

کاربرد شبکه های عصبی RBF در شبکه حمل و نقل شهری

مجید عابدینی^۱

^۱ هیات علمی گروه ریاضی-دانشگاه پیام نور-صندوق پستی ۱۹۳۹۵-۳۶۹۷ -تهران-ایران

چکیده

افزایش حجم ترافیک و ایجاد گرههای ترافیکی در راههای بین شهری و همچنین شبکه ترافیک شهری سبب کاهش کارایی شبکه ترافیکی و راههای مورد نظر میشود. پیشبینی و کشف هرچه سریعتر این گرههای ترافیکی میتواند کمک شایانی به حل مشکل و روان سازی جریان ترافیک نماید. شبکههای عصبی مصنوعی نشان داده اند که با تکیه بر قابلیت یادگیری خود میتوانند عملکرد بسیار مناسبی در این زمینه از خود نشان دهند. هدف اصلی این تحقیق پیشبینی و تشخیص خودکار گرههای ترافیکی با استفاده از مدل شبکه عصبی هوشمند و مقایسه کارایی مدل با مدلهای دیگر موجود است. این مقاله رویکردی را مطرح می کند که ترکیبی از داده های مطلوب و اطلاعات زمان واقعی برای پیش بینی زمان رسیدن اتوبوس می باشد. این رویکرد شامل دو مرحله است. اولاً، مدل شبکه های عصبی براساس تابع پایه شعاعی (RBF) برای تقریب رابطه غیر خطی در داده های مطلوب، سپس در دومین مرحله، یک روش آنلاین برای تعدیل وضعیت واقعی معرفی می شود. در ادامه، یک مطالعه آزمایشی بر روی مسیر شماره ۲۱ اتوبوس در دالیان با استقرار این سیستم بر ای اثبات اعتبار و اثر بخشی این رویکرد انجام شد. به علاوه، مدل رگرسیون خطی چندگانه، شبکه های عصب BP و RBF بدون تعدیل آنلاین استفاده می شود. نتایج نشان می دهد که رویکرد با RBF و تعدیل آنلاین دارای عملکرد پیش بینی بهتری است.

واژه های کلیدی: شبکه های عصبی، تابع پایه شعاعی، تعدیل وضعیت واقعی، گرههای ترافیکی، شبکه ترافیک شهری

۱ - مقدمه

امروزه مسایل و مشکلات حمل و نقل از قبیل آلودگیهای زیست محیطی، کاهش منابع انرژی، افزایش خسارت‌های مادی و معنوی ناشی از سوانح و تصادفات، مشکلات نظارت و مدیریت در حمل و نقل برونشهری، افزایش زمانهای تلف شده و روند رشد سریع تقاضای حمل و نقل به ویژه در ساعات اوج در کلان شهرهای دنیا به یک مشکل جدی تبدیل شده است.

حمل و نقل هوشمند چیست؟ **Intelligent Transportation Systems** یا سیستم حمل و نقل هوشمند، مجموعه‌ای از ابزارها، امکانات و تخصص هاست که شامل مفاهیم مهندسی ترافیک، تکنولوژی‌های نرم افزاری، سخت افزاری و مخابراتی بوده و به صورت یکپارچه به منظور بهبود کارایی و ایمنی در سیستم حمل و نقل به کار گرفته می‌شود. سیستم‌های حمل و نقل هوشمند **ITS** سیستم‌هایی متشکل از فناوری‌های نوین الکترونیک، کامپیوتر، **IT**، الکترو مکانیک و ... هستند که امروزه در برنامه ریزی سیستم‌های حمل و نقل زمینی، هوایی، ریلی و ... نقش بسیار مهمی ایفا می‌نمایند. در سیستم‌های هوشمند فناوری‌های متفاوتی استفاده می‌شود، مانند سیستم‌های هدایت خودرو، سیستم کنترل چراغ‌های

راهنمایی، تابلوهای اعلان ترافیک، دوربین سرعت سنج و سیستم خودکار شناسایی شماره خودرو یا سیستم‌های پیشرفته و پیچیده تری که بطور همزمان اطلاعات متفاوتی را از منابع متفاوت یکپارچه می‌کند. اطلاعاتی مانند وضع آب و هوا، وضعیت ترافیک، وضعیت جاده..

(**ITS**) قدمت کاربرد و برنامه‌ریزی سیستم‌های حمل و نقل هوشمند به اوایل دهه ۹۰ میلادی می‌رسد که در کشورهای توسعه یافته، از همان زمان شروع به مطالعه طراحی و گسترش این سیستم‌ها نموده‌اند با توجه به توسعه سیستم‌های مختلف حمل و نقل زمینی و افزایش تقاضای سفر به صورت تصادعی و مشکلات عرضه، شاخه‌های مختلف (**ITS**) نقل توانسته‌اند، تاثیرات بسیار مطلوبی در حل چالشهای حمل و نقل برای دولتها فراهم می‌آورد.

۱-۱: مزایای به کارگیری سیستم حمل و نقل هوشمند **ITS**

سیستم‌های هوشمند حمل و نقل از آنجا که استفاده از سیستم‌های حمل و نقل هوشمند از فناوری مخابرات، الکترونیک، سخت افزار و نرم افزار کامپیوتر و شیوه‌های نوین علم مدیریت و برنامه‌ریزی استفاده می‌نمایند، می‌توانند مزایای زیادی را در بر داشته باشند، از جمله:

- ۱- کاهش ترافیک و بهبود حرکت در حمل و نقل جاده ای
- ۲- افزایش امنیت
- ۳- افزایش راندمان
- ۴- کاهش مصرف انرژی و آلودگی محیط زیست
- ۵- برطرف نمودن محدودیت منابع مالی و محیطی
- ۶- قابل رقابت شدن تولید
- ۷- اطلاع رسانی به مسافر با سیستم‌های پیشرفته اطلاع رسانی
- ۸- سهولت در انتخاب نوع وسیله نقلیه برای مسافر
- ۹- بایگانی و آرشیو اطلاعات
- ۱۰- سهولت در پرداخت به دلیل استفاده از سیستم پرداخت‌های الکترونیک
- ۱۱- بهینه سازی جریان ترافیک و روانسازی حرکت
- ۱۲- مدیریت و کنترل حوادث
- ۱۳- پشتیبانی و مدیریت وسائل نقلیه امدادی

۱۴- مدیریت اخذ الکترونیکی عوارض، هزینه پارکینگ، خرید و رزوانسیون بلیط و ...

۱۵-مانتیورینگ و کنترل حمل و نقل سنگین

۱۶-مدیریت و پشتیبانی عابر پیاده

همچنین با بکارگیری سیستم های حمل و نقل هوشمند می توان تا حد بسیار زیادی اتلاف انرژی، آلودگی زیست محیطی و یا آمار تصادفات را کاهش داد. سیستم های حمل و نقل هوشمند قادرند تا با استفاده از ازدستگاه های *GPS* و شبکه های مخابراتی، خدماتی همچون موقعیت، هدایت، کنترل و انتقال صدا، تصویر را ارائه دهند که خود نقش بسیار زیادی در کاهش مشکلات حمل و نقل ایفا می کند.

استفاده از شبکه های عصبی در سالهای اخیر رواج فراوانی داشته است و از تحقیقات وسیعتر در زمینه های کاربردی برای حل بسیاری از مسایل دنیای بشری راه گشوده است. شبکه های عصبی مصنوعی در تقابل با شبکه های عصبی طبیعی از قابلیت و قدرت بالاتری در بسیاری از زمینه ها مانند پردازش خطی و حجم بالای پردازش برخوردار است، از جمله در سیستم حمل و نقل اتوبوس شهری. تحقیقات بر روی پیش بینی زمان رسیدن اتوبوس تا اواخر ۱۹۹۰ میلادی با هدف استخراج این اطلاعات از سیستم های پایش وسایل نقلیه (لین و زنگ ۱۹۹۹) انجام شده اند. زو و همکارانش یک سیستم مبتنی بر تلاش مشارکتی کاربران شرکت کننده را توسعه داده و مستقل از شرکت های عملیاتی اتوبوس به جای اشاره به جی پی اس می باشد که امکان جمع اوری اطلاعات را از سازمانهای حمل و نقل داده است. بیایگینی و همکارانش یک الگوریتم دینامیک آنلاین را از پایش و مسیریابی ترانزیت خودکار، پیش بینی زمان ورود را با استفاده از تلفن هوشمند توسعه داد. یک مطالعه آزمایشی بر روی مسیر شماره ۲۱ در دالیان با استقرار سیستم عصبی مصنوعی برای اثبات روایی و اثر بخشی این رویکرد انجام شد. به علاوه، مدل رگرسیون خطی چندگانه، شبکه های عصبی *BP* و *RBF* بدون تعدیل آنلاین استفاده می شود. نتایج نشان داد که رویکرد با *RBF* و تعدیل آنلاین دارای عملکرد پیش بینی بهتری است

۲- شبکه های عصبی تابع پایه شعاعی

یکی از قدرتمندترین شبکه های عصبی مورد استفاده در مسائل تخمین تابع، شبکه عصبی *RBF* است. این نوع شبکه نسبت به شبکه های عصبی پرسپترون پیشخوردی، مزایای استرژیکتی دارد. شبکه های عصبی گاوسی که برای یادگیری نگاشت های پیچیده تعریف شده اند برای یادگیری، شناسایی، همسان سازی و کنترل سیستم های غیرخطی پویا نیز استفاده می شوند. این توابع در تخمین، پیش بینی سریهای زمانی و کنترل مورد استفاده قرار می گیرند. در شبکه عصبی مصنوعی از این توابع می توان به عنوان تابع فعالیت نرون استفاده کرد. برخلاف شبکه های *MLP* که دارای لایه های متوالی متعددی هستند، شبکه *RBF* از سه لایه ثابت تشکیل شده است. لایه ورودی که محل تزریق سیگنالهای ورودی به شبکه است، لایه میانی یا طبقه *RBF* که شامل توابع *RBF* میشود، و لایه خروجی که ترکیبی خطی از کلیه خروجیهای طبقه *RBF* را میسازد. در اکثر موارد از تابع گاوسی در لایه *RBF* استفاده میشود که این توابع با دو پارامتر مرکز گاوسی و واریانس یا میزان گستردگی گاوسی شناسایی میشوند.

۲-۱: الگوریتم های آموزش


با توجه به این ساختمان، آموزش شبکه *RBF* عبارت است از یافتن مقادیر مناسبی برای مراکز و گستردگی گوسیها و همچنین وزنها لایه آخر. تعداد گرهای *RBF* در لایه میانی نیز باید مشخص شود. برای آموزش شبکه *RBF* روشهای مختلفی موجود است. اکثر این روشها ابتدا پارامترهای لایه میانی (مرکز و واریانس تابع گاوسی هر نرون) را به دست می آورند و سپس پارامترهای لایه خروجی (وزنها و بایاسها) با روش کمترین مربعات یا با یک روش بانظر تخمین زده می شوند. برای آموزش پارامترهای لایه میانی *RBF* معمولاً از روش های خوشه بندی استفاده می شود اما می توان از روش های بهینه سازی غیر خطی نیز استفاده نمود. در روش های خوشه بندی سعی می شود با استفاده از داده های آموزشی در فضای

ورودی تعدادی تابع گوسی (معادل نرون) قرار داده شود. به این ترتیب هدف روش‌های خوشه‌بندی، به دست آوردن مرکز و واریانس این توابع و در صورت نیاز تعداد این توابع است. روش‌های بدون ناظر، خوشه‌بندی فقط بر اساس ورودی (در داده‌های آموزشی) انجام می‌پذیرد ولی در روش‌های باناظر خروجی (خطای مدل سازی) نیز در نظر گرفته می‌شود.

۲-۲: آموزش مراکز توابع **Basis**: مراکز توابع **Basis** را می‌توان به طور تصادفی از مقادیر ممکن برای ورودی نمونه برداری کرد. همچنین می‌توان پس از خوشه‌بندی (**Cluster**) نمونه‌ها میابینگین هر نمونه به عنوان مرکز تابع انتخاب کرد.

۲-۳: آموزش وزن‌های لایه خروجی: یکی از روش‌های آموزش وزن‌های لایه خروجی الگوریتم **Gradient Descent** است. در این الگوریتم وزن‌ها در هر مرحله با انتقال در خلاف جهت گرادیان تابع هدف تصحیح می‌شوند.

خصوصیت منحصر به فرد شبکه‌های **RBF**، پردازشی است که در لایه پنهان انجام می‌گیرد. ایده اصلی آن است که الگوهای فضای ورودی، تشکیل خوشه دهند. در صورتی که مراکز این خوشه‌ها مشخص باشد، می‌توان فاصله از مرکز خوشه را اندازه گرفت. به علاوه این اندازه‌گیری فاصله، به صورت غیرخطی انجام می‌گیرد، لذا در صورتی که الگویی در ناحیه‌ی مجاور مرکز یک خوشه قرار داشته باشد، مقداری نزدیک به یک تولید می‌شود. در خارج از این ناحیه، مقدار بدست آمده به طور قابل ملاحظه‌ای کاهش می‌یابد. نکته مهم آن است که این ناحیه به صورت شعاعی در اطراف مرکز خوشه متقارن است، بنابراین تابع غیرخطی به صورت تابع شناخته شده‌ی شعاع مدار در می‌آید. معمولی‌ترین شکل تابع شعاع مدار به صورت زیر است:



شکل ۱: یک شبکه ساده **RBF**

مزایای زیادی برای شبکه عصبی **RBF** در مقایسه با پرسپترون‌های چند لایه عنوان شده است. این شبکه‌ها سریع‌تر از یک **MLP** آموزش داده می‌شوند و نیز محدوده‌های تصمیم‌گیری بهتری را ایجاد می‌کنند. مزیت دیگر شبکه‌های عصبی **RBF** این است که در این شبکه‌ها تعبیر و تفسیر لایه‌ی خروجی به مراتب آسان‌تر از یک **MLP** است. از سوی دیگر این شبکه‌ها نیازمند نرون‌های بیش‌تری نسبت به شبکه‌های استاندارد پیش‌خور با الگوریتم پس انتشار خطا می‌باشد ولی بیش‌تر این شبکه‌ها را می‌توان در زمانی کوتاه‌تر نسبت به زمان مورد نیاز برای شبکه‌های پیش‌خور، آموزش داد. همچنین شبکه‌های عصبی **RBF** از نظر تعداد توابع آموزشی و یادگیری و برخورداری بیش از یک لایه‌ی پنهان، در تجزیه و تحلیل و پیش‌بینی داده‌های سری زمانی نسبت به شبکه‌های **ANN**، قابلیت بالاتری دارند.

روش نقشه‌یابی بین بردار ورودی و بردار خروجی به صورت زیر بدست می‌آید

$$O = F(I) \quad (1)$$

I بردار ورودی، و $I = (x_1, x_2, \dots, x_m)$ است، O بردار خروجی و $O = (y_1, y_2, \dots, y_n)$ می‌باشد. F نقشه‌یابی غیر خطی بین I و O است. فرض کنید که تعداد گره‌ها در لایه پنهان، h است. برای نرون لایه ورودی، تنها یک اثر، انتقال سیگنال می‌باشد که به معنی وجود اوزان ارتباطی بین لایه ورودی و لایه پنهان است. با استفاده از تابع گوسی به صورت **RBF**، تابع فعال سازی به صورت زیر است

$$R(x_k - c_k) = \exp\left(-\frac{\|x_k - c_k\|^2}{2e_k^2}\right) \quad (2)$$

که $\|x_k - c_k\|$ و $k = 1, \dots, h$ و $i = 1, \dots, m$ و $x_i \in I$ به معنی قاعده اقلیدسی است، x_i مقدار ورودی گره ورودی i بوده و c_k مقدار مرکزی k گره پایه در لایه پنهان، σ واریانس تابع گوسی می باشد. تابع فعال سازی منعکس کننده شرایط فعال سازی نورون با تفاضل فاصله اقلیدسی به جای توابع فعال سازی خطی می باشد. از این روی مقادیر خروجی به صورت زیر است

$$y_j = \sum_{i=1}^m \omega_{kj} \exp\left(-\frac{\|x_i - c_k\|^2}{2e_k^2}\right) \quad (3)$$

که $j = 1, \dots, n$ و $y_j \in O$ و ω_{kj} وزنها ارتباطی بین نورون k در لایه پنهان و نورون j در لایه خروجی است. در واقع فرایند آموزش $RBFB$ ، واسنجی σ_k و c_k و ω_{kj} است. الگوریتم یادگیری $RBFB$ را می توان در منابع یافت.

۲-۴: $RBFB$ مورد استفاده در پیش بینی زمان ورود اتوبوس

به گفته جانگ و همکارانش در سال ۲۰۰۴، روابطی میان زمان مسافرت اتوبوس، زمان اقامت، تعداد مسافران، تاخیر و فاصله بین دو ایستگاه وجود دارد به علاوه، در طی آزمایش، نتایج نشان داد که سرعت اتوبوس منعکس کننده سطح ازدحام جاده می باشد و شرایط ازدحام بر زمان ورود یا رسیدن اتوبوس اثر دارد، در حالی که همبستگی بین زمان ورود و این عامل مشخص نیست. رگرسیون خطی، وابستگی های خطی را نشان می دهد که روابط غیر خطی پیشنهاد می شود. به این ترتیب فرضیات بین عوامل موثر و زمان رسیدن اتوبوس به شرح زیر است

$$D_M \propto P_M \quad (4)$$

$$T_M \propto S_M \quad (5)$$

$$T_M \propto Delay_M \quad (6)$$

$$Cong_M \rightarrow \frac{1}{V_M} \quad (7)$$

$$D_M + T_M \propto P_M, S_M, Delay_M, Cong_M \quad (8)$$

$$Y_M = T_M + D_M = F(P_M, S_M, Delay_M, V_M) \quad (9)$$

که T_M زمان رسیدن از ایستگاه M به ایستگاه $M+1$ ، D_M زمان انتظار در ایستگاه، S_M فاصله از ایستگاه M به ایستگاه $M+1$ می باشد و P_M تعداد مسافران ورودی و خروجی به اتوبوس در ایستگاه می باشد که بصورت

$$P_M = \max\{P_M^{on}, P_M^{off}\}$$

می باشد که در آن P_M^{on} بیانگر تعداد مسافر ان سوار شونده و P_M^{off} تعداد مسافر ان پیاده شونده می باشد. $Cong_M$ تاخیر کلی از ایستگاه M تا $M+1$ ، V_M سرعت مسافرت از ایستگاه M تا $M+1$ است، $Cong_M$ شاخص ازدحام بین دو ایستگاه و Y_M به معنی فاصله زمانی بین اتوبوس در ایستگاه M و $M+1$ است.

با این نوع مسئله تقریب غیر خطی پیشرفته، $RBFB$ استفاده می شود. به این ترتیب جمع اوری داده ها ی مطلوب $P_M, S_M, Delay_M, T_M, V_M$ و سازمان دهی آن ها به صورت مجموعه نمونه ها ساده است. سپس، مدل $RBFB$ را می توان آموزش داد.

واقعی را می‌شوند. در این مرحله، داده‌های اصلی و داده‌های تولید شده به صورت افلاین هستند و وقتی که نقشه تعیین شد، مدل تهیه نقشه قادر به بین ارتباط داده‌های منبع است که ساده تر از انجام تحلیل از طریق پایگاه دادهها مختلف می‌باشد. با این عوامل، می‌توان \widehat{T}_M را انتظار داشت.

۳- مدل تعدیل با استفاده از داده‌های آنلاین

داده‌های معیار صادره از اولین مرحله، پارامتر دوره زمانی است که به معنی زمان مسافرت در طی مرحله M تا $M+1$ می‌باشد. وقتی که کاربر آن درخواست زمان ورود اتوبوس می‌کنند، به طور کلی اتوبوس بایستی در مسیر در موارد مختلف باشد. از این روی می‌توان انتظار داشت که روش پیش‌بینی افلاین قادر به دست‌یابی به موقعیت فوری اتوبوس بر این آرایه یک زمان رسیدن دقیق نیست. در مرحله دوم، از یک روشی برای تعدیل داده‌های معیار با پارامترهای عملیاتی آنلاین استفاده می‌شود.

۳-۱ استفاده از فیلتر کالمن

سرعت زیاد وسایل نقلیه بر این نشان دادن وضعیت عملکرد زمان واقعی استفاده می‌شود که برای تعدیل معیار مفید است. $v(t|t)$ یک متغیر وضعیت t ام به معنی سرعت فوری است که t به صورت نقطه زمانی بوده و به این ترتیب طول T با اندازه گام زمانی I تعیین می‌شود و یک روش پیش‌بینی سرعت با فیلتر کالمن به صورت زیر آرایه می‌شود.

بدون بردار ورودی به سیستم، معادله تبدیل وضعیت سیستم و معادله تکرار کواریانس به صورت زیر است

$$v(t|t-1) = v(t-1|t-1) \quad (10)$$

$$P(t|t-1) = P(t-1|t-1) + Q \quad (11)$$

$$v(t|t) = v(t|t-1) + Kg(t) * (v_r - v(t|t-1)) \quad (12)$$

$$P(t|t) = (1 - Kg(t) * P(t|t-1)) \quad (13)$$

که در آن بهره کالمن به صورت زیر تعریف می‌شود

$$Kg(t) = \frac{P(t|t-1)}{P(t|t-1) + R} \quad (14)$$

که $v_r(t)$ سرعت مشاهده شده اتوبوس، $P(t|t)$ کواریانس و Q کواریانس در طی تبدیل سیستم است و r کواریانس مشاهده شده می‌باشد. ما از الگوریتم وزنی برای ترکیب داده‌های معیار با سرعت استفاده می‌کنیم. در ابتدا، زمان مسافرت \widehat{T}_M با زمان و سرعت v_M به صورت زیر محاسبه می‌کنیم

$$v_M = \frac{S_M}{\widehat{T}_M} \quad (15)$$

برای متغیر سرعت v_M^{aux} روش وزن دهی به صورت زیر بدست می‌آید

$$v_M^{aux} = \frac{a.v(t|t) + b.v_M}{a+b} \quad (16)$$

که a و b اوزان می‌باشند و $a = S_M^f$ به معنی طول مقطعی است که در ایستگاه M و $M+1$ قرار می‌گیرد. $b = S_M^1$ به معنی طول مقطعی است که بین ایستگاه M و $M+1$ قرار گرفته است به این ترتیب می‌توان آن را به صورت زیر اصلاح کرد

$$v_M^{aux} = \frac{S_M^f.v(t|t) + S_M^1.v_M}{S_M^f + S_M^1} \quad (17)$$

به این ترتیب می توان کشف کرد که با استفاده از وزنهای متغیر امکان بدست آوردن متغیر وابسته به وجود می آید. وقتی که اتوبوس نزدیک ایستگاه است v_M^{aux} بستگی به v_M دارد درحالی که ایستگاه نزدیک به $M+1$ است و v_M^{aux} وابسته به $v(t|t)$ می باشد

وقتی که اتوبوس در مقطع بین $M_1 - 1$ و M_1 قرار دارد، پیش بینی زمان مسافرت T_{pred} از محل زمان واقعی تا ایستگاه M_1 به صورت زیر بدست می آید

$$T_{pred} = \frac{S_{M_1-1}'}{v_{MO-1}^{aux}} + \sum_{M=M_1}^{M_1-1} \frac{S_M}{v_{M_1-1}^{aux}} + \sum_{M=M_1}^{M_1-1} D_M \quad (18)$$

۴ - طراحی سیستم

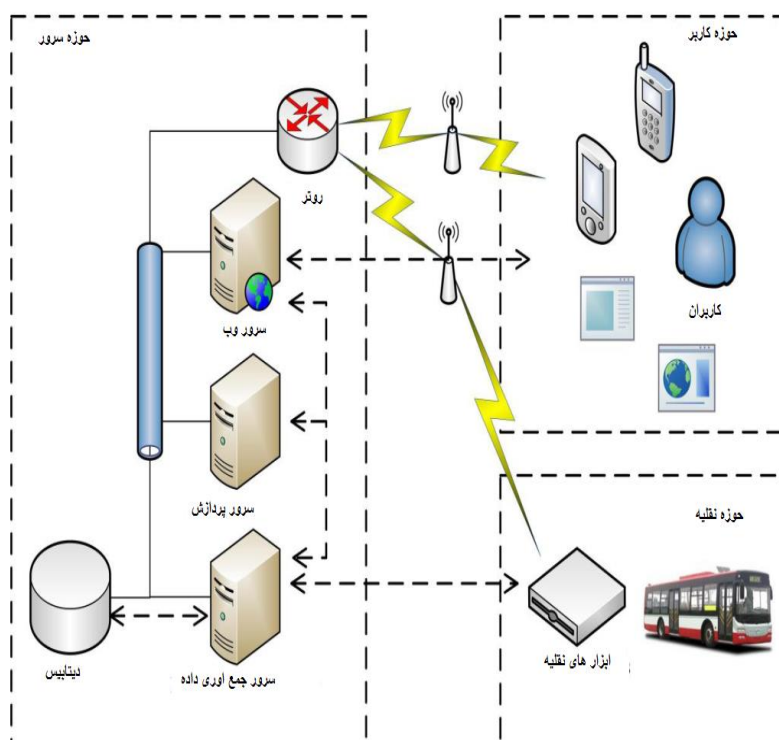
در این تحقیق، ما یک مجموعه از الگوی سیستم نرم افزار کامپیوتری را بر اساس روش پیش بینی زمان رسیدن اتوبوس توسعه داده ایم. ساختار سیستم در شکل ۴ نشان داده شده است. معرفی مختصری از هر یک از اجزا در زیر نشان داده شده است

حوزه سرور :

سرور جمع اوری داده ها: مدیریت حجم زیادی از داده ها از دستگاه های مختلف با پایگاه دادهها
وب سرور: پاسخ به سوالات یا درخواست های کاربر و مدیریت سایر درخواست های اطلاعاتی
سرور پردازش : استفاده از داده ها در پایگاه دادهها برای آموزش خود کار مدل و انجام پیش بینی آنلاین بر ای هر درخواست
حوزه وسایل نقلیه:

جمع اوری داده های عملیاتی اتوبوس ها و ارسال داده ها به سرور جمع اوری داده ها در زمان واقعی
حوزه کاربران:

چندین نوع رابط برای رفع درخواست بر ای اطلاعات پیش بینی زمان ورود اتوبوس از طریق اس ام اس، نرم افزار های تلفن همراه و مرورگرهای وب که توسط وب سرور مدیریت می شود، حفظ می گردد




شکل ۴: طراحی ساختار سیستم

۵- مطالعه آزمایشی



اتوبوس شماره ۲۱ در دالیان به صورت مسیر آزمایشی بر ای جمع اوری داده های پایه انتخاب شد. چون رابط داده های پایشی بر ای همه باز نبوده است ما از وسایل نقلیه این سیستم استفاده کردیم.

داده های یک هفته ای ذخیره شده و در پایگاه دادهها قرار گرفت و سپس بر ای آموزش مدل های RBF استفاده گردید. ما از ۳ تلفن هوشمند استفاده کردیم که نرم افزاری را بر ای تایید اثر پیش بینی ارایه می کند. ۹۰ مجموعه از درخواست های پیش بینی تصادفی پردازش شده و نتایج پیش بینی زمان مسافرت ارایه شده است. با ثبت زمان عملیات واقعی از موقعیت تعیین نشده، که در آن درخواست پیش بینی ارسال شده و پاسخ نتایج پیش بینی دریافت شده است، اثر بخشی و کارایی این روش توسط خطای باقی مانده و خطای نسبی هر درخواست ارزیابی شد. اندازه گیری صحت هر رویکرد، خطای درصد مطلق میانگین می باشد. به علاوه مدل رگرسیون خطی چندگانه، شبکه های عصبی BP و RBF بدون تعدیل آنلاین به صورت مقایسه استفاده می شود.


خطای پیش بینی RBF بدون رویکرد تعدیل آنلاین در شکل ۵ نشان داده شده و خطای پیش بینی RBF با رویکرد تعدیل آنلاین در شکل ۶ نشان داده شده است که در آن ها عرض از مبدا نشان دهنده زمان مسافرت مشاهده شده در الف و ب می باشد. شکل ۵ الف نشان می دهد که نقاط به صورت قطری پراکنده است، اگرچه نقاط در شکل ۶ الف مطابق موارد مختلف است. خطای باقی مانده RBF تعدیل نشده از ۱۰۰- تا ۱۰۰+ متغیر است، در حالی که RBF تعدیل شده در ۵۰- تا ۵۰+ توزیع می شود. این نشان می دهد که مدل RBF دارای صحت بهتری از RBF بدون تعدیل است
ما MLR و $BPNN$ را بدون تعدیل آنلاین مقایسه کرده و RBF با تعدیل آنلاین توسط خطای نسبی $MAPE$ مقایسه می شود. بر ای رویکرد های بدون تعدیل آنلاین، زمان مسافرت از موقعیت اتوبوس به ایستگاه بعدی با روش میان یابی محاسبه گردید. رویکرد RBF تعدیل شده با خطاهای نسبی و $MAPE$ تعیین شد

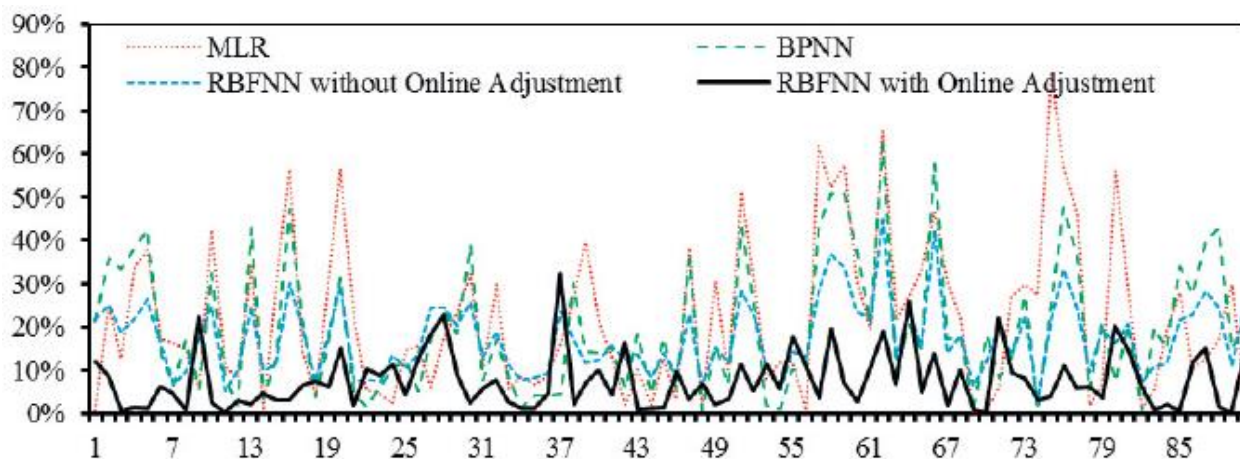


شکل ۵: خطای پیش بینی $BPNN$ بدون تعدیل آنلاین



شکل ۶: خطای پیش بینی RBF با تعدیل آنلاین





شکل ۷: تشابه میان MLR, BPNN و RBF با تعدیل آنلاین

جدول ۱: مقایسه رویکرد ها با MAPE

	MLR	BPNN	RBFNN	Adjusted RBFNN
MAPE	22.87%	17.41%	15.98%	7.59%

۶- نتیجه گیری

این مقاله رویکردی را مطرح می کند که ترکیبی از داده های مطلوب و اطلاعات زمان واقعی برای پیش بینی زمان رسیدن اتوبوس می باشد. این رویکرد شامل دو مرحله است. اولاً، مدل شبکه های عصبی براساس تابع پایه شعاعی (RBF) برای تقریب رابطه غیر خطی در داده های مطلوب، سپس در دومین مرحله، یک روش آنلاین برای تعدیل وضعیت واقعی معرفی می شود. در ادامه یک مطالعه آزمایشی بر روی مسیر شماره ۲۱ اتوبوس در دالیان با استقرار این سیستم برای اثبات اعتبار و اثر بخشی این رویکرد انجام شد. به علاوه، مدل رگرسیون خطی چندگانه، شبکه های عصبی BP و RBF بدون تعدیل آنلاین استفاده می شود. نتایج نشان می دهد که رویکرد با RBF و تعدیل آنلاین دارای عملکرد پیش بینی بهتری است.

به عنوان بخشی از فنون اطلاعاتی، پیشنهاد و انتشار اطلاعات صحیح زمان رسیدن اتوبوس از اهمیت زیادی برای برنامه ریزی زمان مسافرت و کاهش انتظار برخوردار است. اگرچه تعداد جدیدی از رویکرد های پیش بینی شده با تحلیل صحت در این مقاله پیشنهاد شده است و اطمینان پذیری نتایج پیش بینی و وضعیت عملیات اتوبوس می تواند به مسافر ان بگوید که آیا آنها باید اعتماد کنند یا خیر. در نهایت ما یک سیستم اطلاعات یکپارچه را پیشنهاد کردیم که شامل پیش بینی زمان رسیدن، پایش عملیات اتوبوس، مسیر اتوبوس و انتقال اطلاعات به صورت زیر سیستم ها بوده است و یک ماژول مفید و منحصر به فرد در پلتفرم اطلاعات انتقال شهری است.

References

- [1] Biagioni, J., Gerlich, T., Merrifield, T., & Eriksson, J. (2011). Easytracker: automatic transit tracking, mapping, and arrival time prediction using smartphones. In *Proceedings of the 9th ACM Conference on Embedded Networked Sensor Systems* (pp. 68-81). ACM.
- [2] Jeong, R., & Rilett, R. (2004). Bus arrival time prediction using artificial neural network model. In *Intelligent Transportation Systems, 2004. Proceedings. The 7th International IEEE Conference on* (pp. 988-993). IEEE.
- [3] Kalman, R. E. (1960). A new approach to linear filtering and prediction problems. *Journal of basic Engineering*, 82,35-45.

- [4] Lin, Y., Yang, X., Zou, N., & Jia, L. (2013). Real-Time bus arrival time prediction: A case study for Jinan, China. *Journal of Transportation Engineering*, 139, 1133-1140.
- [5] Lin, W. H., & Zeng, J. (1999). Experimental study of real-time bus arrival time prediction with GPS data. *Transportation Research Record: Journal of the Transportation Research Board*, 1666, 101-109.
- [6] Lu Y.W., Sundararajan N., & Saratchandran P. (1998). Performance evaluation of a sequential minimal radial basis function (RBF) neural network learning algorithm. *Neural Networks, IEEE Transactions on*, 9, 308 - 318.
- [7] Park, J., & Sandberg, I. W. (1991). Universal approximation using radial-basis-function networks. *Neural Computation*, 3, 246-257.
- [8] Yu, B., Lam, W. H., & Tam, M. L. (2011). Bus arrival time prediction at bus stop with multiple routes. *Transportation Research Part C: Emerging Technologies*, 19, 1157-1170.
- [9] Yu, B., Yang, Z. Z., & Zeng, Q. C. (2008). Bus arrival time prediction model based on support vector machine and kalman filter. *China Journal of Highway and Transport*, 21, 89-90.
- [10] Zhou, P., Zheng, Y., & Li, M. (2012). How long to wait?: Predicting bus arrival time with mobile phone based participatory sensing. In *Proceedings of the 10th international conference on Mobile systems, applications, and services* (pp. 379-392). ACM.
- [11] Zhu, T., Ma, F., Ma, T., & Li, C. (2011). The prediction of bus arrival time using global positioning system data and dynamic traffic information. In *Wireless and Mobile Networking Conference (WMNC), 2011 4th Joint IFIP* (pp. 1-5) IEEE..