

شناسایی خودکار نوع وسیله‌ی سفر از داده‌های GPS و سایل همراه با استفاده از شبکه‌ی عصبی-فازی

الهه خزاعی^{۱*}، علی‌اصغر آل شیخ^۲، محمد کریمی^۳

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

۲- استاد، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران

۳- استادیار، دانشکده مهندسی نقشه‌برداری، دانشگاه صنعتی خواجه نصیرالدین 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 مکان‌مینا 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 آمدۀ از وسائل 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

سیستم تعیین موقعیت جهانی (GPS)^۵ وسیله‌ی نقلیه صورت می‌گیرد. به علت اینکه داده‌های مانند زمان سفر، مکان و فاصله‌های ثبت شده توسط این روش‌ها، بعد از سفر جمع‌آوری می‌گردند، دقیقت 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. به علاوه 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^۶ و یادگیری ماشین تقسیم‌بندی نمود [۷]. در روش‌های رویه‌ای تلاش عمده‌ای 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 پیش‌فرضهای منطقی مشابه ترکیب شده‌اند [۷]. نمونه‌هایی از این مطالعات عبارتند از: درخت تصمیم‌گیری [۹،۸]، منطق فاری [۱۱،۱۰]

⁵ Global Positioning System
⁶ Procedural

سازمان‌های برنامه‌ریزی منطقه‌ای سال‌ها است که به بررسی سفرهای روزانه با هدف به دست 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 فرآگستر^۱ و محاسبات محیط آگاه^۲ 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 به عنوان سرویس‌های مکان‌بنا^۳ (LBS) شناخته می‌شوند. در این سرویس‌ها از مکان دستگاه و داده‌های دیگر، برای ایجاد برنامه‌های مکان آگاه^۴ استفاده می‌شود [۵]. تبلیغات و بازاریابی نمونه‌ای از کاربردهای سرویس‌های مکان‌بنا 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

¹ Ubiquitous

² Context aware

³ Location Based services

⁴ Location aware

برای داده‌های تست به دست آوردن. داده‌های به کارگرفته شده 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 به دست می‌آورد، به صورت 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.

به دلیل 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 دارد می‌باشد. سیستم ترکیبی شبکه فازی عصبی نامیده می‌شود [۷]. تحقیقات زیادی برای تلفیق قابلیت یادگیری شبکه‌ی عصبی با سیستم استنتاج فازی به منظور استخراج قوانین اولیه‌ی سیستم فازی و بهینه کردن توابع عضویت صورت گرفته است [۱۷، ۱۸، ۱۹].

شبکه بیزی^۱ [۴]، شبکه‌ی عصبی [۵]، ماشین بردار پشتیبان (SVM^۲) [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^۳ و همکاران [۸] داده‌های موقعیت GPS ۶۵ نفر را برای ۱۰ ماه جمع‌آوری نمودند و با به کارگیری درخت تصمیم‌گیری ۷۵/۶٪ از نوع وسیله سفرها را به درستی برآورد کردند. رودلاف و ری^۴ [۱۳] خط سیر را به داده‌های تست و آموزش تقسیم نمودند و از شبکه پرسپترون چند لایه‌ای برای تعیین نوع وسیله‌ی سفر استفاده بردند. نتایج ایشان حاکی از درستی تشخیص ۸۲/۷٪ بود. بلبل^۵ 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 به دست آورند. برج^۶ و همکاران از مدل لوجیت چندگانه^۷ [۱۴] برای تشخیص پیاده، دوچرخه، ماشین و اتوبوس استفاده نمودند. داده‌های مورد استفاده، متشكل از ۹۲۶ قطعه بوده است و ۹۰/۸٪ از سفرها را به درستی برچسب زندند. گنزالز^۸ و همکاران [۵] داده‌های مکانی ۱۱۴ سفر را با استفاده از گوشی همراه جمع‌آوری نموده و با به کارگیری شبکه‌ی عصبی به دقت ۹۱/۲۳٪ برای تشخیص نوع وسیله‌ی سفر رسیدند. اکسیا^۹ و همکاران [۱۵] از ترکیب شبکه‌ی عصبی و بهینه‌سازی ازدحام ذرات^{۱۰} برای بهبود دقت تشخیص نوع سفر استفاده نمودند و دقت ۹۴/۴۴٪.

¹ Bayesian network

² Support Vector Machine

³ Zheng

⁴ Rudloff and Ray

⁵ Bolbol

⁶ Broach

⁷ Multinomial logit

⁸ Gonzalez

⁹ Xiao

¹⁰ Particle Swarm Optimization (PSO)

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

الگوریتم نقاط بحرانی متفاوت از فاصله‌ی بروز رسانی ثابت^۲ است. در فاصله‌ی بروز رسانی ثابت موقعیت، هر X ثانیه بدون در نظر گرفتن اینکه اطلاعات موقعیت به داشت از مسیر کاربر کمکی 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"^۳ 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]

² Fixed update interval

³ Line simplification

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، به کار 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^۱ به منظور 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، به عنوان نقطه‌ی بحرانی در نظر گرفته می‌شود.

¹ Critical point

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 خطای برآورده کلیه پارامترها، روش پس انتشار خطای و یک عبور، روش کمترین مربعات برای تخمین اولیه پارامترهای نتیجه، ترکیب روش پس انتشار خطای و کمترین مربعات که در آن در عبور به جلو پارامترهای نتیجه با روش کمترین مربعات و در عبور به عقب از پس انتشار خطای برای تخمین پارامترهای مقدمه استفاده می‌گردد [۱۹].

با توجه به توضیحات داده‌شده، به‌طورکلی 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 خوشبندی کاهشی، و تقسیم‌بندی گردید استفاده شده است. همچنین در روش‌های خوشبندی 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.

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 (^۱ANFIS): این سیستم در سال ۱۹۹۳ توسط جنگ^۲ 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 مختصرًا می‌توان به صورت زیر بیان کرد:

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

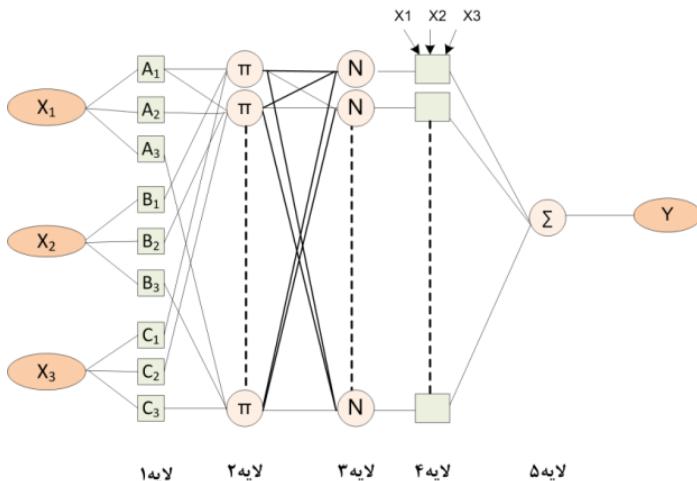
لایه ۲ : هر گره در این لایه به گره‌هایی که نمایش دهنده‌ی پیش فرض‌های قانون موردنظر است وصل می‌شود. هر گره در این لایه گره ثابتی است که در آن سیگنال‌های ورودی در هم ضرب می‌شوند و وزن یک قانون را بیرون می‌فرستد.

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).

¹ Adaptive Neuro - Fuzzy Inference System

² Jang



شکل ۳ : ساختار کلی سیستم استنتاج عصبی-فازی تطبیقی

۴-۲ روش تقسیم‌بندی گریدی

روش تقسیم‌بندی گریدی دارای ساختار گریدی می‌باشد. تفسیرپذیری این روش آسان است و به طور گسترده برای ایجاد قوانین فازی استفاده می‌شود. این روش برای تقسیم‌بندی فضای ورودی مورد استفاده قرار می‌گیرد و در سیستم فازی سوگونه کاربرد دارد. مشکل اساسی آن این است که با افزایش تعداد متغیرهای ورودی، تعداد قوانین به صورت 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].

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

در روش‌های خوشبندی، 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]:

۳-۲ روش خوشبندی کاهشی^۱

خوشبندی کاهشی یکی از روش‌های معمول ایجاد قوانین فازی اولیه می‌باشد. در این الگوریتم هر نقطه به عنوان یک پتانسیل برای مرکز خوشة در نظر گرفته می‌شود. پتانسیل تخصیص داده شده به مرکز هر خوشه به فاصله‌ی آن از نقاط دیگر واگسته است. بعد از محاسبه پتانسیل برای هر نقطه، نقطه‌ای که دارای بالاترین پتانسیل است به عنوان مرکز خوشه انتخاب می‌شود. پس از آن، اندازه پتانسیل هر نقطه تصحیح می‌شود، به طوری که پتانسیل داده‌هایی که نزدیک اولین مرکز خوشه هستند به طور قابل توجهی 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 خوشبندی 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].

^۱ Subtractive clustering

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

با توجه به اینکه شبکه‌ی فازی-عصبی ایجادشده دارای یک خروجی است می‌توان مسئله را به چند مسئله‌ی باینری تبدیل کرد و سپس بر اساس خروجی‌ها، کلاسی داده‌ی مربوطه را مشخص نمود. در این تحقیق از روش یکی در مقابل همه^۵ برای طبقه‌بندی چند کلاسی استفاده شده است. این روش ساده‌ترین روش تبدیل مسئله‌ی طبقه‌بندی میان k کلاس به k مسئله‌ی باینری است به‌طوری‌که 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.

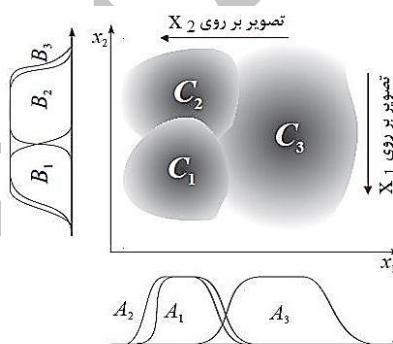
۳- روش کار

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 کاوشی و تقسیم‌بندی گریدی)، قوانین فازی استخراج می‌گردد و سپس با استفاده از 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.

⁵ One-Versus-All (OVA)

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

در این رابطه j نشان‌دهنده هر متغیر، i و k نشان‌دهندهتابع عضویت آن متغیر، l نمایانگر داده‌های آن متغیر و S میزان همپوشانی توابع عضویت می‌باشد. λ را مقداری بین $0/0$ تا $0/85$ تعریف می‌کنند و اگر مقدار $\lambda > S$ باشد، آن دوتابع عضویت جدیدی دارای همپوشانی زیادی هستند و تابع عضویت جدیدی با میانگین‌گیری پارامترهای آن دوتابع 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 به‌وسیله‌ی خوشه‌بندی به وجود می‌آید [۲۶]

۶-۲- روش‌های طبقه‌بندی چند کلاسی^۱

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

¹ Multiclass Classification

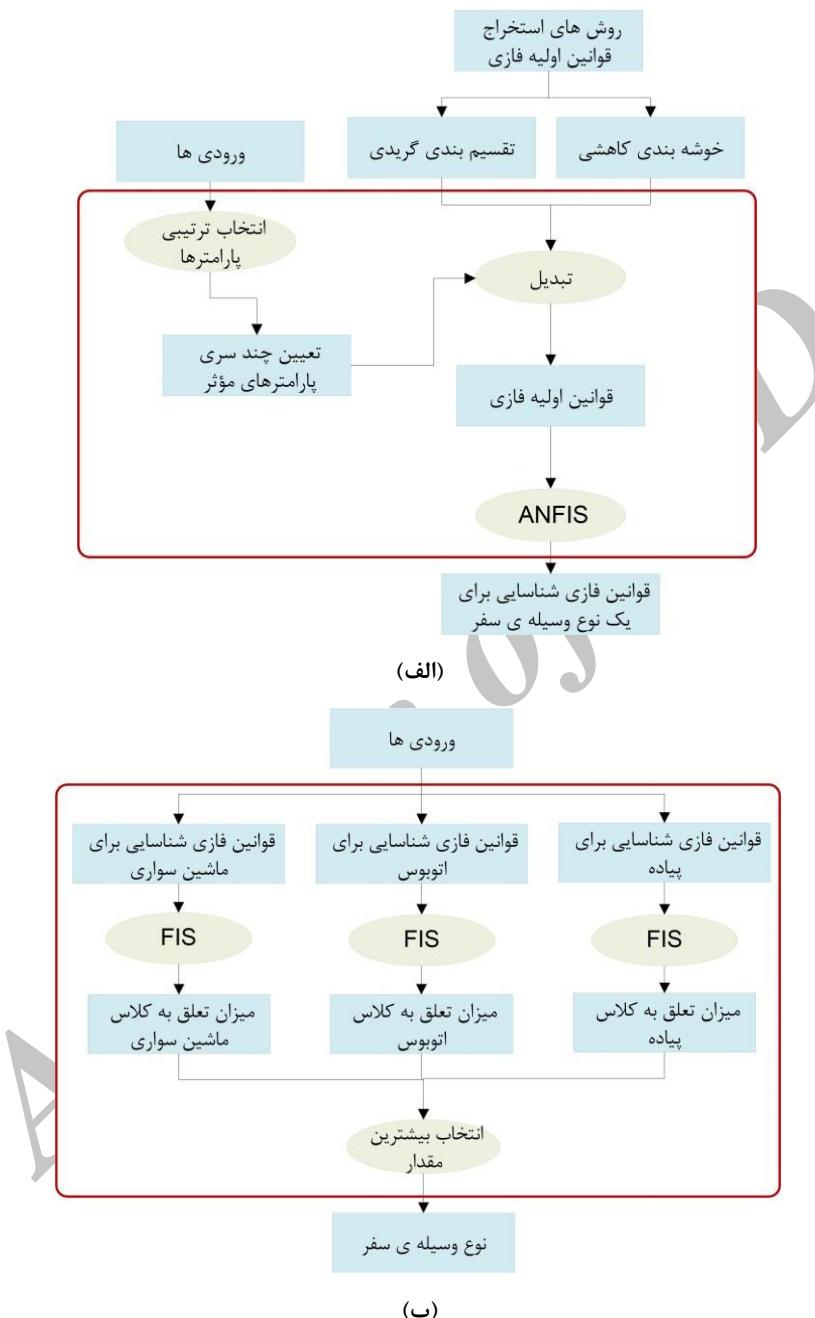
² Decision Trees

³ K-Nearest Neighbor

⁴ Naive Bayes Classifiers

کلاسی که بیشترین مقدار تعلق را دارد، نوع وسیله‌ی سفر ورودی را تعیین می‌کند.

بدین گونه که ورودی‌ها وارد قوانین فازی شده و میزان تعلق به هر کلاس به دست می‌آید. سپس



شکل ۵ : مدل مفهومی تحقیق

این داده‌ها شامل ۱۲۰ سفر می‌باشد که

۱-۱- 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].

متوجه می‌بینیم سرعت به عنوان داده‌های 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 داده شده با GPS قرار دارد، برآورده از عدم قطعیت دقت افقی است. این مقدار برای حالات مختلف سفر متفاوت خواهد بود. به عنوان 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 به عنوان پارامتر ورودی در نظر گرفته شده است. این پارامتر در حالات 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 به طور 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^۱ از ایالت فلوریدا با استفاده از برنامه کاربردی^۲ بر روی گوشی‌های موتورولا^۳ ۸۷۰۱ و موتورولا^۴ ۵۸۰ 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 واسطه 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 ماشین‌سواری، 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 ماشین‌سواری نمایش داده شده است.

۲-۳- پارامترهای مؤثر در تعیین نوع سفر

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

۳-۱- در حالت شناسایی نوع وسیله‌ی سفر

با استفاده از کل نقاط GPS مشخصه‌هایی از داده‌های GPS که تفاوت بارزی بین حالات مختلف سفر دارد باید انتخاب گردد، 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،۹]، برآورد عدم قطعیت

¹ Tampa

² Java ME application TRAC-IT

³ Motorola

جدول ۱: نمونه‌ای از داده‌های جمع‌آوری شده

زمان	عدم قطعیت دقت قائم (دسمتر)	عدم قطعیت دقت افقی (دسمتر)	سرعت (متر بر ثانیه)	عرض جغرافیایی (درجه)	طول جغرافیایی (درجه)	شناسه سفر
۱۶:۴۱:۵۱	۴۷/۰۸۸۰۰۱۲۵	۲۴/۵۲۱۹۹۹۳۶	۱۳/۳۳۳۳۳۳۰۲	- ۸۲/۴۰۶۱۲۷۹۳	۲۸/۰۹۰۰۰۲۰۶	۱۵۳۳
۱۶:۴۱:۵۶	۵۱/۷۵	۲۷/۹۷۴۰۰۰۹۳	۱۴/۴۴۴۴۴۴۶۶	- ۸۲/۴۰۵۷۲۳۵۷	۲۸/۰۹۰۳۶۴۴۶	۱۵۳۳

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

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

انحراف معیار سرعت بین نقاط بحرانی با استفاده از سرعت متوسط بین هر دو نقطه بحرانی به دست می‌آید. انحراف معیار وزن دار سرعت بین نقاط بحرانی با به کارگیری سرعت متوسط بین هر دو نقطه بحرانی و در نظر گرفتن فاصله بین نقاط بحرانی به عنوان وزن آنها محاسبه می‌گردد.

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

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

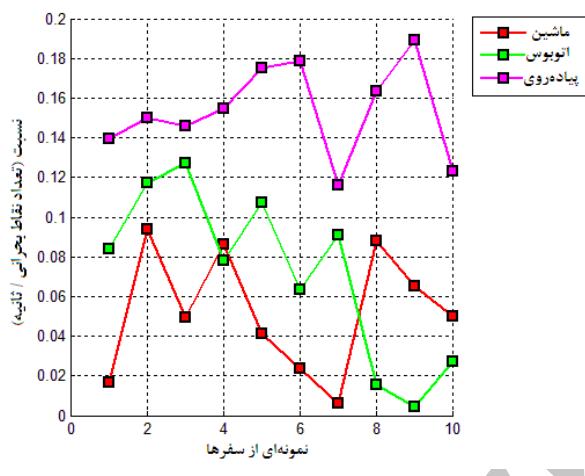
شناسایی نوع وسیله‌ی سفر با استفاده از نقاط بحرانی از مزایای فراوانی برخوردار است؛ زیرا تنها مشخصات این نقاط به سرور انتقال داده می‌شوند. بنابراین بیشتر پارامترهای ورودی ذکر شده برای حالت قبل در اینجا کارا نمی‌باشد. برای مثال برای تعیین انحراف معیار فاصله‌ها بین مکان‌های توقف و میانگین زمان توقف، کل داده‌های 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 زمان سفر، کل فاصله‌ی سفر و فاصله‌ی متوسط بین نقاط بحرانی [۵]، انحراف معیار سرعت بین نقاط بحرانی و انحراف معیار وزن دار سرعت بین نقاط بحرانی.

محاسبه 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^۱ و همکاران از الگوریتم تغییر یافته‌ی نقاط بحرانی استفاده نمودند که در آن سرعت و زمان برای نقاط GPS بلا فاصله قبل یا بعد از نقاط بحرانی نیز ثبت می‌شود. با داشتن دو زمان و سرعت در هر نقطه بحرانی شتاب متوسط برای آن زمان

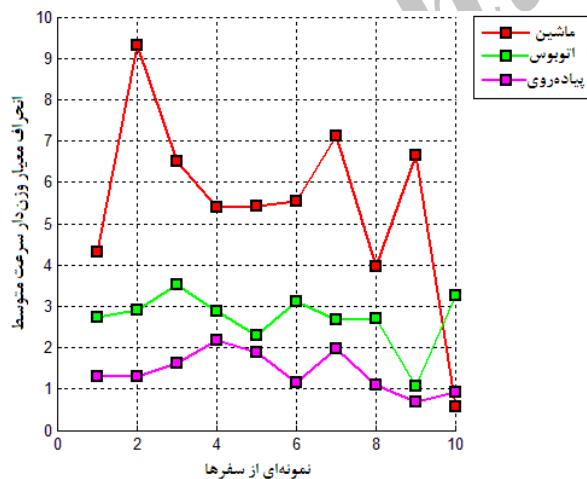
^۱ Gonzalez

شناسایی خودکار نوع وسیله‌ی سفر از داده‌های GPS ... الهه خزاعی، علی اصغر آل شیخ، محمد کریمی

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 وزن دار 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.



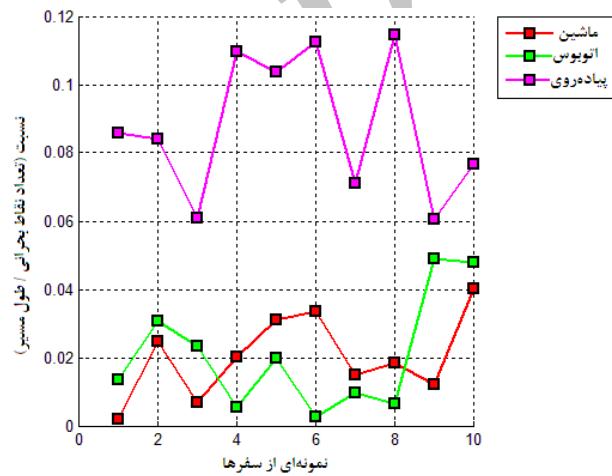
ب: نسبت تعداد نقاط بحرانی به زمان سفر برای چند سفر



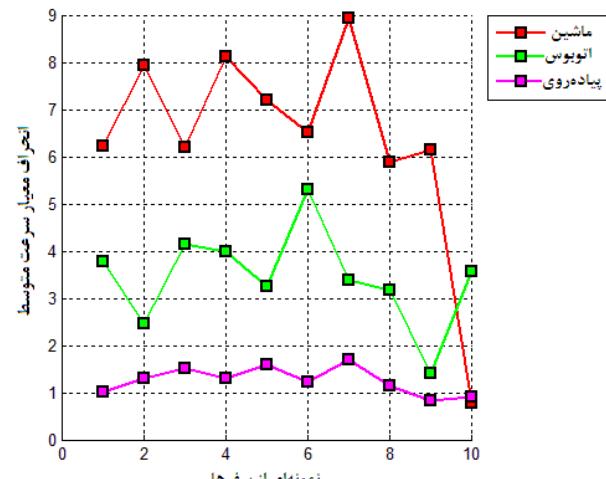
د: انحراف معیار وزن دار سرعت متوسط بین نقاط بحرانی برای چند سفر

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 استخراج شده از داده‌ها برای چند سفر

نقاط بحرانی و جدول (۳) برای کل داده‌های GPS انتخاب گردید. در این جداول هر سطر نمایانگر پارامترهایی است که به عنوان 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 وزن‌دار سرعت متوسط پارامترهای ورودی به شبکه برای شناسایی نوع وسیله‌ی سفر در حالت استفاده از نقاط بحرانی می‌باشد.

۴-۳ آموزش و تست شبکه‌ی ANFIS

به منظور آموزش شبکه‌ی ANFIS، پارامترهای توضیح داده شده 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 داده شده است. به عنوان نمونه اگر داده‌ای مربوط به کلاس اتوبوس باشد برای به دست آوردن قوانین شناسایی اتوبوس خروجی آن داده را ۱ و در به دست 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.

۳-۳-۳ 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^۱ استفاده شد. انتخاب ترتیبی پارامترها رو شی 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^۲ الگوریتم بدون هیچ متغیری آغاز می‌شود و یکی، یکی متغیرها اضافه می‌گردد و در هر گام متغیری که خط را بیشتر از بقیه کاهش می‌دهد نگه داشته می‌شود و به همین ترتیب ادامه می‌یابد تا زمانی که خطا تغییر زیادی نکند ولی در انتخاب رو به عقب^۳ الگوریتم با تمام متغیرها آغاز می‌شود و یکی یکی متغیرها حذف می‌شود و در هر مرحله متغیری حذف می‌گردد که با حذف آن خط کاهش یابد و به همین 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^۴ و با تکرار به دست آمد و چند سری پارامتر انتخاب شد. بر این اساس پارامترهایی مطابق جدول (۲) برای شناسایی با

¹ Sequential Feature Selection

² Forward selection

³ Backward selection

⁴ Cross validation

شناختی خودکار نوع وسیله‌ی سفر از داده‌های GPS ...
اله خزاعی، علی اصغر آل شیخ، محمد کریمی

جدول ۲ : پارامترهای به دست آمده برای استفاده از نقاط بحرانی

شناختی پارامترها	بیشینه شتاب	متوسط شتاب	بیشینه سرعت	متوسط سرعت	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 به دست آمده برای استفاده از کل داده‌های GPS

شناختی 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 خطأ و روش ترکیبی پس‌انتشار خطأ و کمترین مربعات استفاده شد. برای ایجاد قوانین اولیه خوش‌بندی کاهشی و

جدول ۴ : کدگذاری روش یکی در مقابل همه

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

۳-۵-۳- ارزیابی دقت

در این تحقیق برای تحلیل عملکرد و مؤثر بودن روش به کار گرفته شده برای تعیین نوع وسیله‌ی سفر از معیار دقت^۲ (رابطه (۲))، یادآوری^۳ (رابطه (۳)) و صحت^۴ (رابطه (۴)) استفاده گردید، که به صورت زیر تعریف می‌گردد:

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

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

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

که پارامترها در این فرمول‌ها در یک دسته‌بندی دو کلاسی عبارتند از، TP تعداد داده‌های درست طبقه‌بندی شده در کلاس دو، FP تعداد داده‌هایی که در کلاس اول قرار دارند و اشتباه طبقه‌بندی شدند، FN تعداد داده‌هایی است که در کلاس دوم قرار دارند و اشتباه طبقه‌بندی شدند، و TN تعداد داده‌های درست طبقه‌بندی شده در کلاس یک می‌باشد. به عبارتی می‌توان معیارها را به صورت کیفی زیر بیان نمود:

معیار دقت: نسبت تعداد داده‌های درست طبقه‌بندی شده به تعداد کل داده‌های طبقه‌بندی شده برای همان کلاس.

معیار یادآوری: نسبت تعداد داده‌های درست طبقه‌بندی شده به تعداد کل داده‌های مربوط به همان کلاس.

معیار صحت برای ارزیابی کل طبقه‌بندی انجام شده به کار می‌رود که عبارت است از نسبت مجموع تمام داده‌های درست طبقه‌بندی شده تمام کلاس‌ها به تمام داده‌ها.

تقسیم‌بندی گردیدی به کار گرفته شد. در خوشبندی کاهشی فاصله‌ی مؤثر ۰/۴۵ در نظر گرفته شد. این مقدار با سعی و خطا به دست آمد. همان‌طور که ذکر شد قوانین فازی سوگنو برای به کار بردن در این شبکه ایجاد می‌شود. قوانین سوگنو در دو حالت مرتبه‌ی صفر و مرتبه‌ی 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 داده‌ها، برای ارزیابی دقت از اعتبارسنجی ۱۰ لایه‌ای^۱ استفاده گردید. در اعتبارسنجی k لایه‌ای، داده‌ها به‌طور تصادفی به k قسمت تقسیم می‌شوند و سپس یک قسمت به عنوان داده‌های تست و $k-1$ قسمت باقیمانده به عنوان داده‌های آموزشی به کار گرفته می‌شوند. این فرآیند k مرتبه با در نظر گرفتن یک قسمت متفاوت به عنوان داده‌های تست تکرار می‌شود. داده‌های آموزشی با خروجی مربوط به هر کلاس به‌طور جداگانه برای ایجاد قوانین ANFIS اولیه و همچنین آموزش شبکه به کار گرفته می‌شوند و پس از آموزش شبکه، داده‌های تست وارد هر سه سری قوانین شناسایی نوع سفر شده و کلاسی که بیشترین مقدار خروجی را دارا می‌باشد به عنوان نوع وسیله‌ی سفر برای آن داده در نظر گرفته می‌شود. به علت اینکه در اعتبارسنجی ۱۰ لایه‌ای داده‌ها به‌طور تصادفی تقسیم می‌گردند، برای اینکه نتیجه بهینه باشد، نتایج نهایی با ۲۰۰ بار تکرار اعتبارسنجی ۱۰ لایه‌ای به دست آمد.

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

² Precision accuracy

³ Recall accuracy

⁴ Accuracy

^۱ 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 به کارگیری پارامترهای بیشینه سرعت، سرعت متوسط، انحراف معیار سرعت متوسط بین نقاط بحرانی و انحراف معیار وزن دار 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 وزن دار 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 وزن دار 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 وسیله 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 شماره‌ی ۱) به عنوان ورودی و با در نظر گرفتن قوانین سوگنو مرتبه‌ی اول و ایجاد قوانین اولیه با خوشبندی کاهشی و آموزش با روش ترکیبی پس انتشار خطأ و کمترین مربعات، قوانین حاصله دارای دقت شناسایی نوع وسیله‌ی سفر $94/87\%$ 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 وسیله 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؛ به گونه‌ای 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 وزن دار سرعت متوسط (سطر شماره‌ی ۱) به عنوان ورودی و با در نظر گرفتن قوانین سوگنو مرتبه‌ی اول و ایجاد قوانین اولیه با خوشبندی کاهشی و آموزش با روش ترکیبی پس انتشار خطأ 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 وسیله سفر از یک سری پارامترهای یکسان به عنوان ورودی استفاده نمایند. به کارگیری روش طبقه‌بندی چند کلاسه‌ی یکی در مقابل همه این قابلیت را دارد که برای شناسایی هر نوع وسیله سفر از مجموعه پارامترهای متفاوت به عنوان 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 ^a -sub ^b -Hyb ^c	۹۴,۸۷	۹۵,۴۹	۹۱,۴۵	۸۸,۴۲	۹۴,۹۵	۱۰۰	۹۹,۹۲
۲	Zero ^d -Grid ^e -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 ^f	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

Zero^d: قوانین سوگنو مرتبه‌ی صفرGrid^e: ایجاد قوانین با تقسیم‌بندی گردیدیBP^f: آموزش با استفاده از روش ترکیبیOne^a: قوانین سوگنو مرتبه‌ی اولSub^b: ایجاد قوانین با خوشبندی کاهشیHyb^c: آموزش با استفاده از روش ترکیبی

جدول ۶: بهترین نتیجه به دست 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 ^a -sub ^b -BP ^c	۹۴,۰۱	۹۴,۶۱	۹۰,۲۵	۸۹,۶۹	۹۴,۲۰	۹۷,۲۴	۹۹,۶۹
۲	One-sub-Hyb ^d	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 ^e -grid ^f -Hyb	۹۳,۷۵	۹۱,۶۴	۹۲,۳۴	۹۳,۱۳	۹۲,۲۶	۹۶,۶۲	۹۸,۰۱

Hyb^d: آموزش با استفاده از روش ترکیبیZero^e: قوانین سوگنو مرتبه‌ی صفرGrid^f: ایجاد قوانین با تقسیم‌بندی گردیدیOne^a: قوانین سوگنو مرتبه‌ی اولSub^b: ایجاد قوانین با خوشبندی کاهشیBP^c: آموزش با استفاده از روش پس انتشار خطای

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 به دست آمده از ترکیبات مختلف پارامترها

	میانگین زمان توقف	بیشینه سرعت	عدم قطعیت دقت افقی	یادآوری (٪)	دقت (٪)
ماشین سواری	✓	✓✓	✓	۹۰/۹۳	۹۳/۰۵
اتوبوس	✓	✓	✓	۹۳/۶۷	۹۱/۰۴
پیاده	✓	✓	✓	۹۷/۳۲	۹۹/۸۶
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 به دست 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 خطای 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 به صورت 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 به دست آمده 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 استخراج شده از داده‌های GPS به صورت 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 به منظور 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 انجام شده توسط گنزالز و همکاران که با استفاده از شبکه‌ی عصبی به استخراج خودکار نوع وسیله‌ی سفر پرداخته شده بود دقت شناسایی در حالت استفاده از نقاط بحرانی ۹۱/۲۳٪ و در حالت استفاده از

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

سپاسگزاری

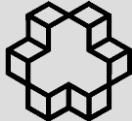
از دکتر باربیو^۱ از دانشکده حمل و نقل دانشگاه فلوریدا جنوبی برای در اختیار گذاشتن داده‌های مورد نیاز این تحقیق سپاسگزاریم.

¹ 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 ^{*1}, Ali Asghar Alesheikh ², Mohammad Karimi ³

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