

## شناسایی خودکار نوع وسیله‌ی سفر از داده‌های GPS وسایل همراه با استفاده از شبکه‌ی عصبی-فازی

الهه خزاعی<sup>۱\*</sup>، علی اصغر آل شیخ<sup>۲</sup>، محمد کریمی<sup>۳</sup>

۱- دانشجوی دکترای GIS، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه‌نصیرالدین طوسی، تهران

۲- استاد، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه‌نصیرالدین طوسی، تهران

۳- استادیار، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه‌نصیرالدین طوسی، تهران

تاریخ دریافت مقاله: ۱۳۹۴/۵/۴ تاریخ پذیرش مقاله: ۱۳۹۵/۳/۱۳

### چکیده

تعیین نوع و تقاضای سفر اهمیت زیادی در سازمان‌های حمل و نقل هر کشور دارد. با تشخیص دقیق نوع وسیله‌ی سفر هر کاربر، امکان ارائه‌ی تصویر واقعی‌تری از تقاضای سفر فراهم می‌شود. همچنین در سرویس‌های مکان‌مبنا دانستن نوع وسیله‌ی سفر برای فرستادن تبلیغات هدفمند کاربرد دارد. در این تحقیق به منظور استخراج خودکار نوع وسیله‌ی سفر از شبکه‌ی عصبی-فازی و داده‌های سیستم تعیین موقعیت جهانی (GPS) وسیله‌ی همراه استفاده شده است. دانش مورد نیاز در قالب قوانین فازی از داده‌ها استخراج گردید و سپس با استفاده از این قوانین نوع وسیله‌ی سفر تعیین شد. در دو حالت مدل پیشنهادی مورد بررسی قرار گرفت. در حالت اول از کل داده‌های GPS به دست آمده از وسایل همراه برای تعیین نوع وسیله‌ی سفر استفاده گردید و در حالت دوم به منظور کاهش تعداد داده‌های مورد نیاز از وسیله‌ی همراه GPS دار، الگوریتم نقاط بحرانی به کار گرفته شد. به کارگیری این الگوریتم علاوه بر کاهش هزینه‌های جمع‌آوری داده، باعث حفظ منابع وسیله‌ی همراه از قبیل عمر باتری می‌گردد. نتایج حاکی از این است که مدل پیشنهادی در حالت استفاده از کل داده‌ها با دقت ۹۴/۱٪ و در حالت استفاده از نقاط بحرانی با دقت ۹۵/۵٪ قابلیت شناسایی نوع وسیله‌ی سفر را دارا می‌باشد.

کلید واژه‌ها: شبکه‌ی عصبی-فازی، شناسایی نوع وسیله‌ی سفر، نقاط بحرانی، داده‌های GPS.

\*نویسنده مکاتبه کننده: خیابان ولیعصر، تقاطع میرداماد، دانشگاه صنعتی خواجه نصیرالدین طوسی، دانشکده مهندسی نقشه‌برداری.

تلفن: ۰۹۳۵۴۲۸۱۵۰۰

## ۱- مقدمه

سازمان‌های برنامه‌ریزی منطقه‌ای سال‌ها است که به بررسی سفرهای روزانه با هدف به‌دست آوردن داده‌های مورد نیاز برای ساخت مدل حمل و نقل می‌پردازند [۱]. بررسی سفرها ابزار مهمی را در اختیار متخصصان حمل و نقل برای برنامه‌ریزی، طراحی، ارزیابی و نگهداری سیستم حمل و نقل قرار می‌دهد [۲، ۳]. با تشخیص دقیق نوع سفر هر کاربر، امکان ارائه‌ی تصویر واقعی‌تری از تقاضای سفر فراهم می‌شود [۴].

از زمینه‌های مهم تحقیقاتی در سامانه‌های فراگستر<sup>۱</sup> و محاسبات محیط آگاه<sup>۲</sup> درک تحرک کاربر از داده‌های سنجنده‌ها است. نوع وسیله‌ی حمل و نقل از قبیل پیاده و ماشین سواری می‌تواند بعضی از مشخصه‌های محیط کاربر متحرک را تعیین نماید و با استفاده از آن سرویس‌های متناسب به کاربر ارائه گردد [۴].

پیاده‌سازی فناوری‌های تعیین موقعیت دقیق در تلفن‌های همراه منجر به ایجاد برنامه‌های کاربردی شده که به‌عنوان سرویس‌های مکان‌مبنای<sup>۳</sup> (LBS) شناخته می‌شوند. در این سرویس‌ها از مکان دستگاه و داده‌های دیگر، برای ایجاد برنامه‌های مکان آگاه<sup>۴</sup> استفاده می‌شود [۵]. تبلیغات و بازاریابی نمونه‌ای از کاربردهای سرویس‌های مکان‌مبنا هستند که می‌توان به آن اشاره نمود. بنابراین با دانستن نوع وسیله‌ی سفر می‌توان تبلیغات هدفمند و سفارشی را به تلفن همراه مسافر ارسال نمود [۴].

بررسی سفر در فرمت‌های مختلفی از قبیل فرم، ثبت کاغذی، مصاحبه تلفنی و یا با کمک

سیستم تعیین موقعیت جهانی (GPS)<sup>۵</sup> وسیله‌ی نقلیه صورت می‌گیرد. به علت اینکه داده‌هایی مانند زمان سفر، مکان و فاصله‌های ثبت شده توسط این روش‌ها، بعد از سفر جمع‌آوری می‌گردند، دقت مناسبی را دارا نمی‌باشند. داده‌های جمع‌آوری شده با خودرو دارای GPS، قابلیت اطمینان بیشتری دارد ولی نمی‌تواند برای حالت‌های مختلف حمل و نقل از جمله حالت پیاده، دوچرخه‌سواری و حمل و نقل عمومی مورد استفاده قرار گیرد. به‌علاوه سفر مربوط به یک خودرو در آن بدون در نظر گرفتن کاربر آن ثبت می‌شود. مدل دقیق تقاضای سفر باید تمام حالت‌های مختلف حمل و نقل مورد استفاده را شامل شود [۶]. GPS می‌تواند مکان دقیق، زمان و اطلاعات سرعت را ثبت کند ولی نمی‌تواند تمام پارامترهای مورد نیاز یک مدل حمل و نقل را ثبت نماید. برای مثال نوع وسیله‌ی سفر با GPS ثبت نمی‌شود ولی می‌توان آن را تا حدودی از داده‌های GPS استخراج نمود [۶].

مطالعاتی که هدفشان استنتاج حالت سفر باشد را می‌توان به دو دسته‌ی روش‌های رویه‌ای<sup>۶</sup> و یادگیری ماشین تقسیم‌بندی نمود [۷]. در روش‌های رویه‌ای تلاش عمدتاً به استنتاج بر اساس مفروضات منطقی است؛ مانند این که چگونه یک شخص معمولی ممکن است سفر کند. مثال دیگر می‌تواند مفروضاتی از قبیل نزدیک‌ترین شبکه‌ی حمل و نقل که محیط اطراف را در بر می‌گیرد باشد. در روش‌های یادگیری ماشین، تلاش برای استنتاج بر اساس یادگیری از داده‌های موجود است که احتمالاً با پیش‌فرض‌های منطقی مشابه ترکیب شده‌اند [۷]. نمونه‌هایی از این مطالعات عبارتند از: درخت تصمیم‌گیری [۸، ۹]، منطق فازی [۱۰، ۱۱]،

<sup>1</sup> Ubiquitous<sup>2</sup> Context aware<sup>3</sup> Location Based services<sup>4</sup> Location aware<sup>5</sup> Global Positioning System<sup>6</sup> Procedural

برای داده‌های تست به‌دست آوردند. داده‌های به‌کارگرفته‌شده برای این تحقیق از ۱۶۵۴ قطعه تشکیل شده است. این تحقیق نشان داد که دقت تشخیص نوع وسیله‌ی سفر با استفاده از این روش از روش‌های لوجیت چندگانه، ماشین بردار پشتیبانی و شبکه‌ی عصبی بیشتر است [۱۵]. متأسفانه دانشی که شبکه‌ی عصبی در مورد مسائل به‌دست می‌آورد، به‌صورت وزن ارتباطات است که بزرگی آن‌ها پس از آموزش ثابت می‌شود. تصمیم‌گیری بر اساس جعبه‌ی سیاه که دانش آن قابل تفسیر نمودن نیست در خیلی از امور امکان‌پذیر نیست. در این تحقیقات ذکر شده پارامترهایی منتج از سرعت، شتاب، فاصله و کیفیت داده‌ها برای تشخیص نوع وسیله‌ی سفر مورد استفاده قرار گرفته است.

به‌دلیل وجود عدم قطعیت در اکثر موجودیت‌های مکانی، نیاز به روشی است که با در نظر گرفتن عدم قطعیت توانایی یادگیری و استنتاج را داشته باشد. یک سیستم فازی با استفاده از قواعد استنتاج فازی و با در نظر گرفتن عدم قطعیت قادر به ارائه‌ی تصمیم‌گیری و پاسخ می‌باشد. تعیین فرم مناسب این قواعد می‌تواند به سیستم توانایی لازم برای تصمیم‌گیری را بدهد [۱۶]. توسعه محاسبات نرم به تلفیق روش‌های هوش مصنوعی از قبیل شبکه‌ی عصبی و سیستم استنتاج فازی کمک کرده است. منطق فازی فرایند استنتاج را تحت عدم قطعیت میسر می‌سازد و شبکه‌ی عصبی نیز قابلیت‌هایی از قبیل یادگیری، انطباق و پردازش موازی را دارا می‌باشد. سیستم ترکیبی شبکه فازی عصبی نامیده می‌شود [۷]. تحقیقات زیادی برای تلفیق قابلیت یادگیری شبکه‌ی عصبی با سیستم استنتاج فازی به‌منظور استخراج قوانین اولیه‌ی سیستم فازی و بهینه کردن توابع عضویت صورت گرفته است [۱۹، ۱۸، ۱۷].

شبکه بیزی<sup>۱</sup> [۴]، شبکه‌ی عصبی [۵]، ماشین بردار پشتیبان (SVM)<sup>۲</sup> [۷] و مدل مارکوف [۱۲].

الگوریتم‌های یادگیری ماشین را می‌توان به سه مرحله تقسیم‌بندی نمود: جمع‌آوری داده‌ها، انتخاب متغیرها برای استنتاج، انتخاب الگوریتم مورد استفاده [۷]. ژنگ<sup>۳</sup> و همکاران [۸] داده‌های موقعیت GPS ۶۵ نفر را برای ۱۰ ماه جمع‌آوری نمودند و با به‌کارگیری درخت تصمیم‌گیری ۷۵/۶٪ از نوع وسیله سفرها را به‌درستی برآورد کردند. رودلاف و ری<sup>۴</sup> [۱۳] ۷۹۲ خط سیر را به داده‌های تست و آموزش تقسیم نمودند و از شبکه پرسپترون چند لایه‌ای برای تعیین نوع وسیله‌ی سفر استفاده کردند. نتایج ایشان حاکی از درستی تشخیص ۸۲/۷٪ بود. بلبل<sup>۵</sup> و همکاران [۷] با جمع‌آوری داده‌های موقعیت GPS ۸۱ نفر به مدت دو هفته و استفاده از ماشین بردار پشتیبانی دقت ۸۸٪ برای شناسایی نوع سفر را به‌دست آوردند. برچ<sup>۶</sup> و همکاران از مدل لوجیت چندگانه<sup>۷</sup> [۱۴] برای تشخیص پیاده، دوچرخه، ماشین و اتوبوس استفاده نمودند. داده‌های مورد استفاده، متشکل از ۹۲۶ قطعه بوده است و ۹۰/۸٪ از سفرها را به‌درستی برچسب زدند. گنزالز<sup>۸</sup> و همکاران [۵] داده‌های مکانی ۱۱۴ سفر را با استفاده از گوشی همراه جمع‌آوری نموده و با به‌کارگیری شبکه‌ی عصبی به دقت ۹۱/۲۳٪ برای تشخیص نوع وسیله‌ی سفر رسیدند. اکسیا<sup>۹</sup> و همکاران [۱۵] از ترکیب شبکه‌ی عصبی و بهینه‌سازی ازدحام ذرات<sup>۱۰</sup> برای بهبود دقت تشخیص نوع سفر استفاده نمودند و دقت ۹۴/۴۴٪

<sup>1</sup> Bayesian network

<sup>2</sup> Support Vector Machine

<sup>3</sup> Zheng

<sup>4</sup> Rudloff and Ray

<sup>5</sup> Bolbol

<sup>6</sup> Broach

<sup>7</sup> Multinomial logit

<sup>8</sup> Gonzalez

<sup>9</sup> Xiao

<sup>10</sup> Particle Swarm Optimization (PSO)

آستانه‌ی کمترین سرعت برای پالایش داده‌هایی است که در هنگامی که وسیله در حرکت نباشد، تولید می‌شود [۲۱].

الگوریتم نقاط بحرانی متفاوت از فاصله‌ی بروز رسانی ثابت<sup>۲</sup> است. در فاصله‌ی بروز رسانی ثابت موقعیت هر  $X$  ثانیه بدون در نظر گرفتن اینکه اطلاعات موقعیت به دانش از مسیر کاربر کمی می‌کند، گزارش می‌شود که با استفاده از این روش مکان‌های تصادفی از مسیر به دست می‌آید. ولی در الگوریتم نقاط بحرانی بروزرسانی داده‌ها بدون در نظر گرفتن فاصله زمانی مشخص صورت می‌پذیرد و به‌گونه‌ای است که مکان‌های مهم مسیر را فراهم می‌آورد. این الگوریتم مانند مفهوم "ساده‌سازی خط"<sup>۳</sup> در GIS است [۲۰]. شکل (۱) تمام داده‌های GPS جمع‌آوری شده در طول سفر با ماشین و شکل (۲) داده‌های GPS باقیمانده پس از اعمال الگوریتم نقاط بحرانی را نمایش می‌دهند.



شکل ۱: تمام نقاط GPS در مسیر سفر [۵]



شکل ۲: نقاط بحرانی در مسیر سفر [۵]

مشارکت اصلی این تحقیق، بهره‌گیری از شبکه‌ی فازی-عصبی در استخراج خودکار دانش حاکم بر محیط در قالب قوانین فازی برای پیش‌بینی نوع وسیله‌ی سفر است. استخراج خودکار پایگاه دانش فازی این توانایی را به سیستم می‌دهد که بدون نیاز به کاربر خبره به تحلیل و تصمیم‌گیری بپردازد. شایان ذکر است که پیش از این، از شبکه عصبی-فازی برای شناسایی نوع وسیله‌ی سفر و استخراج قوانین فازی استفاده نگردیده است. برای این منظور در دو مدل قوانین استخراج گردید. در مدل اول برای شناسایی نوع وسیله‌ی سفر، کل داده‌های GPS جمع‌آوری شده و در مدل دیگر داده‌های GPS کمتری که با استفاده از الگوریتم نقاط بحرانی استخراج شده‌اند، به‌کار گرفته شده است. در ادامه چگونگی انجام این کار شرح داده شده است.

## ۲- مواد و روش بررسی

در این بخش ابتدا با توضیح کوتاهی در مورد نقاط بحرانی و تئوری شبکه‌ی عصبی-فازی، به بیان مراحل اجرا و پیاده‌سازی مدل توسعه داده شده پرداخته می‌شود.

### ۲-۱- نقاط بحرانی

الگوریتم نقاط بحرانی<sup>۱</sup> به‌منظور کاهش حجم داده‌های غیر ضروری انتقال داده شده از وسیله‌ی همراه به سرور و همچنین کاهش مصرف انرژی باتری و هزینه‌های مالی توسعه داده شده است. با استفاده از این الگوریتم فقط داده‌های GPS مورد نیاز برای بازسازی نمایش دقیق مسیر کاربر، به سرور انتقال داده می‌شود [۲۰]. بر اساس این الگوریتم، نقاط اول و آخر سفر و همچنین هر نقطه‌ای که تغییر جهت قابل توجهی از نقطه‌ی بحرانی قبلی داشته باشد و همچنین سرعت آن بیشتر از کمترین سرعت تعیین شده باشد، به‌عنوان نقطه‌ی بحرانی در نظر گرفته می‌شود.

<sup>2</sup> Fixed update interval

<sup>3</sup> Line simplification

<sup>1</sup> Critical point

## ۲-۲- تئوری شبکه‌ی عصبی-فازی

تمام تکنیک‌های ترکیبی شبکه عصبی و سیستم‌های فازی، شبکه عصبی فازی نامیده می‌شود. ترکیب‌های مختلف این تکنیک‌ها، سیستم‌های متفاوتی از قبیل سیستم‌های عصبی فازی مشارکتی، هم‌زمان و ترکیبی را به وجود آورده است [۲۲]. در ادامه روش معمول توسعه‌ی سیستم‌های عصبی-فازی ترکیبی که در این تحقیق مورد استفاده قرار می‌گیرد، ارائه می‌شود.

سیستم استنتاج عصبی-فازی تطبیقی (ANFIS<sup>۱</sup>): این سیستم در سال ۱۹۹۳ توسط جنگ<sup>۲</sup> معرفی شد که برای اجرای سیستم فازی سوگنو در ساختار شبکه عصبی استفاده می‌شود [۱۹]. قانون‌ها در این شبکه‌ها باید مشخص باشند و تنها توابع عضویت مقدم و مؤخر قانون را مشخص می‌کنند. این مدل دارای ۵ لایه است که عملکرد این لایه‌ها را مختصراً می‌توان به صورت زیر بیان کرد:

لایه ۱: توابع عضویت متغیرهای ورودی که به عنوان تابع گره است را شامل می‌شود.

لایه ۲: هر گره در این لایه به گره‌هایی که نمایش دهنده‌ی پیش فرض‌های قانون موردنظر است وصل می‌شود. هر گره در این لایه گره ثابتی است که در آن سیگنال‌های ورودی در هم ضرب می‌شوند و وزن یک قانون را بیرون می‌فرستد.

لایه ۳: هر گره در این لایه عمل محاسبه‌ی وزن نسبی قوانین را انجام می‌دهد.

لایه ۴: هر گره در این لایه دارای تابع گره می‌باشد که به تمام ورودی‌ها و یک گره در لایه‌ی سوم متصل است. (تابع گره در این سیستم ترکیب خطی متشکل از تمام ورودی‌ها می‌باشد).

لایه ۵: هر گره در این لایه گره ثابت است و وظیفه‌ی جمع‌بندی تمام خروجی قوانین را دارد.


روش‌های مختلفی برای تغییر و بهینه‌سازی پارامترهای این مدل وجود دارد. مثلاً استفاده از روش پس انتشار خطا برای برآورد کلیه‌ی پارامترها، روش پس انتشار خطا و یک عبور، روش کمترین مربعات برای تخمین اولیه پارامترهای نتیجه، ترکیب روش پس انتشار خطا و کمترین مربعات که در آن در عبور به جلو پارامترهای نتیجه با روش کمترین مربعات و در عبور به عقب از پس انتشار خطا برای تخمین پارامترهای مقدمه استفاده می‌گردد [۱۹].

با توجه به توضیحات داده‌شده، به‌طور کلی ساختار عمومی سیستم استنتاج عصبی-فازی تطبیقی را می‌توان به صورت شکل (۳) نمایش داد. در شکل (۳) این ساختار برای سه متغیر ورودی و برای هر متغیر، سه تابع عضویت رسم شده است.

همان‌طور که بیان شد، در سیستم استنتاج عصبی-فازی تطبیقی، قانون‌ها و توابع عضویت اولیه باید مشخص باشد و این سیستم فقط پارامترهای توابع عضویت را بهینه می‌کند. برای تعیین قانون‌ها و توابع عضویت اولیه از داده‌ها (بدون دانش کارشناسی) روش‌های متفاوتی وجود دارد که در این تحقیق از روش خوشه‌بندی کاهشی، و تقسیم‌بندی گریدی استفاده شده است. همچنین در روش‌های خوشه‌بندی امکان ایجاد توابع عضویت با همپوشانی زیاد وجود دارد که با استفاده از روش کاهش تعداد توابع عضویت برای هر متغیر، تفسیرپذیری قوانین بهبود یافت. در ادامه هر یک از موارد فوق به اختصار تشریح می‌شود.

<sup>۱</sup> Adaptive Neuro - Fuzzy Inference System

<sup>۲</sup> Jang



شکل ۳: ساختار کلی سیستم استنتاج عصبی-فازی تطبیقی

### ۲-۳- روش خوشه‌بندی کاهشی<sup>۱</sup>

خوشه‌بندی کاهشی یکی از روش‌های معمول ایجاد قوانین فازی اولیه می‌باشد. در این الگوریتم هر نقطه به‌عنوان یک پتانسیل برای مرکز خوشه در نظر گرفته می‌شود. پتانسیل تخصیص داده‌شده به مرکز هر خوشه به فاصله‌ی آن از نقاط دیگر وابسته است. بعد از محاسبه پتانسیل برای هر نقطه، نقطه‌ای که دارای بالاترین پتانسیل است به‌عنوان مرکز خوشه انتخاب می‌شود. پس از آن، اندازه پتانسیل هر نقطه تصحیح می‌شود، به طوری که پتانسیل داده‌هایی که نزدیک اولین مرکز خوشه هستند به‌طور قابل‌توجهی کاهش می‌یابد [۲۳]. پس از تصحیح پتانسیل، مرکز خوشه‌ی بعدی با دارا بودن بیشترین پتانسیل انتخاب می‌شود. روند اخذ خوشه‌ی جدید و تصحیح پتانسیل تا وقتی ادامه پیدا می‌کند که پتانسیل تمام نقاط زیر کسری از پتانسیل مرکز اولین خوشه باشد. حاصل خوشه‌بندی فازی،  $k$  مرکز خوشه به ابعاد مجموع تعداد متغیرهای ورودی و خروجی است. برای هر خوشه یک قانون تعریف می‌شود که رفتار سیستم را نشان می‌دهد [۲۴].

<sup>۱</sup> Subtractive clustering

### ۲-۴- روش تقسیم‌بندی گریدی

روش تقسیم‌بندی گریدی دارای ساختار گریدی می‌باشد. تفسیرپذیری این روش آسان است و به‌طور گسترده برای ایجاد قوانین فازی استفاده می‌شود. این روش برای تقسیم‌بندی فضای ورودی مورد استفاده قرار می‌گیرد و در سیستم فازی سوگونو کاربرد دارد. مشکل اساسی آن این است که با افزایش تعداد متغیرهای ورودی، تعداد قوانین به‌صورت نمایی افزایش می‌یابد. برای هر قانون تعدادی پارامتر باید بهینه شود که با افزایش تعداد متغیرها تعداد پارامترهای زیادی در الگوریتم‌های یادگیری باید بهینه شوند. تعداد زیاد قوانین فازی تفسیرپذیری سیستم را کاهش می‌دهد. بنابراین، این روش برای مجموعه داده‌ها با ابعاد کم و پوشش خوب مناسب است [۲۵].

### ۲-۵- کاهش تعداد توابع عضویت برای هر متغیر و ساده‌سازی قوانین

در روش‌های خوشه‌بندی، امکان ایجاد توابع عضویت با همپوشانی زیاد برای یک متغیر وجود دارد که این توابع عضویت تفسیرپذیری قوانین را کاهش می‌دهند (شکل (۴))؛ بنابراین برای حذف این توابع عضویت از رابطه (۱) استفاده می‌شود [۲۶، ۲۷]:

برای تبدیل طبقه‌بندی چند کلاسی به مجموعه‌ای از طبقه‌بندی باینری اشاره نمود [۲۸].

با توجه به اینکه شبکه‌ی فازی-عصبی ایجاد شده دارای یک خروجی است می‌توان مسئله را به چند مسئله‌ی باینری تبدیل کرد و سپس بر اساس خروجی‌ها، کلاس داده‌ی مربوطه را مشخص نمود. در این تحقیق از روش یکی در مقابل همه<sup>۵</sup> برای طبقه‌بندی چند کلاسی استفاده شده است. این روش ساده‌ترین روش تبدیل مسئله‌ی طبقه‌بندی میان  $k$  کلاس به  $k$  مسئله‌ی باینری است به طوری که هر مسئله یک کلاس مشخص را از بقیه‌ی کلاس‌ها متمایز می‌سازد. وقتی داده‌ای که کلاس آن معلوم نیست وارد فرآیند کلاسه‌بندی شود، برچسب آن مربوط به کلاسی می‌شود که بیشینه خروجی را دارا باشد.


### ۳- روش کار

در این تحقیق از شبکه‌ی عصبی-فازی برای استخراج قوانین فازی مورد نیاز برای شناسایی نوع وسیله‌ی سفر استفاده شده است. در این قسمت مراحل اجرا و پیاده‌سازی مدل ارائه شده تشریح می‌گردد. در شکل (۵-الف) چارچوب کلی این مدل برای به دست آوردن قوانین و در شکل (۵-ب) چگونگی شناسایی نوع وسیله سفر آورده شده است. همان‌طور که در شکل (۵-الف) مشاهده می‌شود، ابتدا با استفاده از روش‌های استخراج قوانین فازی (خوشه‌بندی کاهشی و تقسیم‌بندی گریدی)، قوانین فازی استخراج می‌گردد و سپس با استفاده از ANFIS قوانین فازی بهینه می‌گردند. به این ترتیب قوانین فازی برای شناسایی یک نوع وسیله‌ی نقلیه تعیین می‌گردد. پس از تکرار این روش قوانین فازی برای شناسایی هر نوع وسیله نقلیه ایجاد می‌شود. در شکل (۵-ب) با استفاده از روش طبقه‌بندی چند کلاسی نوع وسیله‌ی سفر مشخص می‌گردد.

<sup>5</sup> One-Versus-All (OVA)

$$S(A_{ij}, A_{kj}) = \frac{\sum_{l=1}^L \min\{u_{ij}(x_{jl}), u_{kj}(x_{jl})\}}{\sum_{l=1}^L \max\{u_{ij}(x_{jl}), u_{kj}(x_{jl})\}} \quad (1)$$

در این رابطه  $z$  نشان‌دهنده‌ی هر متغیر،  $i$  و  $k$  نشان‌دهنده تابع عضویت آن متغیر،  $l$  نمایانگر داده‌های آن متغیر و  $S$  میزان همپوشانی توابع عضویت می‌باشد.  $\lambda$  را مقداری بین  $0/6$  تا  $0/85$  تعریف می‌کنند و اگر مقدار  $S > \lambda$  باشد، آن دو تابع عضویت دارای همپوشانی زیادی هستند و تابع عضویت جدیدی با میانگین‌گیری پارامترهای آن دو تابع عضویت، جایگزین آن دو مجموعه‌ی فازی می‌شود. بدین ترتیب بدون اینکه دقت تغییر محسوسی کند، تفسیرپذیری قانون افزایش می‌یابد [۲۷].



شکل ۴: توابع عضویت اضافی که به وسیله‌ی خوشه‌بندی به وجود می‌آید [۲۶]

### ۲-۶- روش‌های طبقه‌بندی چند کلاسی<sup>۱</sup>

الگوریتم‌های طبقه‌بندی نظارت‌شده به ایجاد مدل یادگیری از داده‌های آموزشی برچسب خورده می‌پردازد. الگوریتم‌های مختلفی برای طبقه‌بندی چند کلاسی پیشنهاد شده که از میان آن‌ها می‌توان به درخت تصمیم‌گیری<sup>۲</sup>، شبکه‌ی عصبی، نزدیک‌ترین همسایه<sup>۳</sup>، طبقه‌بندی پایه بی‌زی<sup>۴</sup>، ماشین بردار پشتیبان و همچنین روش‌هایی


<sup>1</sup> Multiclass Classification

<sup>2</sup> Decision Trees

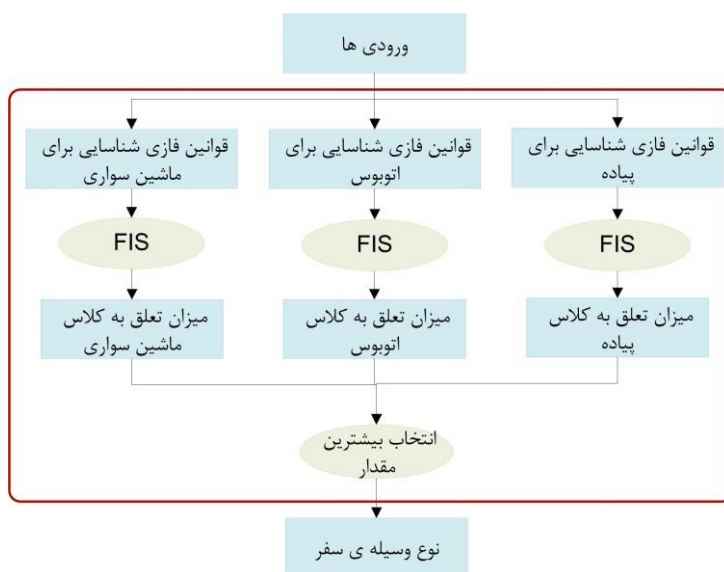
<sup>3</sup> K-Nearest Neighbor

<sup>4</sup> Naive Bayes Classifiers

بدین گونه که ورودی‌ها وارد قوانین فازی شده و میزان تعلق به هر کلاس به دست می‌آید. سپس کلاسی که بیشترین مقدار تعلق را دارد، نوع وسیله‌ی سفر ورودی را تعیین می‌کند.



(الف)



(ب)

شکل ۵: مدل مفهومی تحقیق

این داده‌ها شامل ۱۲۰ سفر می‌باشد که

### ۳-۱- اخذ و آماده‌سازی داده

داده‌های مورد استفاده در این تحقیق از دانشکده حمل و نقل دانشگاه فلوریدا جنوبی اخذ شده است.

دقت افقی، انحراف معیار فاصله‌ها بین مکان‌های توقف و میانگین زمان توقف می‌باشد [۵].

متوسط و بیشینه سرعت به‌علت اینکه در حالت‌های مختلف حمل و نقل دارای مقادیر متفاوتی هستند، انتخاب شدند. برای نمونه در سفر با ماشین سواری سرعت ۱۲۰ km/h ممکن است ولی در سفر با اتوبوس احتمال رسیدن به این سرعت خیلی کم است. اندازه‌ی فاصله اطمینان از اینکه تلفن همراه در موقعیت نشان داده‌شده با GPS قرار دارد، برآوردی از عدم قطعیت دقت افقی است. این مقدار برای حالت‌های مختلف سفر متفاوت خواهد بود. به‌عنوان مثال، اتوبوس دارای بدترین برآورد عدم قطعیت دقت افقی است زیرا جعبه فلزی آن مانع سیگنال‌های GPS می‌شود. در مقابل، سفر پیاده بهترین تخمین عدم قطعیت دقت افقی را دارد زیرا انسداد کننده‌ی سیگنال GPS معمولاً کیف یا جیب کاربر است [۵]. انحراف معیار فاصله بین مکان‌های توقف نیز به‌عنوان پارامتر ورودی در نظر گرفته شده است. این پارامتر در حالت‌های مختلف سفر متفاوت است. برای مثال سفر با اتوبوس احتمالاً دارای فاصله‌ی کمتری بین مکان‌های توقف نسبت به ماشین است با توجه به توقف‌های مکرر که یک وسیله نقلیه حمل و نقل به‌طور معمول می‌سازد. میانگین زمان توقف عبارت است از میانگین زمانی که کاربر سرعت آن زیر مقدار معینی قرار می‌گیرد. برای مثال این پارامتر اغلب دارای مقدار بالاتر برای سفر با ماشین یا پیاده و دارای مقدار کم برای سفر با اتوبوس می‌باشد زیرا در اتوبوس توقف کوتاه صورت می‌گیرد تا مسافران سوار یا پیاده شوند [۵].

در منطقه تمپا<sup>۱</sup> از ایالت فلوریدا با استفاده از برنامه کاربردی<sup>۲</sup> بر روی گوشی‌های موتورولا<sup>۳</sup> i ۸۷۰ و موتورولا i ۵۸۰ ثبت شده است. برنامه کاربردی (TRAC-IT) مجموعه‌ای از برنامه‌های کاربردی هستند که برای کنترل و آنالیز رفتار سفر از داده‌های جمع‌آوری شده توسط تلفن‌های همراه GPS دار استفاده می‌شود. این برنامه، یک واسط کاربری را فراهم می‌کند که می‌تواند اطلاعاتی از قبیل نوع وسیله‌ی سفر و هدف سفر را که مستقیماً از داده‌های GPS به دست نمی‌آیند، را توسط کاربر ثبت نماید. وسیله‌های سفر در داده‌های اخذ شده، شامل ماشین سواری، اتوبوس و پیاده می‌باشد. داده‌های طول و عرض جغرافیایی نقاط، سرعت، دقت افقی، دقت قائم و زمان در فاصله‌ی زمانی ۴ ثانیه در این سفرها اخذ گردیده بودند. در جدول (۱) نمونه‌ای از داده‌ها برای یک سفر با ماشین سواری نمایش داده شده است.

### ۳-۲- پارامترهای مؤثر در تعیین نوع سفر

در ادامه به معرفی پارامترهای مؤثر در تعیین نوع سفر در دو حالت استفاده از تمامی نقاط GPS و استفاده از نقاط بحرانی پرداخته می‌شود.

### ۳-۲-۱- در حالت شناسایی نوع وسیله‌ی سفر با استفاده از کل نقاط GPS

مشخصه‌هایی از داده‌های GPS که تفاوت بارزی بین حالت‌های مختلف سفر دارد باید انتخاب گردند، تا شبکه‌ی عصبی-فازی بتواند نوع وسیله سفر را به آسانی مشخص کند. پارامترهای ورودی در حالتی که کل نقاط GPS مورد استفاده قرار گیرد شامل: متوسط و بیشینه سرعت [۷،۸،۵]، برآورد عدم قطعیت

<sup>1</sup> Tampa

<sup>2</sup> Java ME application TRAC-IT

<sup>3</sup> Motorola

جدول ۱: نمونه‌ای از داده‌های جمع‌آوری شده

زمان	عدم قطعیت دقت قائم (دسی متر)	عدم قطعیت دقت افقی (دسی متر)	سرعت (متر بر ثانیه)	عرض جغرافیایی (درجه)	طول جغرافیایی (درجه)	شناسه سفر
۱۶:۴۱:۵۱	۴۷/۰۸۸۰۰۱۲۵	۲۴/۵۲۱۹۹۹۳۶	۱۳/۳۳۳۳۳۰۲	- ۸۲/۴۰۶۱۲۷۹۳	۲۸/۰۹۰۰۲۰۶	۱۵۳۳
۱۶:۴۱:۵۶	۵۱/۷۵	۲۷/۹۷۴۰۰۰۹۳	۱۴/۴۴۴۴۴۶۶	- ۸۲/۴۰۵۷۲۳۵۷	۲۸/۰۹۰۳۶۴۴۶	۱۵۳۳

قابل محاسبه می‌باشد. بیشینه شتاب متوسط را می‌توان از مجموعه‌ی شتاب متوسط انتخاب نمود [۵]. همچنین شتاب متوسط نهایی از تقسیم مجموع شتاب متوسط بر تعداد به‌دست می‌آید.

سرعت متوسط بین هر دو نقطه‌ی بحرانی با استفاده از نسبت فاصله اقلیدسی بین هر دو نقطه‌ی بحرانی متوالی بر زمان سپری شده بین این دو نقطه به دست می‌آید؛ که در آن فاصله‌ی اقلیدسی با به‌کارگیری مختصات این دو نقطه محاسبه می‌گردد. به‌علت اینکه بین دو نقطه‌ی بحرانی را می‌توان خط راست در نظر گرفت، بنابراین فاصله‌ی این دو نقطه را می‌توان فاصله‌ی اقلیدسی آن در نظر گرفت. متوسط سرعت کل مسیر از جمع فواصل بین نقاط بحرانی تقسیم بر کل زمان سپری شده به‌دست می‌آید. بیشینه سرعت از سرعت‌های به‌دست‌آمده در نقاط بحرانی انتخاب می‌شود [۵].

انحراف معیار سرعت بین نقاط بحرانی با استفاده از سرعت متوسط بین هر دو نقطه‌ی بحرانی به دست می‌آید. انحراف معیار وزن‌دار سرعت بین نقاط بحرانی با به‌کارگیری سرعت متوسط بین هر دو نقطه‌ی بحرانی و در نظر گرفتن فاصله‌ی بین نقاط بحرانی به‌عنوان وزن آن‌ها محاسبه می‌گردد.

در شکل (۶) به ترتیب تفاوت نسبت تعداد نقاط بحرانی در سفر به کل فاصله‌ی سفر، نسبت تعداد نقاط بحرانی در سفر به کل زمان سفر، انحراف معیار سرعت متوسط بین نقاط بحرانی و انحراف معیار وزن‌دار سرعت متوسط بین نقاط بحرانی برای حالت‌های مختلف سفر، برای چند سفر انتخابی نمایش داده شده است. همان‌طور که مشاهده می‌شود با

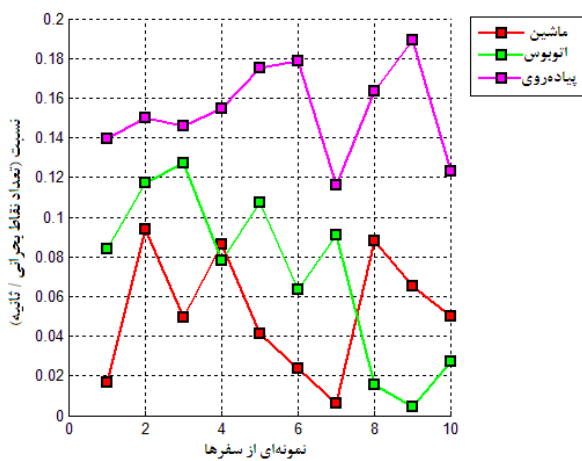
### ۳-۲-۲- در حالت شناسایی نوع وسیله‌ی سفر با استفاده از نقاط بحرانی

شناسایی نوع وسیله‌ی سفر با استفاده از نقاط بحرانی از مزایای فراوانی برخوردار است؛ زیرا تنها مشخصات این نقاط به سرور انتقال داده می‌شوند. بنابراین بیشتر پارامترهای ورودی ذکر شده برای حالت قبل در اینجا کارا نمی‌باشد. برای مثال برای تعیین انحراف معیار فاصله‌ها بین مکان‌های توقف و میانگین زمان توقف، کل داده‌های GPS مورد نیاز می‌باشد که در این حالت در دسترس نیست. به این دلیل ورودی‌های شبکه‌ی فازی-عصبی متفاوت از حالت قبل می‌باشد. ورودی‌ها در این حالت عبارت‌اند از: بیشینه و متوسط شتاب، ماکزیمم و متوسط سرعت [۵،۷،۸]، نسبت تعداد نقاط بحرانی در سفر به کل فاصله‌ی سفر، نسبت تعداد نقاط بحرانی در سفر به کل زمان سفر، کل فاصله‌ی سفر و فاصله‌ی متوسط بین نقاط بحرانی [۵]، انحراف معیار سرعت بین نقاط بحرانی و انحراف معیار وزن‌دار سرعت بین نقاط بحرانی.


محاسبه‌ی متوسط شتاب وقتی که از الگوریتم نقاط بحرانی معمولی استفاده می‌شود با مشکل همراه است؛ زیرا نقاط بحرانی از نظر زمانی یا مکانی نزدیک هم نیستند. برای حل این مشکل، گنزالز<sup>۱</sup> و همکاران از الگوریتم تغییر یافته‌ی نقاط بحرانی استفاده نمودند که در آن سرعت و زمان برای نقاط GPS بلافاصله قبل یا بعد از نقاط بحرانی نیز ثبت می‌شود. با داشتن دو زمان و سرعت در هر نقطه‌ی بحرانی شتاب متوسط برای آن زمان

<sup>1</sup> Gonzalez

ماشین و اتوبوس تفکیک نمود. شکل (۶-ج) نشان می‌دهد که انحراف معیار سرعت متوسط برای حالت‌های مختلف سفر با یکدیگر متفاوت است و همچنین شکل (۶-د) انحراف معیار وزن‌دار سرعت متوسط بین نقاط بحرانی را برای چند سفر نمایش می‌دهد که بیشتر بودن مقدار آن برای ماشین، امکان تفکیک ماشین از پیاده و اتوبوس را ممکن می‌سازد.



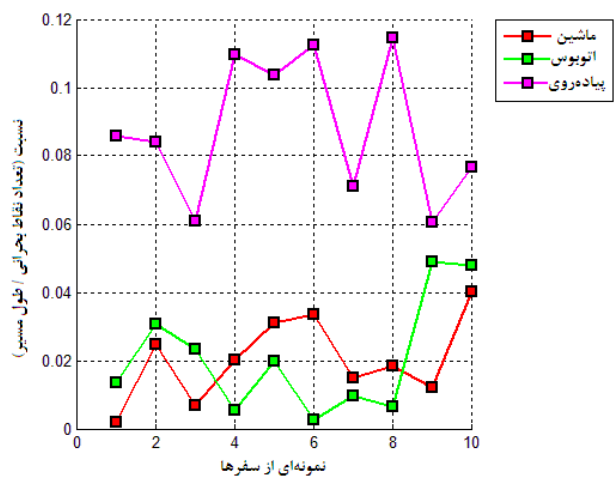
ب: نسبت تعداد نقاط بحرانی به زمان سفر برای چند سفر




د: انحراف معیار وزن‌دار سرعت متوسط بین نقاط بحرانی برای چند سفر

انتخاب این پارامترها امکان تفکیک نوع سفر فراهم می‌گردد.

شکل (۶-الف) نشان می‌دهد که نسبت تعداد نقاط بحرانی به طول مسیر پیاده بیشتر از ماشین سواری و اتوبوس است که با استفاده از آن امکان تفکیک پیاده از ماشین و اتوبوس فراهم می‌گردد. در شکل (۶-ب) نیز مشاهده می‌شود که نسبت تعداد نقاط بحرانی به زمان سفر پیاده بیشتر از ماشین سواری و اتوبوس است و با استفاده از آن می‌توان پیاده را از



الف: نسبت تعداد نقاط بحرانی به طول مسیر برای چند سفر



ج: انحراف معیار سرعت متوسط بین نقاط بحرانی برای چند سفر

شکل ۶: نمودارهای چند پارامتر استخراج‌شده از داده‌ها برای چند سفر

### ۳-۳- انتخاب پارامترهای مؤثر برای تعیین نوع وسیله‌ی سفر

به علت اینکه در شبکه‌ی عصبی-فازی، تعداد زیاد ورودی‌ها علاوه بر کاهش شفافیت مدل، پیچیدگی محاسبات را افزایش می‌دهند [۲۹]، پارامترهایی که تأثیرگذاری بیشتری برای تعیین نوع وسیله‌ی سفر دارند، انتخاب گردیدند. برای این کار از روش انتخاب ترتیبی پارامترها<sup>۱</sup> استفاده شد. انتخاب ترتیبی پارامترها روشی است که در آن پارامترهایی که بیشترین تأثیر را در دقت نهایی دارند، انتخاب می‌شوند. به عبارت دیگر پارامترهای کم اهمیت برای کاهش ابعاد داده‌ها حذف می‌شوند. این کار به دو طریق قابل اجرا است. در انتخاب رو به جلو<sup>۲</sup> الگوریتم بدون هیچ تغییری آغاز می‌شود و یکی، یکی متغیرها اضافه می‌گردد و در هر گام متغیری که خطا را بیشتر از بقیه کاهش می‌دهد نگه داشته می‌شود و به‌همین ترتیب ادامه می‌یابد تا زمانی که خطا تغییر زیادی نکند ولی در انتخاب رو به عقب<sup>۳</sup> الگوریتم با تمام متغیرها آغاز می‌شود و یکی یکی متغیرها حذف می‌شود و در هر مرحله متغیری حذف می‌گردد که با حذف آن خطا کاهش یابد و به‌همین ترتیب ادامه داده می‌شود [۳۰].

در این تحقیق از روش انتخاب رو به جلو استفاده گردید. با توجه به اینکه با تغییر داده‌های آموزشی شبکه‌ی عصبی-فازی خروجی متفاوت است، بنابراین انتخاب پارامترها با اعتبارسنجی چند لایه‌ای<sup>۴</sup> و با تکرار به‌دست آمد و چند سری پارامتر انتخاب شد. بر این اساس پارامترهایی مطابق جدول (۲) برای شناسایی با

نقاط بحرانی و جدول (۳) برای کل داده‌های GPS انتخاب گردید. در این جداول هر سطر نمایانگر پارامترهایی است که به‌عنوان متغیرهای ورودی به شبکه‌ی عصبی-فازی مورد استفاده قرار می‌گیرد. برای مثال همان‌طور که در جدول (۲) مشاهده می‌شود، سطر اول نشان می‌دهد که پارامترهای بیشینه سرعت، سرعت متوسط، انحراف معیار سرعت متوسط بین نقاط بحرانی و انحراف معیار وزن دار سرعت متوسط پارامترهای ورودی به شبکه برای شناسایی نوع وسیله‌ی سفر در حالت استفاده از نقاط بحرانی می‌باشند.

### ۳-۴- آموزش و تست شبکه‌ی ANFIS

به‌منظور آموزش شبکه‌ی ANFIS، پارامترهای توضیح داده‌شده برای هر سفر از داده‌ها استخراج گردید. سپس با توجه به اینکه شبکه‌ی ANFIS مورد استفاده دارای یک خروجی می‌باشد، مسئله برای شناسایی نوع وسیله‌ی سفر به سه مسئله‌ی باینری تبدیل گردید که برای شناسایی هر نوع وسیله‌ی سفر یک سری قوانین ایجاد می‌شود. در جدول (۴) کدگذاری روش طبقه‌بندی چند کلاسی یکی در مقابل همه برای خروجی مدل مذکور نمایش داده‌شده است. به‌عنوان نمونه اگر داده‌ای مربوط به کلاس اتوبوس باشد برای به‌دست آوردن قوانین شناسایی اتوبوس خروجی آن داده را ۱ و در به‌دست آوردن قوانین مربوط به ماشین سواری و پیاده، خروجی آن صفر در نظر گرفته می‌شود. بنابراین برای هر داده سه خروجی در نظر گرفته شد.

<sup>1</sup> Sequential Feature Selection

<sup>2</sup> Forward selection

<sup>3</sup> Backward selection

<sup>4</sup> Cross validation

جدول ۲: پارامترهای به‌دست آمده برای استفاده از نقاط بحرانی

شناسه پارامترها	بیشینه شتاب	متوسط شتاب	بیشینه سرعت	سرعت متوسط	نسبت تعداد نقاط بحرانی در سفر به کل فاصله‌ی سفر	نسبت تعداد نقاط بحرانی در سفر به کل زمان سفر	کل فاصله‌ی سفر	فاصله‌ی متوسط بین نقاط بحرانی	انحراف معیار سرعت متوسط	انحراف معیار وزن دار سرعت متوسط
۱			✓	✓✓					✓	✓
۲			✓	✓			✓		✓	
۳			✓		✓				✓	
۴		✓	✓	✓					✓	
۵			✓	✓					✓	
۶	✓					✓			✓	
۷	✓			✓				✓	✓	

جدول ۳: پارامترهای به‌دست آمده برای استفاده از کل داده‌های GPS

شناسه پارامترها	سرعت متوسط	بیشینه سرعت	میانگین زمان توقف	انحراف معیار فاصله‌ها بین مکان‌های توقف	عدم قطعیت دقت افقی
۱	✓	✓			
۲	✓	✓			✓
۳		✓	✓		✓
۴		✓	✓		
۵	✓	✓	✓	✓	
۶	✓		✓	✓	
۷	✓	✓	✓		✓

برای آموزش شبکه از نرم‌افزار MATLAB 7.10 استفاده گردید. در شبکه‌ی ANFIS آموزش در دو روش پس‌انتشار خطا و روش ترکیبی پس‌انتشار خطا و کمترین مربعات استفاده شد. برای ایجاد قوانین اولیه خوشه‌بندی کاشکی و

جدول ۴: کدگذاری روش یکی در مقابل همه

ماشین سواری	۱	۰	۰
اتوبوس	۰	۱	۰
پیاده	۰	۰	۱

## ۳-۵- ارزیابی دقت

در این تحقیق برای تحلیل عملکرد و مؤثر بودن روش به کار گرفته شده برای تعیین نوع وسیله سفر از معیار دقت<sup>۲</sup> (رابطه (۲))، یادآوری<sup>۳</sup> (رابطه (۳)) و صحت<sup>۴</sup> (رابطه (۴)) استفاده گردید، که به صورت زیر تعریف می گردند:

$$\text{precision} = \frac{TP}{TP+FP} \quad \text{رابطه (۲)}$$

$$\text{recall} = \frac{TP}{TP+FN} \quad \text{رابطه (۳)}$$

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad \text{رابطه (۴)}$$

که پارامترها در این فرمولها در یک دسته بندی دو کلاسی عبارتند از،  $TP$  تعداد داده های درست طبقه بندی شده در کلاس دو،  $FP$  تعداد داده هایی که در کلاس اول قرار دارند و اشتباه طبقه بندی شدند،  $FN$  تعداد داده هایی است که در کلاس دوم قرار دارند و اشتباه طبقه بندی شدند، و  $TN$  تعداد داده های درست طبقه بندی شده در کلاس یک می باشد. به عبارتی می توان معیارها را به صورت کیفی زیر بیان نمود:

معیار دقت: نسبت تعداد داده های درست طبقه بندی شده به تعداد کل داده های طبقه بندی شده برای همان کلاس.

معیار یادآوری: نسبت تعداد داده های درست طبقه بندی شده به تعداد کل داده های مربوط به همان کلاس.

معیار صحت برای ارزیابی کل طبقه بندی انجام شده به کار می رود که عبارت است از نسبت مجموع تمام داده های درست طبقه بندی شده تمام کلاسها به تمام داده ها.

تقسیم بندی گزیدی به کار گرفته شد. در خوشه بندی کاهشی فاصله ی مؤثر  $0/45$  در نظر گرفته شد. این مقدار با سعی و خطا به دست آمد. همان طور که ذکر شد قوانین فازی سوگنو برای به کار بردن در این شبکه ایجاد می شود. قوانین سوگنو در دو حالت مرتبه ی صفر و مرتبه ی یک مورد بررسی قرار گرفت. منظور از قوانین سوگنو مرتبه صفر این است که تابع مؤخر قانون فازی، تابع ثابت و در سوگنو مرتبه یک، تابع مؤخر تابعی خطی از ورودی هاست.

به علت کم بودن تعداد داده ها، برای ارزیابی دقت از اعتبارسنجی ۱۰ لایه ای<sup>۱</sup> استفاده گردید. در اعتبارسنجی  $k$  لایه ای، داده ها به طور تصادفی به  $k$  قسمت تقسیم می شوند و سپس یک قسمت به عنوان داده های تست و  $k-1$  قسمت باقیمانده به عنوان داده های آموزشی به کار گرفته می شوند. این فرآیند  $k$  مرتبه با در نظر گرفتن یک قسمت متفاوت به عنوان داده های تست تکرار می شود. داده های آموزشی با خروجی مربوط به هر کلاس به طور جداگانه برای ایجاد قوانین اولیه و همچنین آموزش شبکه ANFIS به کار گرفته می شوند و پس از آموزش شبکه، داده های تست وارد هر سه سری قوانین شناسایی نوع سفر شده و کلاسی که بیشترین مقدار خروجی را دارا می باشد به عنوان نوع وسیله سفر برای آن داده در نظر گرفته می شود. به علت اینکه در اعتبارسنجی ۱۰ لایه ای داده ها به طور تصادفی تقسیم می گردند، برای اینکه نتیجه بهینه باشد، نتایج نهایی با ۲۰۰ بار تکرار اعتبارسنجی ۱۰ لایه ای به دست آمد.

برای افزایش تفسیرپذیری قوانین به دست آمده از روش خوشه بندی کاهشی، از روش کاهش تعداد توابع عضویت فازی با در نظر گرفتن  $\lambda = 0/8$  استفاده شد.

<sup>2</sup> Precision accuracy

<sup>3</sup> Recall accuracy

<sup>4</sup> Accuracy

<sup>1</sup> 10\_Fold cross validation

جدول (۶) نشان می‌دهد که برای ایجاد قوانین شناسایی ماشین‌سواری استفاده از پارامترهای بیشینه سرعت، سرعت متوسط و انحراف معیار سرعت متوسط بین نقاط بحرانی و همچنین به‌کارگیری پارامترهای بیشینه سرعت، سرعت متوسط، انحراف معیار سرعت متوسط بین نقاط بحرانی و انحراف معیار وزن‌دار سرعت متوسط بین نقاط بحرانی برای ایجاد قوانین شناسایی اتوبوس و در نهایت برای شناسایی پیاده استفاده از مجموعه پارامترهای بیشینه سرعت، سرعت متوسط و انحراف معیار وزن‌دار سرعت متوسط بین نقاط بحرانی، دقت نهایی  $95/53\%$  محاسبه می‌گردد. جدول (۶) نشان می‌دهد که پارامترهای مرتبط با سرعت بهترین نتایج را برای شناسایی نوع وسیله سفر داشته‌اند. برای پیاده و اتوبوس انحراف معیار وزن‌دار سرعت متوسط بین نقاط بحرانی از پارامترهای منتخب برای شناسایی وسیله سفر بوده است. وزن این پارامتر فاصله بین نقاط بحرانی در نظر گرفته شده است. به عبارتی برای شناسایی پیاده و اتوبوس فاصله بین نقاط بحرانی تأثیر غیرمستقیم دارد.

#### ۴-۲- شناسایی نوع وسیله‌ی سفر با استفاده از کل نقاط GPS

در جدول (۷) نتایجی که دارای بیشترین دقت شناسایی (با هر سری از پارامترهای ذکر شده در جدول (۳)) است را به نمایش می‌گذارد. برای نمونه با در نظر گرفتن پارامترهای بیشینه و متوسط سرعت (سطر شماره ۱) به‌عنوان ورودی و با در نظر گرفتن قوانین سوگنو مرتبه‌ی اول و ایجاد قوانین اولیه با خوشه‌بندی کاهشی و آموزش با روش پس انتشار خطا، قوانین حاصله دارای دقت شناسایی نوع وسیله‌ی سفر  $94/01\%$  می‌باشند.

#### ۴-نتایج

در ادامه به ارائه نتایج حاصل از شناسایی نوع وسیله سفر در دو حالت استفاده از نقاط بحرانی و استفاده از نقاط GPS پرداخته می‌شود.

#### ۴-۱- شناسایی نوع وسیله‌ی سفر با استفاده از نقاط بحرانی

قوانین فازی در سیستم سوگنو با روش شبکه‌ی عصبی-فازی برای شناسایی نوع وسیله‌ی سفر ایجاد گردید. در جدول (۵) نتایجی که دارای بیشترین دقت شناسایی نوع وسیله (با هر سری از پارامترهای ذکر شده در جدول (۲)) است نمایش داده شده است؛ به‌گونه‌ای که شماره سطر در جدول (۵) متناظر با شماره سطر در جدول (۲) می‌باشد. برای نمونه با در نظر گرفتن پارامترهای بیشینه و متوسط سرعت، انحراف معیار سرعت متوسط و انحراف معیار وزن‌دار سرعت متوسط (سطر شماره ۱) به‌عنوان ورودی و با در نظر گرفتن قوانین سوگنو مرتبه‌ی اول و ایجاد قوانین اولیه با خوشه‌بندی کاهشی و آموزش با روش ترکیبی پس انتشار خطا و کمترین مربعات، قوانین حاصله دارای دقت شناسایی نوع وسیله‌ی سفر  $94/87\%$  می‌باشند.

نتایج جدول (۵) برای حالتی است که هر سه مجموعه قوانین شناسایی نوع وسیله‌ی سفر از یک سری پارامترهای یکسان به‌عنوان ورودی استفاده نمایند. به‌کارگیری روش طبقه‌بندی چند کلاسه‌ی یکی در مقابل همه این قابلیت را دارد که برای شناسایی هر نوع وسیله‌ی سفر از مجموعه پارامترهای متفاوت به‌عنوان ورودی استفاده شود. بنابراین در این تحقیق انواع مختلف ترکیبات پارامترها برای ورودی شبکه‌ی عصبی-فازی به کار گرفته شد که بهترین نتیجه‌ی آن در جدول (۵) نمایش داده شده است.

جدول ۵: روش‌های منتخب و نتایج آن‌ها برای حالات مختلف بررسی شده با نقاط بحرانی

شناسه پارامترها	ANFIS	صحت (%)	اتوبوس		ماشین سواری		پیاده	
			یادآوری (%)	دقت (%)	یادآوری (%)	دقت (%)	یادآوری (%)	دقت (%)
۱	One <sup>a</sup> -sub <sup>b</sup> -Hyb <sup>c</sup>	۹۴٫۸۷	۹۵٫۴۹	۹۱٫۴۵	۸۸٫۴۲	۹۴٫۹۵	۱۰۰	۹۹٫۹۲
۲	Zero <sup>d</sup> -Grid <sup>e</sup> -Hyb	۹۴٫۷۱	۹۴٫۰۹	۹۲٫۳۹	۸۹٫۶۸	۹۳٫۳۹	۹۹٫۹۲	۹۹٫۳۶
۳	One-sub-Hyb	۸۸٫۳۷	۸۲٫۸۸	۸۶٫۲۴	۸۳٫۳۸	۸۲٫۱۰	۹۸٫۹	۹۷٫۹۸
۴	One-sub-BP <sup>f</sup>	۹۴٫۴۶	۹۳٫۳۵	۹۲٫۱۴	۸۹٫۶۵	۹۲٫۴۰	۱۰۰	۹۹٫۹۸
۵	One-sub-Hyb	۹۴٫۷۰	۹۴٫۰۵	۹۲٫۲۴	۸۹٫۶۲	۹۳٫۲۱	۱۰۰	۹۹٫۹۴
۶	One-sub-BP	۹۱٫۹۵	۸۸٫۷۶	۹۰٫۱۱	۹۱٫۷۸	۹۰٫۰۰	۹۵٫۶۱	۹۷٫۳۵
۷	One-sub-BP	۹۳٫۶۰	۸۹٫۳۴	۹۳٫۵۰	۹۱٫۷۴	۸۸٫۵۱	۹۹٫۹۶	۹۹٫۵۵

One<sup>a</sup>: قوانین سوگنو مرتبه‌ی اول  
 Sub<sup>b</sup>: ایجاد قوانین با خوشه‌بندی کاهشی  
 Zero<sup>d</sup>: قوانین سوگنو مرتبه‌ی صفر  
 Grid<sup>e</sup>: ایجاد قوانین با تقسیم‌بندی گریدی  
 Hyb<sup>c</sup>: آموزش با استفاده از روش ترکیبی  
 BP<sup>f</sup>: آموزش با استفاده از روش پس انتشار خطا

جدول ۶: بهترین نتیجه به‌دست آمده از ترکیبات مختلف پارامترها

	بیشینه سرعت	سرعت متوسط	انحراف معیار سرعت متوسط	انحراف معیار وزن دار سرعت متوسط	یادآوری (%)	دقت (%)
ماشین سواری	✓	✓✓	✓		۸۹٫۱۶	۹۶٫۳۴
اتوبوس	✓	✓	✓	✓	۹۶٫۶۸	۹۲٫۰۸
پیاده	✓	✓		✓	۱۰۰	۹۹٫۸۳
صحت (%)	۹۵/۵۳%					

جدول ۷: روش‌های منتخب و نتایج آن‌ها برای حالات مختلف بررسی شده با کل داده‌های GPS

شناسه پارامترها	ANFIS	صحت (%)	اتوبوس		ماشین سواری		پیاده	
			یادآوری (%)	دقت (%)	یادآوری (%)	دقت (%)	یادآوری (%)	دقت (%)
۱	One <sup>a</sup> -sub <sup>b</sup> -BP <sup>c</sup>	۹۴٫۰۱	۹۴٫۶۱	۹۰٫۲۵	۸۹٫۶۹	۹۴٫۲۰	۹۷٫۲۴	۹۹٫۶۹
۲	One-sub-Hyb <sup>d</sup>	۹۴٫۰۶	۹۴٫۸۴	۹۰٫۲۰	۸۹٫۶۴	۹۴٫۵۴	۹۷٫۱۸	۹۹٫۵۶
۳	One-sub- BP	۹۴٫۰۷	۹۳٫۶۷	۹۱٫۰۴	۹۰٫۹۳	۹۳٫۰۵	۹۷٫۳۲	۹۹٫۸۶
۴	One-sub- BP	۹۳٫۵۷	۹۲٫۶۴	۹۰٫۷۰	۹۰٫۴۷	۹۱٫۸۳	۹۷٫۴۰	۹۹٫۸۵
۵	One-sub-Hyb	۹۳٫۵۹	۹۰٫۶۴	۹۲٫۳۵	۹۲٫۹۴	۹۰٫۵۵	۹۷٫۴۴	۹۹٫۱۷
۶	One-sub- BP	۹۳٫۴۱	۹۱٫۴۴	۹۱٫۲۸	۹۱٫۲۹	۹۱٫۴۳	۹۷٫۴۸	۹۹٫۱۹
۷	Zero <sup>e</sup> -grid <sup>f</sup> -Hyb	۹۳٫۷۵	۹۱٫۶۴	۹۲٫۳۴	۹۳٫۱۳	۹۲٫۲۶	۹۶٫۶۲	۹۸٫۰۱

One<sup>a</sup>: قوانین سوگنو مرتبه‌ی اول  
 Sub<sup>b</sup>: ایجاد قوانین با خوشه‌بندی کاهشی  
 BP<sup>c</sup>: آموزش با استفاده از روش پس انتشار خطا  
 Hyb<sup>d</sup>: آموزش با استفاده از روش ترکیبی  
 Zero<sup>e</sup>: قوانین سوگنو مرتبه‌ی صفر  
 Grid<sup>f</sup>: ایجاد قوانین با تقسیم‌بندی گریدی

توقف بهترین نتایج را برای شناسایی نوع وسیله‌ی سفر با استفاده از کل نقاط GPS داشتند که دقت نهایی ۹۴/۰۷٪ محاسبه گردید.

جدول (۸) نشان می‌دهد که برای ایجاد قوانین شناسایی ماشین‌سواری، اتوبوس و پیاده، پارامترهای عدم قطعیت دقت افقی، بیشینه سرعت و میانگین زمان

جدول ۸: بهترین نتیجه به‌دست‌آمده از ترکیبات مختلف پارامترها

دقت (%)	یادآوری (%)	عدم قطعیت دقت افقی	بیشینه سرعت	میانگین زمان توقف
۹۳/۰۵	۹۰/۹۳	✓	✓✓	✓
۹۱/۰۴	۹۳/۶۷	✓	✓	✓
۹۹/۸۶	۹۷/۳۲	✓	✓	✓
صحت (%) ۹۴/۰۷%				

کل داده‌ها ۸۸/۶٪ محاسبه گردیده است [۵]. در این تحقیق که برای مقایسه نتایج، از داده‌های مطالعه‌ی گنزالز و همکاران استفاده گردیده است با دستیابی به دقت ۹۵/۵۳٪ در حالت استفاده از نقاط بحرانی و دقت ۹۴/۰۷٪ در به‌کارگیری کل داده‌ها، نشان داده شد که سیستم استنتاج عصبی-فازی روشی مناسب و کارا برای شناسایی خودکار نوع وسیله‌ی سفر می‌باشد. با به‌کارگیری سیستم استنتاج عصبی-فازی، قوانین فازی برای شناسایی نوع وسیله‌ی سفر استخراج گردید و با استفاده از طبقه‌بندی چند کلاسی امکان به‌دست آمدن قوانین فازی با پارامترهای متفاوت برای هر نوع وسیله‌ی سفر فراهم گردید. لازم به ذکر است که استخراج خودکار پایگاه دانش فازی این توانایی را به سیستم می‌دهد که بدون نیاز به شخص خبره به تحلیل و تصمیم‌گیری بپردازد. همچنین از دلایلی که شبکه‌ی عصبی-فازی قادر به تشخیص دقیق نوع وسیله‌ی سفر نیست می‌توان به امکان وجود خطا در داده‌ها و تعداد کم سفرها اشاره نمود.

از محدودیت‌های این تحقیق می‌توان این مورد را ذکر نمود که داده‌های GPS مورد استفاده حالت‌های مختلف سفر به‌صورت دستی تقسیم‌بندی شده بودند و هر سفر شامل یک نوع وسیله‌ی حمل و نقل بود.

## ۵- جمع‌بندی

در این تحقیق با به‌کارگیری سیستم استنتاج عصبی-فازی و استفاده از داده‌های GPS به‌دست‌آمده از تلفن همراه GPS دار، قوانین فازی مورد نیاز برای شناسایی نوع وسیله‌ی سفر از داده‌ها استخراج گردید. شبکه‌ی عصبی-فازی این قابلیت را در اختیار می‌گذارد که با استفاده از توانایی یادگیری شبکه‌ی عصبی، دانش مورد نیاز در مورد پدیده‌ی موردنظر، بدون نیاز به شخص خبره، در قالب قوانین مناسب بیان گردد. ماشین سواری، اتوبوس، پیاده وسیله‌های سفر بودند که با استفاده از قوانین فازی استخراج‌شده از داده‌های GPS به‌صورت خودکار شناسایی گردیدند. در دو حالت این مدل مورد بررسی قرار گرفت. در یک حالت از کل داده‌های GPS برای استخراج قوانین استفاده گردید و در مدل دیگر به‌منظور کاهش نقاط ثابت GPS انتقالی به سرور و صرفه‌جویی در مصرف انرژی باتری، پهنای باند شبکه و فضای ذخیره از نقاط بحرانی برای آموزش شبکه استفاده گردید.

در مطالعه‌ی انجام‌شده توسط گنزالز و همکاران که با استفاده از شبکه‌ی عصبی به استخراج خودکار نوع وسیله‌ی سفر پرداخته‌شده بود دقت شناسایی در حالت استفاده از نقاط بحرانی ۹۱/۲۳٪ و در حالت استفاده از

بنابراین پیشنهاد می‌شود روی روش‌هایی که بتوان به‌طور اتوماتیک داده‌های GPS به‌دست‌آمده در طی روز را به قسمت‌هایی که شامل یک نوع وسیله‌ی سفر هستند تقسیم نماید، کار شود. همچنین از آنجایی که داده‌ها دارای خطا می‌باشند باید با روش‌هایی میزان خطا در داده‌ها تشخیص داده شود تا در داده‌های اصلی حذف یا اصلاح گردد که بتوان با روش‌های یادگیری ماشین نوع وسیله‌ی سفر به‌درستی تشخیص داده شود.

### سپاسگزاری

از دکتر باربیو<sup>۱</sup> از دانشکده حمل و نقل دانشگاه فلوریدا جنوبی برای در اختیار گذاشتن داده‌های مورد نیاز این تحقیق سپاسگزاریم.

---

<sup>۱</sup> Sean J. Barbeau

## مراجع

- [1] Stopher, P., & Greaves, S. P., "Household travel surveys: Where are we going?". *Transportation Research Part A*, Vol. 41, pp. 367–381, 2007.
- [2] Murakami, E., Wagner, D. P., Neumeister, D. M. ., "Using Global Positioning Systems and Personal Digital Assistants for Personal Travel Surveys in the United States". Grainau, Germany. : International Conference on Transport Survey Quality and Innovation, 1997.
- [3] Murakami, E. and D. P. Wagner. "Can using global positioning system (GPS) improve trip reporting?" *Transportation Research Part C*, Vol. 7(2/3), pp. 149-165, 1999.
- [4] Stenneth, L., Wolfson, O., Yu, P. S., & Xu, B., "Transportation mode detection using mobile phones and GIS information" . ACM SIGSPATIAL GIS-Chicago, IL, USA, 2011.
- [5] Gonzalez,P, Weinstein,J, Barbeau,S., Labrador, M, Winters,P, Georggi ,N., Perez,R., "Automating mode detection for travel behaviour analysis by using global positioning systems enabled mobile phones and neural networks". *IEEE, Intelligent Transport Systems, IET*, Vol. 4, pp. 37- 49. 1751-956X, 2010.
- [6] Gong,H., Chen,C, Bialostozky,E, Lawson,C.T., "A GPS/GIS method for travel mode detection in New York City". *Computers, Environment and Urban Systems*, Vol. 36, pp. 131-139, 2012.
- [7] Bolbol,A, Cheng,T., Tsapakis,I, Haworth,J., "Inferring hybrid transportation modes from sparse GPS data using a moving window". 6, *Computers, Environment and Urban Systems*, Vol. 36, pp. 526–537, 2012.
- [8] Zheng, Y., Chen, Y., Li, Q., Xie, X., & Ma, W., "Understanding transportation modes based on GPS data for Web applications". 4 *ACM Transaction on the Web*, Vol. 1, pp. 1-36, 2010.
- [9] Reddy, S., Mun, M., Burke, J., Estrin, D., Hansen, M., Srivastava, M., "Using Mobile Phones to Determine Transportation Modes". 2, *ACM Transactions on Sensor Networks*, Vol. 6, 2010.
- [10] Schüssler, N.,& Axhausen,K.W. "Processing GPS Raw Data Without Additional Information". *Transportation Research Record: Journal of the Transportation Research Board*, 2105, pp. 28–36, 2009.
- [11] Iljecki, F., Ledoux, H. and Van Oosterom, P., "Transportation mode-based segmentation and classification of movement trajectories", *International Journal of Geographical Information Science*, Vol. 27(2) ,pp. 385-407,2013.
- [12] Waga, K., Tabarcea, A., Chen, M. and Fränti, P., "Detecting movement type by route segmentation and classification," *Collaborative Computing: Networking, Applications and Worksharing (CollaborateCom)*, 2012 8th International Conference on. *IEEE*, 2012.
- [13] Rudloff, C. and Ray, M., "Detecting Travel Modes and Profiling Commuter Habits Solely Based on GPS Data, " In *Proceedings of the Transportation Research Board 89th Annual Meeting*, Washington, DC, USA, 10–14 January 2010.
- [14] Broach, J.; McNeil, N.W.; Dill, J., "Travel Mode Imputation Using GPS and Accelerator Data from Multi-Day Travel Survey.," In *Proceedings of the Transportation Research Board 93rd Annual Meeting*, Washington, DC, USA, 12–16 January 2014.
- [15] Xiao, G., Zhicai J., and Jingxin Gao, "Travel Mode Detection Based on Neural Networks and Particle Swarm Optimization ," *Information* Vol.6(3), pp: 522-535,2015.
- [16] Wang, L., "Fuzzy Systems and Fuzzy Control", translated by Teshne Lab, M.,

- Ofyuni , D., Safarpour, N., Khaje Nasir Toosi University Press, 2010
- [17] Horikawa, S., T., Furuhashi, Y., Uchikawa , “On fuzzy modelling using fuzzy neural networks with the back-propagation algorithm”. 5, IEEE Trans Neural Netw, Vol. 3, pp. 801-806. doi:10.1109/72.159069, 1992.
- [18] Lin, C.T., C.S.G., Lee. “Neural-network-based fuzzy logic control and decision system”. 12, IEEE Trans Comput C, Vol. 40, pp. 1320-1336, 1991.
- [19] Jang, J.S.R. “ANFIS: Adaptive-Network-Based Fuzzy Inference Systems”. IEEE Transaction on Systems, Man, and Cybernetics 23, pp. 665-685, 1993
- [20] Gonzalez, P., Weinstein, J., Barbeau, S., Labrador, M., Winters, P., Georggi, N., Perez, R., “Automating Mode Detection Using Neural Networks and Assisted GPS Data Collected Using GPS-enabled Mobile Phones”. 15th World Congress on Intelligent Transportation Systems, 2008.
- [21] Barbeau, S., Labrador, M., Perez, A., Winters, P., Georggi, N., Aguilar, D., Perez, R. “Dynamic Management of Real-Time Location Data on GPS-enabled Mobile Phones”. UBIComm 2008 – The Second International Conference on Mobile Ubiquitous Computing, Systems, Services, and Technologies, Valencia, Spain, September 29 – October 4, 2008.
- [22] Vieira, J., M., Dias, F.A., Mota. “Neuro-Fuzzy Systems: A Survey”. 5th WSEAS NNA International Conference on Neural Networks and Applications, 2004.
- [23] Hammouda, K. “A comparative study of data clustering techniques”. Citeseer, Vol. 625, 2000.
- [24] Chiu. “fuzzy model identification based on cluster estimation”. Journal of Intelligent & Fuzzy Systems, Vol. 2, pp. 267-278, 1994.
- [25] Wu, Y., et al. “Fuzzy Logic and Neuro-fuzzy Systems: A Systematic Introduction”. 2, International Journal of Artificial Intelligence and Expert Systems (IJAE), Vol. 2, 2011.
- [26] Setnes, M., et al. “Similarity Measures in Fuzzy Rule Base Simplification”. 3, IEEE Transactions on systems, man, and cybernetics part b cybernetics, vol. 28, 1998.
- [27] Chen, M.Y., D.A., Linkens. “Rule-base self-generation and simplification for data-driven”. Fuzzy Sets and Systems, Vol. 142, pp. 243 – 265, 2004.
- [28] Aly, M. “Survey on Multi-Class Classification Methods”. Technical Report, Caltech, USA, 2005.
- [29] Jang, J.S.R. “Input selection for ANFIS learning”. IEEE, pp. 1493-1499. 1098-7584, 978-1-4244-3596-8, 1996.
- [30] Ladha, L., Deepa, T. “Feature selection methods and algorithms”. 5, International Journal on Computer Science and Engineering (IJCSE), Vol. 3. ISSN:0975-3397, 2011.



## **Automatic mode detection in transportation using GPS data from mobile devices and neuro –fuzzy system**

**Elahe Khazaei <sup>\*1</sup>, Ali Asghar Alesheikh <sup>2</sup>, Mohammad Karimi <sup>3</sup>**

1- PHD student in GIS, Faculty of Geomatics Engineering, K.N. Toosi University of Technology

2- Professor, GIS Department, Faculty of Geodesy and Geomatics Eng. K.N. Toosi University of Technology

3- Assistant professor, GIS Department, Faculty of Geodesy and Geomatics Eng. K.N. Toosi University of Technology

### **Abstract**

Cognition of travel mode and travel demand is of prime importance to transportation communities and agencies in every country. If the precise transportation modes of individual users are recognized, a more realistic travel demand can be considered. Also, in location-based service, the knowledge of a traveler's transportation mode is applied to send targeted and customized informative advertisements. This study examines the feasibility of using a neuro-fuzzy inference system to automatically detect the mode of transportation from GPS data collected by GPS-enabled mobile phones. To achieve this, the knowledge was extracted in the form of fuzzy rules from the data and, then, the rules are being used for determination of transportation's mode. For this purpose, the model was examined in two cases. In the first case, all GPS data from mobile devices were used, while in the second case the critical point algorithm was exercised. In addition to reducing the size of required GPS datasets, the critical point algorithm decreases data collection cost and saving mobile phone resources such as its battery life. The results showed that the suggested model have the capability of detecting a transportation mode with 94/1 percent accuracy in case of using all GPS data and 95.5 percent accuracy in case of using critical points.

**Key words:** Neuro-fuzzy system, Transportation Mode detection, Critical points, GPS data.

**Correspondence Address :** GIS Department, Faculty of Geodesy and Geomatics Eng. K.N. Toosi University of Technology, Tehran, Iran.  
**Tel :** +98 9354281500  
**Email:** Ekhazaei@mail.kntu.ac.ir