توسط گیرنده RSS نامیده می‌شود که معمولاً برحسب دسی‌بل میلی‌وات[1] یا میلی‌وات (mW) بیان می‌شود. با استفاده از RSS، فاصله بین سامانه‌های فرستنده و گیرنده را می‌توان از اختلاف توان سیگنال ارسالی و دریافتی به دست آورد، اما رابطه فاصله و RSS، به‌خصوص در محیط‌های داخلی به دلیل چندمسیره بودن مسیر سیگنال، لزوماً خطی نیست. شبکه‌های بی‌سیم مبتنی بر RSS دو مدل انتشار رایج دارند: اول، مدل‌های فضای آزاد[2] و دوم، مدل‌های لگاریتمی - نمایی[3]. مدل‌های فضای آزاد عموماً بیان ساده‌ای دارند؛ ولی موانع بین گیرنده‌ها و فرستنده‌ها را در مدل خود در نظر نمی‌گیرند. ازسوی‌دیگر، مدل‌های لگاریتمی - نمایی کاربردی‌تر هستند و برای مکان‌یابی داخلی و خارجی استفاده می‌شوند، زیرا شرایط محیطی متفاوت را در نظر می‌گیرند[۳۱]مدل انتشار فضای آزاد به‌صورت زیر تعریف می‌شود[۳۲].

$$P_r = 10Log\left(\frac{P_t G_t G_r \lambda^2}{(4\pi)^2 d^2 L}\right), \qquad (۱)$$

در معادله بالا، P_r توان دریافتی، P_tتوان ارسالی، G_t بهره آنتن فرستنده، G_r بهره آنتن گیرنده، λ طول‌موج سیگنال، d فاصله بین فرستنده و گیرنده، و L افت سیگنال ناشی از انتشار در کانال محوشونده است. در حالت دوم، مدل انتشار log-normal به‌صورت زیر تعریف می‌شود[۳۱] :

$$P_r=P_t+G_t+G_r-L_p(d_0)-10Log(\frac{d}{d_0})^{\alpha}+C_a \qquad (۲)$$

در معادله (۲)، α نمای افت توان مسیر انتشار سیگنال است که به آن محیط انتشار خاص بستگی دارد، $L_p(d_0)$ افت مسیر در فاصله مرجع d_0 است و C_a یک عدد تصادفی معمولی توزیع‌شده با میانگین صفر و واریانس σ^2 است که پدیده سایه‌افکنی و سایر منابع عدم قطعیت در مسیر انتشار سیگنال را در نظر می‌گیرد[۳۱] همچنین، RSSI را می‌توان به‌صورت زیر محاسبه کرد:

$$RSSI = 10\log_{10}^{(\frac{P_{received}}{P_{reference}})}, \qquad (۳)$$

که در آن $P_{received}$ قدرت سیگنال دریافتی را برحسب میلی‌وات و $P_{reference}$ نشان‌دهنده توان مرجع است که یک میلی‌وات است. اندازه‌گیری RSS فقط به آشکارسازهای توان معمول نیاز دارد که در فناوری رایج مانند شبکه محلی بیسیم[4]، فناوری باند وسیع[5]، Zigbee، بلوتوث و دستگاه‌های مادون‌قرمز رایج هستند. سامانه‌های RSS نیازی به همگام‌سازی زمان ندارند. علاوه بر این، در این روش، انجام فرایند همگام‌سازی بین دستگاه‌ها موردنیاز نیست[۳۳].

خود کدگذار یک شبکه عصبی است که آموزش‌داده‌شده است تا ورودی خود را در خروجی خود تکرار کند. آموزش خود کدگذار بدون نظارت است به این معنا که به داده‌های برچسب‌گذاری شده نیاز نیست. فرایند آموزش همچنان بر اساس بهینه‌سازی تابع هزینه است. تابع هزینه خطای بین ورودی x و بازسازی آن در خروجی را اندازه‌گیری می‌کند. خود کدگذارها از فن‌های مهندسی سنتی در دقت و عملکرد در بسیاری از برنامه‌ها، ازجمله تشخیص ناهنجاری، تولید متن، تولید تصویر، حذف نویز تصویر و ارتباطات دیجیتال، پیشی گرفته‌اند.

خود کدگذار از دو شبکه کوچک‌تر تشکیل‌شده است: شبکه کدگذار و شبکه کدگشا. در طول آموزش، خود کدگذار مجموعه‌ای از ویژگی‌ها را که به‌عنوان نمایش پنهان شناخته می‌شود، از داده‌های ورودی یاد می‌گیرد. سپس این نمایش پنهان (مانند نحوه نوشتن هر عدد) می‌تواند برای کارهای مختلف (به‌عنوان‌مثال استخراج ویژگی که می‌تواند سپس برای طبقه‌بندی یا خوشه‌بندی استفاده شود) یا برای درک ویژگی‌های اساسی یک مجموعه‌داده بسیار مفید باشد. درعین‌حال، کدگشا آموزش می‌بیند تا داده‌ها را بر اساس این ویژگی‌ها بازسازی کند. خود کدگذار می‌تواند برای پیش‌بینی ورودی‌هایی که قبلاً دیده نشده‌اند اعمال شود. خود کدگذارها بسیار قابل‌تعمیم هستند و می‌توانند در انواع داده‌های مختلف ازجمله تصاویر، سری‌های زمانی و متن استفاده شوند.

در واقعیت، خود کدگذار یک شبکه عصبی بدون نظارت است که یاد می‌گیرد چگونه داده‌ها را به طور مؤثر فشرده کند. خود کدگذار همچنین یاد می‌گیرد که چگونه داده‌ها را از نمایش فشرده بازسازی کند به‌طوری که تفاوت بین داده‌های اصلی و داده‌های بازسازی‌شده حداقل باشد.

به‌طورکلی، بخش کدگذار را می‌توان به‌عنوان تابع $g(.)$ به‌صورت زیر نوشت که $\mathbf{h}_i$ یا فضای ویژگی، خروجی آن است و به‌صورت زیر می‌تواند نوشته شود:

$$\mathbf{h}_i = g\left(\mathbf{x}_i\right); \qquad (۴)$$

[1] dBm
[2] Freespace models
[3] Log-normal models
[4] Wireless Local-Area Network (WLAN)
[5] Ultra Wide Band (UWB)

بخش بعدی یک شبکه خود کدگذار، کدگشا است که درواقع خروجی شبکه خود کدگذار است و با $\mathbf{x}_i$ نشان خواهیم داد را می‌توان به‌عنوان تابع از ویژگی‌های پنهان به‌صورت $f(.)$ نوشت.

$$\mathbf{x}_i = f\left(\mathbf{h}_i\right) = f\left(g\left(\mathbf{x}_i\right)\right); \qquad (۵)$$

در ادامه برای یافتن رابطه ریاضی آموزش شبکه خود کدگذار $\mathbf{x}_i$ را نشان‌دهنده داده‌های ورودی (مقادیر RSSI) در نظر می‌گیریم. در مسئله‌آموزش یک خود کدگذار، هدف به‌حداقل‌رساندن تابع هزینه با به‌دست‌آوردن پارامترهای وزن بهینه مدل شبکه خود کدگذار است که می‌تواند به‌صورت زیر فرمول‌نویسی شود:

$$\underset{\boldsymbol{\theta}}{arg\,min}\ \mathrm{L}\left(f\left(g\left(\mathbf{x}_i\right),\mathrm{P}\right),\mathbf{x}_i\right). \qquad (۶)$$

که در عبارت بالا، f نشان‌دهنده تابع شبکه خود کدگذار است، L نشان‌دهنده تابع هزینه مدل و P نشان‌دهنده پارامترهای مدل شبکه خود کدگذار است. با آموزش مدل شبکه خود کدگذار برای به‌حداقل‌رساندن تابع هزینه، می‌توانیم پارامترهای بهینه را تعیین کنیم که برای پیش‌بینی مکان داخلی در مرحله آنلاین با استفاده از مقادیر RSSI تازه جمع‌آوری‌شده استفاده می‌شود.

رگولاریزاسیون $\ell 1$ و $\ell 2$، فن‌هایی هستند که معمولاً در یادگیری ماشین و مدل‌سازی آماری برای جلوگیری از بیش برازش و بهبود قابلیت تعمیم یک مدل استفاده می‌شوند. این فن‌ها، یک عبارت جریمه به تابع زیان اضافه می‌کنند و مدل را به داشتن مقادیر پارامتر کوچک‌تر تشویق می‌کنند.

به عبارتی رگولاریزاسیون نُرم $\ell 1$، در خود کدگذارها به معنای اعمال تنکی در مدل شبکه خود کدگذار یا انتخاب ویژگی‌های مهم است. این روش، قدرمطلق بزرگی ضرایب را به‌عنوان یک عبارت جریمه به تابع هزینه مدل (L) اضافه می‌کند. این عبارت جریمه می‌تواند برخی از ضرایب را به صفر کاهش دهد که به انتخاب فقط ویژگی‌های مهم و نادیده‌گرفتن ویژگی‌های کم‌اهمیت‌تر کمک می‌کند.

برای اعمال رگولاریزاسیون $\ell 1$ به شبکه خود کدگذار نیاز هست که عبارت زیر را حل نماییم:

$$\underset{f,g}{arg\,min}\ \mathrm{E}\left[\Delta\left(\mathbf{x}_i, f\left(g\left(\mathbf{x}_i\right)\right)\right)\right] + \lambda\sum_i |\,\boldsymbol{\theta}_i\,|. \qquad (۷)$$

که $\boldsymbol{\theta}_i$ پارامترهای توابع $f(.)$ و $g(.)$ یا به عبارتی در توابع شبکه‌های عصبی، پارامترهای وزن هستند و عبارت λ فرا پارامتری است که بیانگر ضریب رگولاریزاسیون یا بزرگی و شدت رگولاریزاسیون نُرم $\ell 1$ است که مقداری اسکالر و مثبت به خود می‌گیرد. Δ شاخص اندازه‌گیری تفاوت ورودی و خروجی است. همچنین عملگر E مقدار امید ریاضی در میان تمام مشاهدات را محاسبه می‌نماید.

روش دیگر برای اعمال رگولاریزاسیون به تابع شبکه خود کدگذار، افزودن یک عبارت رگوله‌سازی نُرم $\ell 2$ به تابع هزینه شبکه خود کدگذار است. این روش، مجذور بزرگی ضرایب را به‌عنوان یک عبارت جریمه به تابع هزینه مدل (L) اضافه می‌کند. برخلاف رگولاریزاسیون $\ell 1$، رگولاریزاسیون $\ell 2$، ضرایب را مجبور به دقیقاً صفر بودن نمی‌کند، بلکه آن‌ها را به داشتن مقدار کوچک تشویق می‌کند. برای اعمال رگولاریزاسیون $\ell 2$ به شبکه خود کدگذار نیاز هست که عبارت زیر را حل نماییم:

$$\underset{f,g}{arg\,min}\ \mathrm{E}\left[\Delta\left(\mathbf{x}_i, f\left(g\left(\mathbf{x}_i\right)\right)\right)\right] + \beta\sum_i \boldsymbol{\theta}_i^2. \qquad (۸)$$

عبارت β فرا پارامتری است که بیانگر ضریب رگولاریزاسیون یا بزرگی و شدت رگولاریزاسیون نُرم $\ell 2$ است که مقداری اسکالر و مثبت به خود می‌گیرد. در مورد رگوله‌سازی نُرم $\ell 2$، این عبارت معمولاً به‌راحتی قابل‌پیاده‌سازی است؛ زیرا مشتق باتوجه‌به پارامترها به‌راحتی قابل‌محاسبه است، اما در مورد رگوله‌سازی نُرم $\ell 1$ این عبارت مسئله بهینه‌سازی را چالش‌برانگیزتر کند، زیرا توابع غیر هموار در همه‌جا مشتق‌پذیر نیستند. استفاده از این فن‌ها به نمایش ویژگی پنهان، تنکی اضافه می‌کند.

به‌طورکلی می‌توان گفت که تأثیر رگولاریزاسیون $\ell 2$ کاهش مقادیر بزرگ در ماتریس وزن شبکه است درحالی‌که رگولاریزاسیون $\ell 1$ ماتریس وزن شبکه را با صفر کردن تعداد زیادی از مقادیر وزنی تُنک می‌کند.

در هنگام پیاده‌سازی انواع متفاوت رگولاریزاسیون‌ها در TensorFlow/Keras، رگولاتورها می‌توانند روی هسته[1]، بایاس[2] یا نحوه فعال‌بودن خروجی لایه اعمال شوند. در رگولاریزاتور هسته جریمه به ماتریس وزن‌های اصلی لایه اضافه می‌شود. رگولاریزاتور بایاس همان مقدار ثابتی است که به خروجی هر نورون اضافه می‌شود و به طور پیش‌فرض تأثیر زیادی در بیش برازش ندارد، اما گاهی در مدل‌های خیلی پیچیده یا خاص، کنترل‌کردن بایاس هم اهمیت پیدا می‌کند. در رگولاریزاسیون روی فعالیت لایه، منظور خروجی نورون‌ها بعد از اعمال وزن، بایاس و تابع فعال‌ساز است. در این حالت درواقع از فعال‌شدن بیش از حد نورون‌ها جلوگیری می‌شود. این رفتار باعث می‌شود که خروجی نورون‌ها در محدوده معقول باقی بمانند و شبکه رفتار پایداری داشته باشد.

تعریف رگولاریزاتورها، معمولاً هنگام تعریف لایه‌ها مثل

[1] Kernel
[2] Bias

Dense، Conv1D، Conv2D یـا Conv3D انجـام می‌شـود و از طریـق آرگومان‌هـای kernel_regularizer، bias_regularizer یـا activity_regularizer پیاده‌سازی می‌گردد. تمام این رگلاتورها در کتابخانه keras.regularizers قابل فراخوانی هسـتند و بـه کمـک متدهای get_config و from_config می‌توان پیکربندی آن‌هـا را ذخیره یا بازسازی کرد.

درنهایت، در این مقاله برای ارزیابی عملکرد سامانه مکان‌یاب داخلی پیشنهادی، از عبارت ریشه میانگین مربعات خطا[1] استفاده خواهیم کرد. مقدار این عبـارت کـه خروجـی شـبکه را محاسـبه می‌کند به‌صورت زیر قابل‌محاسبه است:

$$\mathrm{RMSE} = \sqrt{\frac{1}{N}\sum_{i=1}^{N}\left[(\hat{x}_i - x_i)^2 + (\hat{y}_i - y_i)^2\right]} = \sqrt{\mathrm{RMSE}_x + \mathrm{RMSE}_y}. \quad (۹)$$

RMSE، نشان‌دهنده خطای بین مکان‌های تخمین زده‌شده و واقعی سامانه مکان‌یاب داخلی مبتنی بر شبکه یادگیری عمیق بـا ساختار خود کدگذار دارای رگولاریزاتورهای غیر هموار است.

۵. نتایج عددی و شبیه‌سازی

در این بخش، مـا بـه ارزیـابی عملکـرد سـامانه موقعیت‌یـاب پیشنهادی، مبتنی بر شـبکه یـادگیری عمیـق بـا سـاختار خـود کدگذار دارای رگولاریزاتورهای غیـر همـوار خـواهیم پرداخـت و میزان بهبود سامانه موقعیت‌یـابی در حالـت بـدون اعمـال انـواع رگولاریزاسیون و اعمـال رگولاریزاسـیون هـای متفـاوت بررسـی خواهیم نمود.

شبکه خود کدگذار دارای رگولاریزاتورهای غیر هموار بر بستر TensorFlow [۳۴] پیاده‌سازی گردیده اسـت. سـایر پارامترهـا و مقادیر استفاده‌شده برای اجرای پیاده‌سازی سـامانه موقعیت‌یـابی مبتنی بر شبکه یادگیری عمیق بـا سـاختار خـود کدگـذار دارای رگولاریزاتورهای غیر هموار در جدول شماره (۱) خلاصه گردیـده است. همچنین، سخت‌افزار مورداستفاده برای پردازش داده‌هـا در این مطالعه، یک رایانه شخصی با مشخصـات: پردازنـده Core i۵، ۱۶ گیگابایت رم، ۵۱۲ گیگابایت حافظـه SSD و کـارت گرافیـک NVIDIA GTX 1060 باقابلیـت محاسـباتی ۶. ۱، ۶ گیگابایـت حافظه اختصاصی و ۱۴ گیگابایت حافظه مشترک است. برای این امر، روش خود را روی مجموعـه‌داده عمـومی ارزیـابی مـی‌کنیم: UJI-IndoorLoc [۳۵].

گرچه مقالات زیادی در مقالات علمی وجود دارد که سعی در حل مشکل مکان‌یابی داخلی با استفاده از یک روش مبتنی بر اثر انگشت WLAN دارند، اما هنوز یـک نقـص مهـم در ایـن زمینـه وجود دارد که فقدان یک پایگاه‌داده مشترک برای اهداف مقایسه است؛

جدول ۱: مقادیر و نوع پارامترهای استفاده‌شده در شبیه‌سازی

تعریف	نماد
اندازه ورودی	۵۲۰
اندازه خروجی	۲
الگوریتم بهینه‌سازی	Adam
تابع فعال‌ساز شبکه کدگذار	Relu
تابع فعال‌ساز لایه آخر شبکه کدگشا	Sigmoid
تابع هزینه	MSE
درصد نمونه‌های آموزشی	۸۰ درصد
درصد نمونه‌های آزمایشی	۲۰درصد
تعداد لایه‌های کدگذار	۲
تعداد لایه‌های کدگشا	۲
تعداد بعد لایه اول کدگذار (ویژگی‌های استخراجی)	۳۰۰
تعداد بعد لایه دوم کدگذار (ویژگی‌های استخراجی)	۱۵۰

بنابراین، پایگاه‌داده UJIIndoorLoc برای غلبه بر این شـکاف ارائه‌شده است. باتوجه‌به وجود استانداردهای بالا، ایـن پایگـاه‌داده به‌عنوان مرجع برای مقایسه روش‌های مختلف مکان‌یـابی داخلـی مبتنی بر اثر انگشت WiFi تبدیل‌شده است.

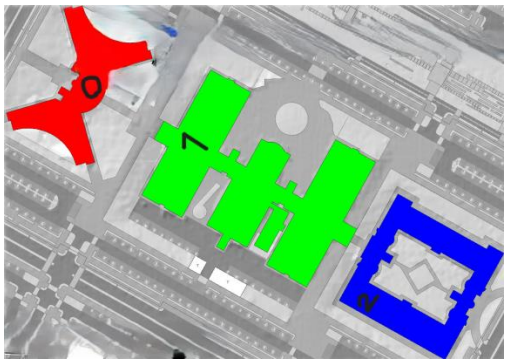
پایگاه‌داده UJIIndoorLoc سه ساختمان از دانشگاه Jaume I را با ۴ یا ۵ طبقه و تقریباً ۱۰۸۷۰۳ مترمربع پوشش می‌دهد.

ایـن پایگـاه‌داده می‌توانـد بـرای طبقه‌بنـدی، بـه‌عنوان‌مثال شناسایی واقعی ساختمان و طبقـه، یـا رگرسـیون، بـه‌عنوان‌مثال تخمین طـول و عـرض جغرافیـایی واقعـی، اسـتفاده شـود. ایـن پایگاه‌داده توسط بیش از ۲۰ کاربر مختلف و ۲۵ دستگاه اندرویـد ایجادشده است. این پایگاه‌داده شامل ۱۹۹۳۷ رکـورد آموزشـی و ۱۱۱۱ رکورد اعتبارسنجی است. ۵۲۹ ویژگی شامل اثـر انگشـت وای‌فای، مختصات محل ثبت آن و سایر اطلاعـات مفیـد در ایـن پایگاه‌داده ثبت است. هر اثر انگشت وای‌فای را می‌تـوان بـا نقـاط دسترسی بی‌سیم شناسایی‌شده و شدت قدرت سـیگنال دریـافتی مربوطه مشخص کرد. مقادیر شـدت به‌صـورت مقـادیر صـحیح از ۱۰۴- dBm (سیگنال بسیار ضعیف) تـا صـفر dBm نمـایش داده می‌شوند. مقدار مثبت ۱۰۰ برای نشان‌دادن زمانی که یک WAP شناسایی نشده است، استفاده می‌شود. در طول ایجاد پایگـاه‌داده، ۵۲۰ WAP مختلف شناسایی شدند؛ بنابراین، از ۵۲۹ اثر انگشـت وای‌فای، ۵۲۰ عدد مقادیر RSSI است. سپس به ترتیب، مختصات جغرافیایی شامل طول و عرض جغرافیایی ثبـت می‌شـوند. سـایر ویژگی‌ها اطلاعاتی در مورد شماره ساختمان و طبقه و اینکه چـه کسی (کاربر)، چگونه (دستگاه اندروید و نسخه)

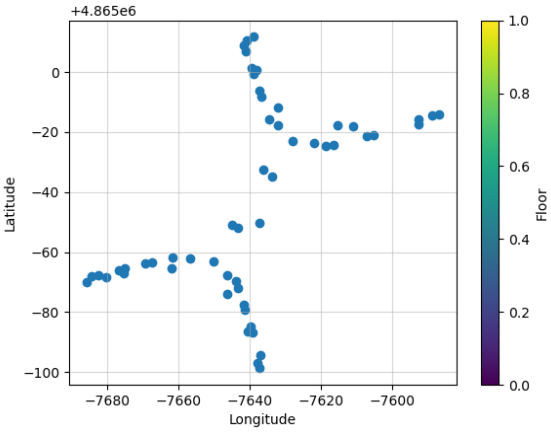
و چه زمانی (برچسب زمانی) وای‌فای را ضبط کـرده اسـت را شامل می‌شوند. برای حـل مسـئله رگرسـیون و تخمـین طـول و عرض جغرافیایی واقعی در میان پایگاه‌داده شـکل‌گرفته در شـکل

[1] Root Mean Square Error (RMSE)

(۲)،



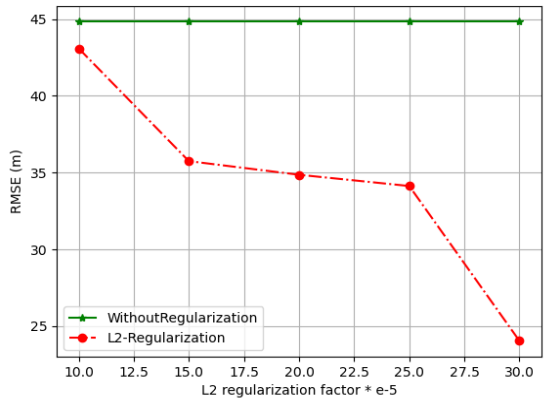
شکل (۲). نقشه سه ساختمان از دانشگاه Jaume I که پایگاه‌داده UJIIndoorLoc بر اساس آن و در مساحتی حدود ۱۰۸۷۰۳ مترمربع شکل‌گرفته است [۳۵].



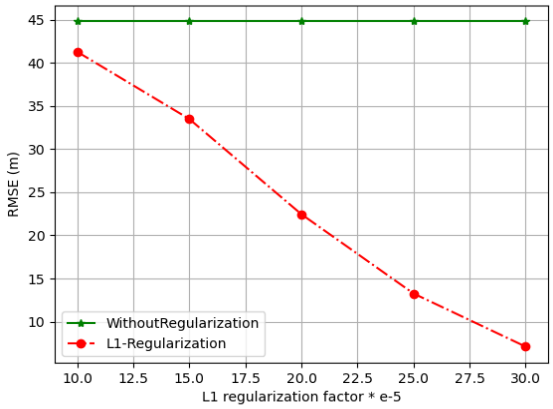
شکل (۳). فرایند جداسازی نقاط مرجع، در پایگاه‌داده معرفی‌شده UJIIndoorLoc، (ساختمان شماره صفر در شکل ۲ و طبقه اول) برای حل مسئله رگرسیون و تخمین طول و عرض جغرافیایی واقعی.

در ابتدا نقاط مرجع واقع در ساختمان اول و طبقه اول را همانند شکل (۳) جدا می‌نماییم سپس شبکه خود کدگذار دارای رگولاریزاتورهای غیر هموار طبق توضیحات ارائه‌شده در بخش‌های ۳ و ۴ آموزش می‌دهیم و در مرحله تخمین موقعیت آنلاین نیز، داده‌های RSS را در یک مکان ناشناخته اندازه‌گیری می‌کنیم. سپس داده‌های RSS را به خود کدگذار آموزش‌دیده می‌دهیم تا نمایش کم‌بعد آن را به دست آوریم. این نمایش را با نزدیک‌ترین تطابق پایگاه‌داده اثر انگشت مقایسه می‌کنیم و درنتیجه مکان مرتبط با این داده به‌عنوان مکان تخمینی ارائه می‌شود.

شکل ۴ خروجی سامانه موقعیت‌یابی مبتنی بر خود کدگذار عمیق بدون اعمال رگولاریزاسیون و نیز اعمال رگولاریزاسیون $\ell 2$ در هنگام تخمین موقعیت آنلاین برحسب بزرگی مقدار رگولاریزاسیون $\ell 2$ را با معیار RMSE نشان می‌دهد. می‌توان مشاهده کرد که RMSE خروجی شبکه با افزایش بزرگی مقدار رگولاریزاسیون $\ell 2$ یا همان β ، به‌ویژه، در مقادیر بالا، کاهش می‌یابد و دقت سامانه موقعیت‌یابی افزایش قابل‌توجهی را تجربه می‌کند که منجر به کاهش انحراف قابل‌توجهی بین موقعیت پیش‌بینی‌شده و موقعیت واقعی می‌شود.



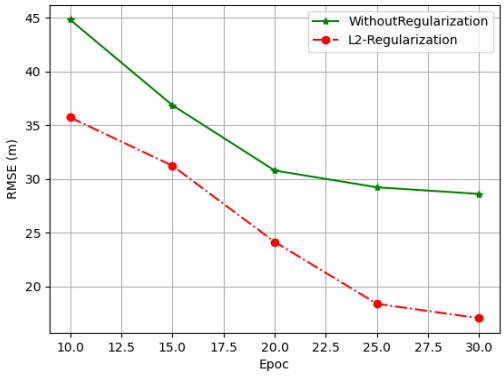
شکل (۴). مقایسه RMSE سامانه موقعیت‌یابی مبتنی بر خود کدگذار عمیق بدون رگولاریزاسیون و رگولاریزاسیون $\ell 2$ در هنگام تخمین موقعیت آنلاین برحسب بزرگی مقدار رگولاریزاسیون β



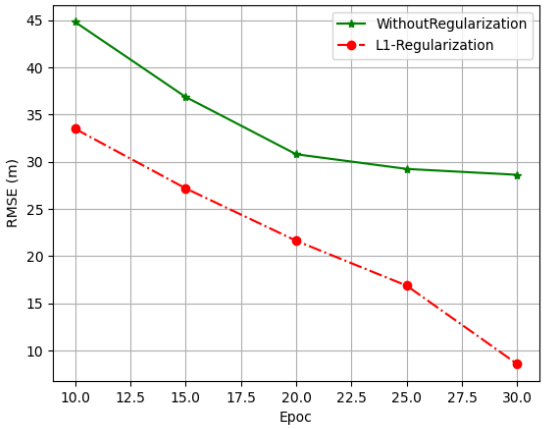
شکل (۵). مقایسه RMSE سامانه موقعیت‌یابی مبتنی بر خود کدگذار عمیق بدون رگولاریزاسیون و رگولاریزاسیون $\ell 1$ در هنگام تخمین موقعیت آنلاین برحسب بزرگی مقدار رگولاریزاسیون λ

شکل ۵ خطای سامانه موقعیت‌یابی مبتنی بر خود کدگذار عمیق بدون اعمال رگولاریزاسیون و نیز اعمال رگولاریزاسیون غیر هموار $\ell 1$ در هنگام تخمین موقعیت آنلاین برحسب بزرگی مقدار رگولاریزاسیون یا همان λ ، با معیار RMSE به تصویر کشیده است. همان‌طور که قابل‌مشاهده است، خطای مکان‌یابی با افزایش λ ، کاهش می‌یابد. در مقایسه باحالتی که رگولاریزاتور غیر هموار در شبکه اعمال نشده است و خطای مکان‌یابی تقریباً برابر ۴۴/۸۲۳ متر است، استفاده از فن رگولاریزاسیون غیر هموار این خطا را تا حدود ۷/۰۹۷ متر نیز کاهش داده است. شکل‌های ۶ و ۷ به ترتیب تأثیر استفاده از رگولاریزاسیون‌های $\ell 2$ و $\ell 1$ بر

سامانه موقعیت‌یابی مبتنی بر خود کدگذار عمیق برحسب تعداد ای پاک‌های متفاوت را نمایش می‌دهد.

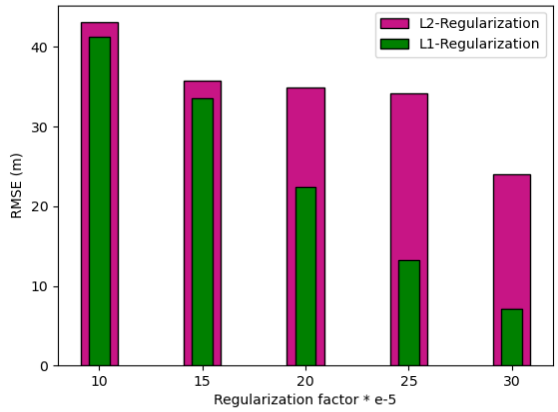


شکل (۶). مقایسه RMSE سامانه موقعیت‌یابی مبتنی بر خود کدگذار عمیق بدون رگولاریزاسیون و رگولاریزاسیون $\ell 2$ در هنگام تخمین موقعیت آنلاین برحسب تعداد ای پاک‌ها

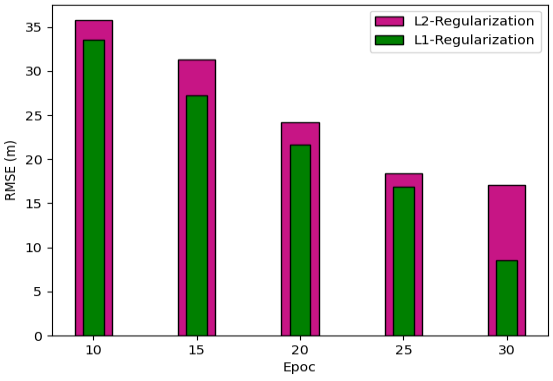


شکل (۷). مقایسه RMSE سامانه موقعیت‌یابی مبتنی بر خود کدگذار عمیق بدون رگولاریزاسیون و رگولاریزاسیون $\ell 1$ در هنگام تخمین موقعیت آنلاین برحسب تعداد ای پاک‌ها

همان‌طور که به‌وضوح از شکل‌ها نمایان است هرچقدر تعداد ای پاک‌ها افزایش می‌یابد، چه در حالتی که رگولاریزاسیون $\ell 2$ یا $\ell 1$ به شبکه اعمال نشده است و چه در حالتی که به شبکه اعمال‌شده است، افزایش تعداد ای پاک‌ها سبب کاهش RMSE شده است. به‌عنوان‌مثال، زمانی که تعداد ای پاک‌ها در این شکل‌ها برابر ۲۰ می‌شود RMSE در حالت بدون اعمال رگولاریزاسیون برابر ۳۰/۸۰۲ متر، در حالت اعمال رگولاریزاسیون $\ell 2$ برابر ۲۴/۱۶۹ متر و در حالت اعمال رگولاریزاسیون غیر هموار $\ell 1$ برابر ۲۱/۶۳۴ متر است. همین مقادیر زمانی که تعداد ای پاک‌ها برابر ۳۰ شود، RMSE به ترتیب در حالت بدون اعمال رگولاریزاسیون برابر ۲۸/۶۲۴ متر، در حالت اعمال رگولاریزاسیون $\ell 2$ برابر ۱۷/۰۷۶ متر و در حالت اعمال رگولاریزاسیون غیر هموار $\ell 1$ برابر ۸/۵۶۳ متر می‌شود.



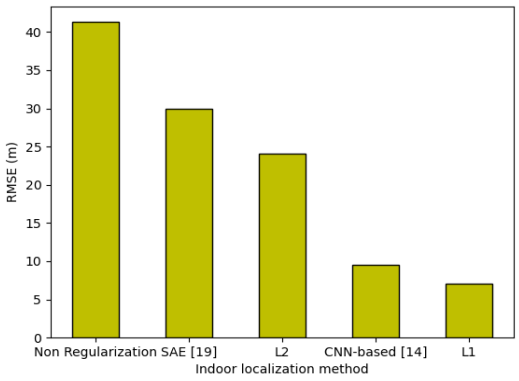
شکل (۸). مقایسه RMSE سامانه موقعیت‌یابی مبتنی بر خود کدگذار عمیق با اعمال رگولاریزاسیون $\ell 1$ و رگولاریزاسیون $\ell 2$ برحسب بزرگی مقدار رگولاریزاسیون



شکل (۹). مقایسه RMSE سامانه موقعیت‌یابی مبتنی بر خود کدگذار عمیق با اعمال رگولاریزاسیون $\ell 1$ و رگولاریزاسیون $\ell 2$ برحسب تعداد ای پاک‌ها

در شکل ۸ RMSE سامانه موقعیت‌یابی پیشنهادی، با اعمال رگولاریزاسیون $\ell 1$ و رگولاریزاسیون $\ell 2$ در هنگام تخمین موقعیت آنلاین برحسب بزرگی مقدار رگولاریزاسیون‌های متفاوت به تصویر کشیده شده است. همان‌طور که از تصویر مشخص است، هر مقدار که بزرگی رگولاریزاسیون افزایش می‌یابد، مقدار RMSE نیز کاهش می‌یابد. این کاهش مقدار RMSE به‌خصوص درزمانی که به شبکه خود کدگذار، رگولاریزاسیون غیر هموار $\ell 1$ اعمال می‌شود مقدار بیشتری کاهش می‌یابد. درواقع بردارهای RSSI در پایگاه‌داده UJIIndoorLOC غالباً دارای ویژگی‌هایی مانند تنکی (پراکندگی)، فراوانی و نویزی هستند و بسیاری از APها اطلاعات اندکی فراهم می‌کنند. رگولاریزاتوری $\ell 1$ با استفاده از این خاصیت تنکی موجب انتخاب زیرمجموعه‌ای از ویژگی‌های پایدار و حذف نویز می‌شود، درحالی‌که $\ell 2$ عمدتاً به هموارسازی وزن‌ها محدود است. این امر توضیح می‌دهد که چرا $\ell 1$ در این

کاربرد خاص عملکرد بهتری دارد.



شکل (۱۰). مقایسه RMSE سامانه موقعیت‌یابی مبتنی بر خود کدگذار عمیق با اعمال رگولاریزاسیون $\ell 1$ و رگولاریزاسیون $\ell 2$ و بزرگی مقدار رگولاریزاسیون برابر با ۳۰ با سایر روش‌های ذکرشده در مراجع بخش پیشینه تحقیق در پایگاه‌داده UJIIndoorLoc .

شکل ۹ به مقایسه RMSE سامانه موقعیت‌یابی مبتنی بر خود کدگذار عمیق با اعمال رگولاریزاسیون $\ell 1$ و رگولاریزاسیون $\ell 2$ در هنگام تخمین موقعیت آنلاین برحسب تعداد ای پاک‌های متفاوت می‌پردازد. همان‌طور که از تصویر مشخص است، هر مقدار که تعداد ای پاک‌ها افزایش می‌یابد، مقدار RMSE نیز کاهش می‌یابد. این کاهش مقدار RMSE به‌خصوص درزمانی که به شبکه خود کدگذار رگولاریزاسیون غیر هموار $\ell 1$ اعمال می‌شود همچنان مقدار بیشتری کاهش می‌یابد.

شکل ۱۰، مقایسه‌ای از عملکرد چند روش مختلف مکان‌یابی داخلی را نشان می‌دهد. همان‌طور که دیده می‌شود، روش مکان‌یابی با استفاده از خود کدگذار بدون رگولاریزاسیون (Non Regularization) بیشترین خطا را با مقدار ۴۴/۸۲ m دارد و دقت آن پایین است. مرجع[۱۹]که از SAE برای کاهش ابعاد و یک تابع هزینه وزن‌دار برای شبکه استفاده کرده است، در مجموعه‌داده UJIIndoorLoc خطای موقعیت‌یابی ۲۹/۹ m را گزارش کرده است.

با افزودن رگولاریزاتور $\ell 2$ میزان خطا کاهش چشمگیری پیدا کرده و به مقدار ۲۴/۰۳ m رسیده است. روش‌های جدیدتر مانند مرجع[۱۴] که روشی نو مبتنی بر شبکه‌های کانولوشنی پیشرفته‌تری است، در پایگاه‌داده UJIIndoorLoc، عملکرد بهتری از خود نشان داده است و خطای ۹/۵ m را ثبت نموده است. درنهایت، همان‌طور که در شکل نمایش‌داده‌شده است، سامانه موقعیت‌یابی پیشنهادی مبتنی بر شبکه یادگیری عمیق با ساختار خود کدگذار دارای رگولاریزاتورهای غیر هموار $\ell 1$ کمترین مقدار خطا را با مقدار ۷/۰۹۷ m ثبت کرده و نشان می‌دهد که این روش نسبت به سایر روش‌ها، برتری محسوسی در کاهش خطا و بهبود دقت سامانه مکان‌یابی داخلی دارد. در ادامه به‌منظور بررسی تحلیلی روش پیشنهادی جدول‌های ۲ و ۳ ترسیم‌شده‌اند.

جدول ۲: خروجی RMSE سامانه مکان‌یابی پیشنهادی برحسب مقدار رگولاریزاسیون.

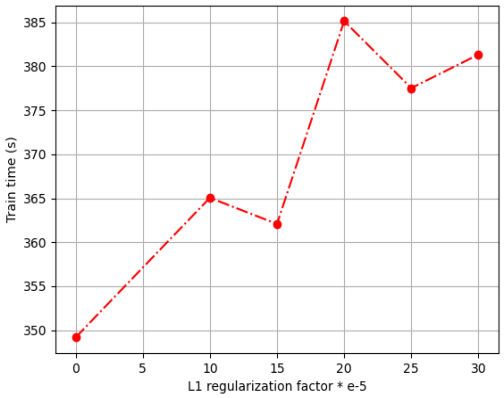
رگولاریزاسیون $\ell 1$	رگولاریزاسیون $\ell 2$	خود کدگذار بدون رگولاریزاسیون	مقدار رگولاریزاسیون
۴۱.۳۰	۴۳.۰۸	۴۴.۸۲	۱۰×e-۵
۳۳.۵۰	۳۵.۷۴	۴۴.۸۲	۱۵×e-۵
۲۲.۴۵	۳۴.۸۵	۴۴.۸۲	۲۰×e-۵
۱۳.۲۶	۳۴.۱۲	۴۴.۸۲	۲۵×e-۵
۷.۰۹۷	۲۴.۰۳	۴۴.۸۲	۳۰×e-۵

جدول ۳: خروجی RMSE سامانه مکان‌یابی پیشنهادی برحسب تعداد ای پاک‌ها

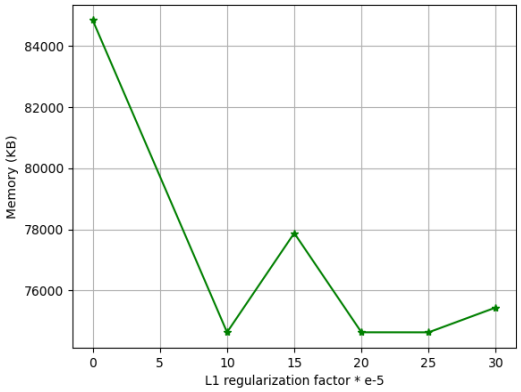
رگولاریزاسیون $\ell 1$	رگولاریزاسیون $\ell 2$	خود کدگذار بدون رگولاریزاسیون	تعداد ای پاک‌ها
۳۳.۵۰	۳۵.۷۴	۴۴.۸۲	۱۰
۲۷.۱۹	۳۱.۲۵	۳۶.۸۷	۱۵
۲۱.۶۳	۲۴.۱۶	۳۰.۸۰	۲۰
۱۶.۸۷	۱۸.۴۱	۲۹.۲۴	۲۵
۸.۵۶	۱۷.۰۷	۲۸.۶۲	۳۰

جدول ۲ روند تغییر خطای سامانه مکان‌یابی داخلی را در شرایط مختلف خود کدگذار بدون رگولاریزاسیون، با رگولاریزاسیون $\ell 2$ و با رگولاریزاسیون $\ell 1$ برحسب مقادیر رگولاریزاسیون متفاوت، نشان می‌دهد. همان‌طور که مشاهده می‌شود در حالت بدون رگولاریزاسیون، مقدار خطا، مقداری ثابت و زیاد باقی‌مانده است، اما با اعمال رگولاریزاسیون، خطا به‌تدریج کاهش‌یافته و هرچه مقدار رگولاریزاسیون بیشتر شده، دقت مدل به‌ویژه در حالت اعمال رگولاریزاسیون $\ell 1$ ، به طور قابل‌توجهی بهبود پیدا کرده است. به‌ویژه در رگولاریزاسیون با مقدار ۳۰، خطابه کمترین میزان خود رسیده و عملکرد مدل بسیار ارتقایافته است. این نتایج به‌خوبی بیانگر اهمیت و تأثیر مثبت رگولاریزاسیون در افزایش دقت روش‌های مبتنی بر خود کدگذار در مکان‌یابی داخلی است.

جدول ۳ نشان می‌دهد که با افزایش تعداد ای پاک‌ها، خطای سامانه مکان‌یابی در همه روش‌ها کاهش می‌یابد، بااین‌حال، مدل سامانه مکان‌یابی بدون رگولاریزاسیون همچنان خطای بالاتری دارد. در مقابل، به‌کارگیری رگولاریزاسیون باعث افت چشمگیر خطا شده و درنهایت، وقتی‌که بزرگی مقدار رگولاریزاسیون برابر ۰/۰۰۱۵ در نظر گرفته‌شده است، در ای پاک ۳۰ کمترین میزان خطا برای همه مدل‌های مکان‌یابی ثبت گردیده است. این روند نشان‌دهنده نقش کلیدی رگولاریزاسیون و وجود آموزش کافی در بهبود عملکرد سامانه مکان‌یابی مبتنی بر خود کدگذار است.



شکل (۱۱). بررسی پیچیدگی زمانی سامانه موقعیت‌یابی پیشنهادی مبتنی بر خود کدگذار عمیق با اعمال رگولاریزاسیون $\ell 1$ برحسب بزرگی مقدار رگولاریزاسیون (زمان آموزش مدل خود کدگذار عمیق)



شکل (۱۲). بررسی پیچیدگی فضایی سامانه موقعیت‌یابی پیشنهادی مبتنی بر خود کدگذار عمیق با اعمال رگولاریزاسیون $\ell 1$ برحسب بزرگی مقدار رگولاریزاسیون (میزان مصرف حافظه)

۵-۱. تحلیل پیچیدگی محاسباتی و ظرفیت مقیاس‌پذیری خود کدگذار عمیق با بهره‌گیری از رگولاریزاسیون غیر هموار در سامانه مکان‌یابی پیشنهادی

یکی از جنبه‌های حیاتی در ارزیابی الگوریتم‌های یادگیری ماشین، بررسی پیچیدگی محاسباتی است که شامل دو بعد اصلی، یعنی پیچیدگی زمانی و فضایی می‌شود. در سامانه موقعیت‌یابی مبتنی بر شبکه یادگیری عمیق با ساختار خود کدگذار دارای رگولاریزاتورهای غیر هموار پیشنهادی، زمان آموزش عمدتاً تابعی از تعداد نمونه‌های آموزشی، تعداد ویژگی‌های ورودی، تعداد لایه‌ها و تعداد نورون‌ها در هر لایه است.

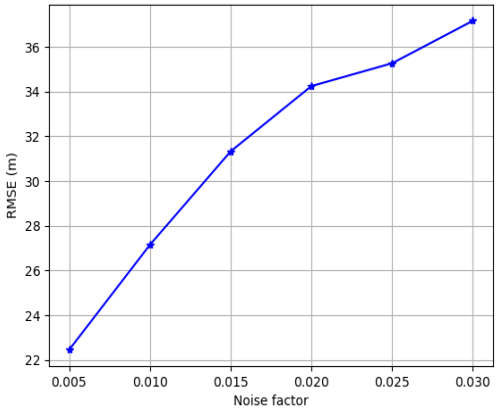
شکل ۱۱ به بررسی پیچیدگی زمانی مدل می‌پردازد. نتایج ارائه‌شده در شکل نشان می‌دهد که بزرگی مقدار رگولارسازی $\ell 1$ تأثیر مستقیمی بر زمان آموزش مدل دارد. با افزایش ضریب رگولارساز، زمان آموزش دچار نوسانات محسوسی شده و در مقادیر بالاتر افزایش قابل‌توجهی را تجربه می‌کند. این رفتار به طور عمده ناشی از تحمیل قیود اضافی بر فضای بهینه‌سازی و دشوارتر شدن فرایند همگرایی شبکه است. از منظر تحلیلی، می‌توان دریافت که انتخاب مقادیر بسیار کوچک رگولارساز تأثیر اندکی بر هزینه محاسباتی دارد، اما مقادیر بزرگ‌تر باعث ایجاد پیچیدگی بیشتر در حل مسئله بهینه‌سازی و درنتیجه افزایش زمان آموزش می‌شود.

پیچیدگی فضایی نشان‌دهنده میزان حافظه موردنیاز برای ذخیره داده‌ها، وزن‌ها، گرادیان‌ها و سایر متغیرهای واسطه‌ای در طول فرایند آموزش و پیش‌بینی است. در مدل‌های عمیق، مصرف حافظه به‌ویژه در مواجهه با ورودی‌های حجیم و شبکه‌های با تعداد لایه و نورون زیاد می‌تواند به‌سرعت افزایش یابد. همان‌طور که در شکل ۱۲ مشاهده می‌شود، استفاده از رگولاریزاسیون ناهموار $\ell 1$، موجب می‌شود برخی وزن‌ها به صفر کاهش یابند که این فرایند، مصرف حافظه برای ضرب ماتریسی و نگهداری وزن‌های غیرصفر را بهینه می‌کند. همچنین رگولاریزاسیون $\ell 1$ به دلیل ایجاد تنکی در ویژگی‌ها، به‌ویژه در دیتاست‌های با ابعاد بالا، منجر به بهبود عمومیت‌بخشی و کاهش نیاز به حافظه می‌شود. این ویژگی می‌تواند برای ساختمان‌های بزرگ‌تر مفید باشد و مقیاس‌پذیری سامانه پیشنهادی را افزایش دهد.

۵-۲. تحلیل مقاومت سامانه پیشنهادی در برابر نویز و منابع بروز خطا

در سامانه‌های مکان‌یابی داخلی مبتنی بر خود کدگذار با رگولاریزاتور $\ell 1$، عملکرد سامانه می‌تواند تحت‌تأثیر سناریوها و شرایط محیطی مختلف کاهش یابد. تغییرات شدید محیطی مانند جابه‌جایی مبلمان، تغییر چیدمان اتاق یا تراکم بالای جمعیت الگوهای سیگنال را مختل می‌کند و نمایش یاد گرفته‌شده ممکن است دقیق نباشند. ناهمگونی شدید دستگاه‌ها، شامل تفاوت در سخت‌افزار و حساسیت آنتن‌ها، و تداخل RF از دستگاه‌ها یا APهای مجاور، نویز و اختلال در سیگنال ایجاد می‌کند. رگولاریزاسیون $\ell 1$ به طور طبیعی نمایش تنکی از ویژگی‌ها ایجاد می‌کند. این تنکی به‌خصوص در مکان‌یابی داخلی معنادار است، زیرا در هر مکان تنها تعداد محدودی AP اطلاعات قوی فراهم می‌کنند و بقیه APها نویز یا سیگنال‌های ضعیف دارند؛ بنابراین این نمایش تنک به تفکیک بهتر مکان‌ها کمک می‌کند.

عوامل مختلف می‌توانند دقت مکان‌یابی داخل اتاق با استفاده از خود کدگذار دارای رگولاریزاتور $\ell 1$ را تحت‌تأثیر قرار دهند.



شکل (۱۳). بررسی تأثیر افزایش نویز بر عملکرد سامانه موقعیت‌یابی پیشنهادی مبتنی بر خود کدگذار عمیق با اعمال رگولاریزاسیون $\ell 1$ برحسب بزرگی مقدار نویز

ناهمگونی دستگاه‌ها باعث تغییر در داده‌ها و اختلاف در شدت سیگنال می‌شود، اما تنکی ایجادشده توسط رگولاریزاتور $\ell 1$ به مدل اجازه می‌دهد که تنها ویژگی‌های قوی و پایدار را در مدل حفظ کند و اثر نویز ناشی از تفاوت دستگاه‌ها کاهش یابد. تغییرات محیطی، مانند جابه‌جایی مبلمان، تراکم جمعیت یا تغییر چیدمان اتاق، روابط بین APها و نقاط مکان‌یابی را دستخوش تغییر می‌کنند، در این شرایط، نمایش تنک کمک می‌کنند تا مدل بر APهای کلیدی تمرکز کند، اما تغییرات شدید همچنان می‌تواند دقت را کاهش دهد و نیاز به به‌روزرسانی مدل را ضروری سازد.

علاوه بر این، تداخل از دستگاه‌های دیگر یا APهای مجاور می‌تواند نویز ایجاد کند و شدت سیگنال را تصادفی تغییر دهد، اما $\ell 1$ با انتخاب ویژگی‌های مهم، اثر نویز و تداخل را کاهش می‌دهد، هرچند در محیط‌های با تداخل بالا احتمال کاهش دقت وجود دارد. به‌طورکلی، رگولاریزاتور $\ell 1$ مقاومت نسبتاً خوبی در برابر نویز و تغییرات محیطی و دستگاهی ایجاد می‌کند، اما سناریوهای شدید هنوز نیازمند تحلیل هستند. در شکل ۱۳، رابطه‌ی میان افزایش نویز و خطای مکان‌یابی (RMSE) در یک خود کدگذار با رگولاریزاتور ناهموار به تصویر کشیده شده است. با مشاهده‌ی روند صعودی منحنی می‌توان دریافت که حتی سطوح اندک نویز نیز به‌تدریج دقت مدل را کاهش داده و به رشد خطا می‌انجامند. این رفتار نشان می‌دهد که خود کدگذار در برابر اغتشاشات محیطی حساس است و پایداری آن در شرایط واقعی باید تقویت گردد. چنین تحلیلی اهمیت طراحی سازوکارهای مقاوم‌سازی و به‌کارگیری رگولاریزاتورهای ناهموار را آشکار می‌سازد.

۶. نتیجه‌گیری

در این مقاله یک سامانه مکان‌یاب داخلی مبتنی بر یادگیری عمیق معرفی شد که از ساختار خود کدگذار با رگولاریزاتورهای غیر هموار برای استخراج نمایش کم‌بعد از داده‌های RSS استفاده می‌کند. در مرحله آموزش آفلاین، داده‌های RSS به‌دست‌آمده از چندین AP از یک شبکه یادگیری عمیق با ساختار خود کدگذار دارای رگولاریزاتورهای غیر هموار عبور داده می‌شود تا شبکه نمایش کم‌بعد داده‌های RSS به دست بیاید. در مرحله تخمین موقعیت آنلاین، داده‌های RSS در یک مکان ناشناخته اندازه‌گیری می‌کنیم و آن‌ها را به خود کدگذار آموزش‌دیده می‌دهیم تا نمایش کم‌بعد آن به دست بیاید. سپس مکان کاربر با استفاده از نزدیک‌ترین تطابق در این پایگاه‌داده تخمین زده می‌شود. با مقایسه رگولاریزاتورهای اعمال‌شده به ساختار خود کدگذار، نتایج شبیه‌سازی‌ها نشان داد که استفاده از رگولاریزاتورهای غیر هموار در ساختار خود کدگذار می‌تواند دقت مکان‌یابی را به طور معناداری بهبود دهد. به‌عنوان جهت‌های آینده، توسعه روش‌های ترکیبی مبتنی بر چند منبع داده، استفاده ترکیبی از معماری‌های متفاوت شبکه‌های عمیق پیشنهاد می‌شود. این مسیرها می‌توانند موجب ارتقای بیشتر دقت و پایداری سامانه مکان‌یابی پیشنهادی شوند. همچنین توسعه مدل‌هایی که علاوه بر دقت بالایی که ارائه می‌دهند، مصرف انرژی کم و قابلیت اجرا روی تلفن همراه داشته باشند، بسیار بااهمیت خواهند بود. همچنین سامانه‌های ناوبری داخل ساختمان و اینترنت اشیا و مدیریت انرژی از کاربردهای عملی روش پیشنهادی در محیط‌های واقعی هستند که البته با محدودیت‌هایی مانند نیاز به داده آموزشی کافی و حساسیت به شرایط محیطی روبه‌رو هستند.

۷. مراجع

[1] IEEE: N. Doğan and Ö. H. Bettemir, “Assessment of Blind-Spots and Multi-Path Effects at Indoor Positioning by Multilateration,” Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci., vol. XLVIII-M-6, pp. 337-344, 2025.

[2] T. G. Hailu, X. Guo, H. Si, L. Li, and Y. Zhang, “Theories and Methods for Indoor Positioning Systems: A Comparative Analysis, Challenges, and Prospective Measures,” Sensors, vol. 24, no. 21, art. no. 6876, Oct. 2024. doi: 10.3390/s24216876

[3] S. Tiku, D. Gufran, and S. Pasricha, “Multi-Head Attention Neural Network for Smartphone Invariant Indoor Localization,” 2022 IEEE 12th International Conference on Indoor Positioning and Indoor Navigation (IPIN), Pisa, Italy, 2022, pp. 1-8, doi: 10.1109/IPIN54987.2022.9918120

[4] Yang, Z., Zhou, Z., & Liu, Y. (2013). From RSSI to CSI: Indoor localization via channel response. ACM Computing Surveys (CSUR), 46(2), 1–32. https://doi.org/10.1145/2543581.

[5] D. J. Suroso and F. Y. M. Adiyatma, "C-MEL: Consensus-Based Multiple Ensemble Learning for Indoor Device-Free Localization Through

[21] R. Wang, Z. Li, H. Luo, F. Zhao, W. Shao and and Q. Wang, "A robust Wi-Fi fingerprint positioning algorithm using stacked denoising autoencoder and multi-layer perceptron," *Remote Sensing,* vol. 11, no. 11, p. 1293, 2019.

[22] X. S. e. al., "CNNLoc: Deep-Learning Based Indoor Localization with Wi-Fi Fingerprinting," in IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation, Leicester, UK, 2019.

[23] X. Feng, K. A. Nguyen and Z. Luo, "A survey of deep learning approaches for Wi-Fi-based indoor positioning," Journal of Information and Telecommunication, vol. 6, no. 2, pp. 163-216, 2022.

[24] W. Zhang, K. Liu, W. Zhang, Y. Zhang and a. J. Gu, "Deep neural networks for wireless localization in indoor and outdoor environments," Neurocomputing, vol. 194, pp. 279-287, 2016.

[25] N. Salahian, F. A. Tab, S. A. Seyedi and J. Chavoshinejad, "Deep autoencoder-like NMF with contrastive regularization and feature relationship preservation," Expert Systems with Applications, vol. 214, p. 119051, 2023.

[26] H. Steck and D. G. Garcia, "On the Regularization of Autoencoders," arXiv preprint arXiv:2110.11402, 2021.

[27] S. Amini and S. Ghaernmaghami, "Sparse autoencoders using non-smooth regularization," in 2018 26th European Signal Processing Conference (EUSIPCO), 2018.

[28] S. Amini and S. Ghaemmaghami, "A new framework to train autoencoders through non-smooth regularization," IEEE Transactions on Signal Processing, vol. 67, no. 7, pp. 1860-1874, 2019.

[29] Y. Dar, V. Muthukumar and R. G. Baraniuk, "A farewell to the bias-variance tradeoff, an overview of the theory of overparameterized machine learning," arXiv preprint arXiv:2109.02355, 2021.

[30] M. Belkin, D. Hsu, S. Ma and S. Mandal, "Reconciling modern machine-learning practice and the classical bias--variance trade-off," Proceedings of the National Academy of Sciences, vol. 116, no. 32, pp. 15849-15854, 2019.

[31] Garca and J. Vallet, "Characterization of the log-normal model for received signal strength measurements in real wireless sensor networks," J. Sensor Actuator Netw, vol. 9, no. 1, p. 12, 2020.

[32] B. Yamamoto, A. Wong, P. J. Agcanas, K. Jones, D. Gaspar, R. Andrade and A. Z. Trimble, "Received signal strength indication (RSSI) of 2.4 GHz and 5 GHz wireless local area network systems projected over land and sea for near-shore maritime robot operations," Journal of Marine Science and Engineering, vol. 7, no. 9, p. 290, 2019.

[33] M. Castillo, J. Ramirez, and P. Torres, "RSSI-Based Indoor Localization Using Machine Learning for Wireless Sensor Networks: A Recent Review," in Proc. IEEE ANDESCON, Arequipa, Peru, Nov. 2024, pp. 1–6, doi: 10.1109/ANDESCON61840.2024.10755908.

[34] M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin et al., "Tensorflow: Large-scale machine learning on heterogeneous distributed systems," arXiv preprint arXiv:1603.04467, 2016.

[35] Torres-Sospedra, Ra´ul Montoliu, Adolfo Mart´ınez-Us´o, Joan P. Avariento, Tom´as J. Arnau, Mauri Benedito-Bordonau, and Joaqu´ın Huerta, " UJIIndoorLoc: A New Multi-building and Multi-floor Database for WLAN Fingerprint-based Indoor Localization Problems," In Proceedings of the Fifth International Conference on Indoor Positioning and Indoor Navigation (IPIN 2014), Busan (Korea), 2014.

Fingerprinting," in IEEE Access, vol. 12, pp. 166381-166392, 2024, doi: 10.1109/ACCESS.2024.3493889.

[6] O. Muta, K. Takata, K. Noguchi, T. Murakami and S. Otsuki, "DeviceFree WLAN Based Indoor Localization Scheme With Spatially Concat-enated CSI and Distributed Antennas," *IEEE Transactions on Vehicular Technology,* vol. 72, pp. 852-865, 2023.

[7] N. Singh and R. P. S. Choe, "Machine Learning Based Indoor Localization Using Wi-Fi RSSI Fingerprints: An Overview," IEEE Access, vol. 9, pp. 127150-127174, 2021.

[8] Alaei, Nasrin and Tajoddin, Asghar, "Host-based Anomaly Malware Detection Using Deep Learning," Electronic and cyber defense Journal, vol. 12, no. 4, 2025 (in Persian).

[9] zare mehrjardi, fatemeh and latif, ali mohammad and sardari zarchi, mohsen, "Forgery detection in digital images using the hybrid deep learning method," Electronic and cyber defense Journal, vol. 11, no. 4, 2024 (in Persian).

[10] asghari tahergorabei, khatereh and rajabi behjat, amir and Dallaki, Hedayatollah "Daily rainfall forecasting with Deep ESN neural network based on experimental data from meteorological station in Hormozgan province," Information technology innovations and applied communications, vol. 2, no. 1, 2021(in Persian).

[11] R. Gao, X. Li and W. Chen, "A Semi-Supervised Indoor Localization Algorithm Based on Probabilistic Distribution Modeling," in IEEE Transactions on Mobile Computing, 2025. doi: 10.1109/TMC.2025.3608276.

[12] W. Long et al., "Reliable Indoor Localization in Multibuilding Environments: Leveraging Environment-Invariant and Position-Related Features," in IEEE Internet of Things Journal, vol. 12, no. 14, pp. 26401-26414, 15 July15, 2025, doi: 10.1109/JIOT.2025.3561500.

[13] P. Park, P. D. Marco and F. Santucci, "Efficient Data Collection and Training for Deep-Learning-Based Indoor Vehicle Navigation," in IEEE Internet of Things Journal, vol. 11, no. 11, pp. 20473-20485, 1 June1, 2024, doi: 10.1109/JIOT.2024.3371385.

[14] A. Kargar-Barzi, E. Farahmand, N. Taheri Chatrudi, A. Mahani and M. Shafique, "An Edge-Based WiFi Fingerprinting Indoor Localization Using Convolutional Neural Network and Convolutional Auto-Encoder," in IEEE Access, vol. 12, pp. 85050-85060, 2024, doi: 10.1109/ACCESS.2024.3412676.

[15] T. Hoang, B. Yuen, X. Dong, T. Lu, R. Westendorp and and K. Reddy, "Recurrent neural networks for accurate rssi indoor localization," IEEE Internet of Things Journal, vol. 6, no. 6, p. pp. 10, 2019.

[16] M. Nowicki and J. Wietrzykowski, "Low-effort place recognition with Wi-Fi fingerprints using deep learning,," in Innovations in Automation, Robotics and Measurement Techniques 1, 2017.

[17] A. Moreira, M. J. Nicolau, F. Meneses and and A. Costa, "Wi-Fi fingerprinting in the real world - rtls at the evaal competition," in International Conference on Indoor Positioning and Indoor Navigation (IPIN), 2015.

[18] K. S. Kim, R. Wang, Z. Zhong, Z. Tan, H. Song, J. Cha and and S. Lee, "Large-scale location-aware services in access: Hierarchical building/floor classification and location estimation using Wi-Fi fingerprinting based on deep neural networks," in International Workshop on Fiber Optics in Access Network (FOAN), 2017.

[19] K. S. Kim, S. Lee and and K. Huang, "A scalable deep neural network architecture for multi-building and multi-floor indoor localization based on Wi-Fi fingerprinting," Big Data Analytics, vol. 3, no. 1, 2018.

[20] W. Zhang, K. Liu, W. Zhang, Y. Zhang and a. J. Gu, "Deep neural networks for wireless localization in indoor and outdoor environments," Neurocomputing, vol. 194, pp. 279-287, 2016.