



### (مدیریت هوشمند مترو در شهر مشهد بر پایه الگوریتم های هوش ازدحامی بهینه شده)

نگین حشمتی<sup>۱</sup>

دانشجوی کارشناسی، گروه مهندسی راه آهن، دانشکده مدیریت مهندسی، دانشگاه صنعتی کرمانشاه، کرمانشاه، ایران

مهدی فلاحي<sup>\*۲</sup>

عضو هیئت علمی، گروه مهندسی راه آهن، دانشکده مدیریت مهندسی، دانشگاه صنعتی کرمانشاه، کرمانشاه، ایران

#### چکیده

امروزه مترو یکی از سریع ترین و کاراترین وسایل حمل و نقل عمومی است که کشورهای مختلف به دنبال ساخت بسترهای آن می باشند. به دلیل کاهش آلودگی های زیست محیطی، ترافیکی و همین طور کم هزینه بودن و سرعت جابجایی سریع مسافران، استفاده از مترو به شدت در کشورهای پیشرفته و در حال توسعه مقرون به صرفه است. از این رو، ارائه سیستم های هوشمند برای مدیریت کارآمد، امری ضروری است. در شهرهای مختلف ایران، مترو در حال گسترش است و مدیریت هوشمند آن تحت مسئله مسیریابی، نیازمند بررسی های دقیقی است تا با حداقل مصرف زمان و هزینه برای کاربران همراه باشد. لذا ارائه یک روش مدیریت هوشمند برای مسئله مسیریابی در متروی شهر مشهد، ایران، با الگوریتم های تکاملی و هوش ازدحامی مدنظر قرار می گیرد تا بتوان ساختار دقیقی برای تحقق اهداف و چالش ها، ارائه نمود. الگوریتم پیشنهادی این تحقیق، ترکیب الگوریتم ژنتیک NSGA-II و الگوریتم ازدحام ذرات بهینه دودویی توسعه یافته است.

**واژگان کلیدی:** مدیریت هوشمند، مسیریابی مترو، یادگیری ماشین، الگوریتم ازدحام ذرات دودویی بهینه

<sup>1</sup> Negin.heshmati78@gmail.com  
<sup>\*2</sup> Mehdi.fallahi@gmail.com



### 1- مقدمه

امروزه با توجه به افزایش بسیار زیاد هزینه های توسعه شبکه های خیابانی برای استفاده وسایل نقلیه شخصی و پیامدهای منفی آن، توسعه سیستم های حمل و نقل همگانی به عنوان یک راه حل اصولی برای شهرهای بزرگ محسوب می شود و در بسیاری از شهرهای با بیش از یک میلیون نفر جمعیت، علاوه بر اتوبوس از سیستم های دیگری نیز استفاده می شود. این سیستم ها برای نیل به اهداف متفاوتی از جمله افزایش راحتی و امنیت سفر، کاهش آلودگی هوا و حفظ محیط زیست، کاهش زمان سفر و حل مشکلات ترافیکی ناشی از تردد وسایل نقلیه شخصی ایجاد می شوند. از میان سیستم های حمل و نقل همگانی، مترو به دلیل امتیازات عملکردی اش نسبت به سایر سیستم ها دارای توجه بیشتری در شهرهای بزرگ است. مترو، سیستمی است که در مسیرهای خاص و زیرزمینی و بعضاً بر روی زمین و به صورت مجزا از سایر وسایل نقلیه و عابرین، حرکت می کند. با توجه به این که مسیرهای مختلفی در مترو وجود دارد، لذا حرکت مسافران از مبدا تا مقصد، با توجه به مسیرها، می بایست به صورتی بهینه باشد تا در سریع ترین زمان ممکن به مقصد برسند. یکی از مهمترین مولفه های ترافیک، حجم ترافیکی است که ورودی اکثر سیستم های حمل و نقل محسوب می شود. در حجم ترافیکی، مبحثی به نام حجم متوسط ترافیک روزانه وجود دارد که متوسط ترافیک روزانه در سال را مجموع حجم ترافیک سالیانه تقسیم بر 365 می باشد (Vlahogiann, 2007).

بهینه سازی زمان بندی در مسیریابی مترو به عنوان یکی از مسائل مهم در حوزه تحقیق در عملیات ساخته می شود. در واقع به کارگیری یک دانش جهت تحلیل با هدف یک سازوکار تصمیم گیری مناسب برای رسیدن به یک راه حل، می تواند تحقیق در عملیات را تشریح نماید. اجرای تصمیم مناسب تر از داده های پیچیده با در نظر گرفتن تمامی شرایط و محدودیت های آن ها با هدف رسیدن به یک پیش بینی دقیق و بررسی میزان ریسک، یک سیستم تصمیم گیری را ارائه می نماید که بر پایه مدل های ریاضیاتی است. پیش بینی در بسیاری از مسائل و مشکلات دنیای واقعی اعم از ترافیک جاده ای، ترافیک اینترنتی، ازدحام در خیابان ها و غیره، مورد استفاده واقع می شود تا بتوان عامل اصلی را کشف و دانشی از این قضیه را به دست آورد. در پیاده سازی این پروژه که به پیش بینی مسیر مترو در شهر تهران می پردازد، سعی در ارائه یک روش مناسب در مسیریابی با حداقل زمان مصرفی و بهترین دقت در پیمودن مسافت بین ایستگاه های مختلف خواهد بود.

### 2- مروری بر پیشینه تحقیق

تقسیم بندی یک شبکه پیچیده از معابر درون شهری به گروه ها و سامانه هایی که خصوصیات مشابهی دارند را طبقه بندی معابر درون شهری می گویند. راه به مجموعه ای از معابر است که برای وسایل نقلیه موتوری، دوچرخه و عابر پیاده ساخته می شود. به راه های درون شهری، خیابان اطلاق می شود. معبری که در تمام طول آن ترافیک دو طرف به طور فیزیکی کاملاً تفکیک شده است و نحوه طراحی آن به گونه ای است که جریان ترافیک در آن بدون توقف باشد را آزادراه می گویند. برای تامین چنین شرایطی در این معابر، تقاطع ها باید از نوع غیر هم سطح بوده و نحوه ورود و خروج وسایل نقلیه به آن کاملاً کنترل شده و بر اساس طراحی های صحیح انجام شود. معابری که ارتباط بین



کاربری ها و واحدهای مسکونی را فراهم ساخته و آن ها را به خیابان جمع و پخش کننده متصل می نماید، معابر محلی گویند. معابر محلی نباید در اختیار ترافیک عبوری، قرار گیرند. تعداد وسیله نقلیه ای که در واحد زمان (ساعت) از مقطع مشخصی از راه می گذرد، حجم ترافیک می گویند. حجم ترافیک روزانه، حجم ترافیکی است که در طی یک شبانه روز از مقطع مشخصی از راه می گذرد. بیشترین تعداد وسایل نقلیه ای که عبور آن ها در ظرف مدت یک ساعت با کیفیت معین ترافیک از مقطع مشخصی از راه امکان پذیر باشد را ظرفیت می گویند. مسیر معمولاً یک طرفه ای که دو معبر مختلف را به یکدیگر مرتبط می دهند را رمپ یا شیبراهه می گویند ( Street Design and Community Livability, 2000).

پیش بینی در مسیرهای مترو و خطوط راه آهن شهری و بین شهری در زمینه و جنبه های مختلف مورد بررسی واقع شده است. به طور مثال در مطالعه (Guang, et al., 2017) یک شبکه بیزین<sup>1</sup> جهت پیش بینی خطاهای ممکن در زمان ناپایداری آب و هوا ارائه شده است. در واقع یک پیش بینی از وضعیت آب و هوا جهت تاثیر در ریل های خطوط آهن انجام گرفته است که از یک مجموعه داده آب و هوا و یک مجموعه داده وضعیت ریل ها استفاده گردیده است. در یک تحقیق دیگر که در مطالعه (He, et al., 2017) ارائه شده است، پیش بینی تضاد زمان بندی در خطوط پر سرعت راه آهن مبتنی بر دانش فازی<sup>2</sup> انجام گرفته است. کاری که این تحقیق ارائه می دهد، ایجاد یک سامانه پیش بینی در زمان بندی خطوط راه آهن جهت حضور قطار یا مترو در ریل است. در مطالعه (Wei, et al., 2016) انتخاب مجموعه مسیر با اطلاعات عملیاتی در شبکه های مترو ارائه شده است. این تحقیق به دو بخش تقسیم می شود. در ابتدا در رابطه با انتخاب مسیر به صورت بهینه بحث می کند. سپس روشی برای این منظور را ارائه می نماید که بسیار بهینه باشد.

پژوهش های دیگری نیز در حوزه های دیگر سامانه های حمل و نقل انجام گرفته است. در مطالعه (Neveu, 1983) از رگرسیون با استفاده از پارامترهای جمعیت، میزان مالکیت خودرو، تعداد خانوار و شاغلین در یک خانواده، جهت تخمین حجم ترافیک در یک سال استفاده کرده است. در مطالعه (Zhao and Chung, 2001) مدلی از رگرسیون چندگانه با استفاده از تعداد خطوط، کاربری زمین، نوع مسیر و شرایط اقتصادی را ارائه داده اند. در مطالعه (Sharma, et al., 1999) از شبکه عصبی متناوب برای تخمین 63 محل در شبکه بزرگراه ایالت مینسوتا در امریکا استفاده کردند. نتیجه این پژوهش که رویکرد استفاده از شبکه عصبی در روش های بعدی تخمین و پیش بینی ترافیک نیز بود، این است که شبکه عصبی هنگامی که ایستگاه های شمارش به طور مناسب دسته بندی شده اند، همانند سایر روش های کلاسیک تخمین حجم ترافیک عمل می کند و بهتر از آن ها نیست.

در مطالعه (Eleni I., 2008) به رویکرد شناسایی رویدادهای غیربازگشتی در ترافیک شهری پرداخته است. روش ارائه شده به شناسایی و پیش بینی جریان ترافیک برپایه استفاده از تحلیل غیرخطی با استفاده از شبکه عصبی احتمالاتی می پردازد. در واقع قرار است عملیات الگوشناسی برای پیش بینی ترافیک انجام پذیرد. سه الگو به عنوان الگوهای زمانی در نظر گرفته شده اند که شامل پایایی، غیرپایایی و منحصر بفردی (غیرخطی بودن) است. در مطالعه (Wen, et al., 2011) به پیش بینی تصادفات در بزرگ راه ها به صورت بلادرنگ پرداخته اند که رویکرد استفاده آن ها برپایه تحلیل انتروپی رابطه خاکستری و شبکه عصبی احتمالاتی است. معیار اصلی این پژوهش، نمایش تلاطم در

Bayesian Network<sup>1</sup>  
Fuzzy Knowledge<sup>2</sup>



جریان ترافیکی است که بر اساس انتروپی رابطه خاکستری تحلیل می شود و جهت شناسایی و پیش بینی بلادرنگ تصادفات بزرگ راه به صورت بلادرنگ از شبکه عصبی احتمالاتی استفاده می شود.

در مطالعه (Raveau, et al., 2014) یک مقایسه رفتاری انتخاب مسیر در شبکه های مترو انجام شده است که بر اساس یک سری معیارها شامل زمان، حمل و نقل مسافران، ازدحام، هم بندی در شناخت مسیر و جمعیت شناسی در حوزه مترو است. مدل انتخاب مسیر به شبکه زیرزمینی متروی شهر لندن در انگلستان و همینطور متروی سانتیاگو در شهر مادرید در اسپانیا اعمال شده است و مقایسه ای کلی بین تصمیم گیری مسافران در بین مسیرهای کوتاه در خطوط این دو متروی متفاوت، انجام شده است. همین طور شناخت مسیرهای کوتاه در خطوط دو متروی نام برده نیز مقایسه شده اند. به صورت کلی بررسی شده است که مسافران در متروی لندن، به قدم زدن در حاشیه مترو به منظور به دست آوردن یک جای مناسب جهت نشستن بیشتر اهمیت می دهند تا این که سریع تر به مقصد برسند، اما مسافران در متروی سانتیاگو ترجیح به منتظر ماندن برای رسیدن مترو و سریع سوار شدن و رسیدن به مقصد هستند.

یکی از اولین تحقیقات انجام شده در زمینه مسیریابی خطوط حمل و نقل رساله دکتری ارائه شده در مطالعه (Decesare, 1970) است که مسئله را به صورت یافتن مسیری با کمترین هزینه بین مبدا و مقصد مطرح نموده و آن را مدل کرده است. روش ارائه شده در مطالعه (Decesare, 1970) در (Current, et al., 1985) بهبود بخشیده شد. در (Current, et al., 1985) مسیری با حداکثر پوشش و مدل کوتاه ترین مسیر با حداکثر جمعیت ارائه شده است. هر دو مدل، گزینه ها را با توجه به هزینه های ساخت و میزان منافع اجتماعی، ارزیابی می کنند و به صورت برنامه ریزی عدد صحیح، مدل سازی شده اند. در مطالعه (Dufourd, et al., 1996) مکان یابی یک خط حمل و نقل سریع را توسط الگوریتم جستجوی ممنوعه مورد توجه قرار دادند. تابع هدف در الگوریتم ارائه شده، ماکسیم نمودن پوشش جمعیتی مسیر می باشد. در مطالعه (Bruno, et al., 1998) مدلی ارائه شده است که در آن وسیله نقلیه ضعیف، رقیب وسیله نقلیه همگانی شده است. در این مطالعه فرض بر آن است که کاربران، سیستم های حمل و نقل را به گونه ای انتخاب می کنند که هزینه های آن ها کمینه شود. در مطالعه (Bruno, et al., 2002) مطالعه انجام شده است که در آن هدف، بیشینه کردن جمعیت پوشش داده شده توسط مسیر است. در مطالعه (Laporte, et al., 2005) مفهوم پوشش سفر برای ایستگاه مطرح شده است و با استفاده از یک روش تکاملی و محدودیت حداکثر طول امتداد، به حل مسئله مسیریابی پرداخته شده است.

### 3- رویکرد پیشنهادی

در ابتدا داده ها نرمال سازی می شوند. لذا لازم است برای عملیات بعدی، ویژگی های آن ها استخراج شوند. داده ها بعد از نرمال سازی به الگوریتم ژنتیک NSGA-II سپرده می شوند تا در حالت نرمالی از آن با حذف داده های پرت حاصل شود. الگوریتم ژنتیک NSGA-II به دلیل حالت تصادفی و مکانیزم آموزشی که دارد، مدنظر این تحقیق خواهد بود. در این روش فرض می شود که داده های ورودی  $n$  تایی در  $m$  خوشه قرار می گیرند و خوشه ها دارای آرایش یک بعدی یا دو بعدی منظم هستند. بردار وزن برای هر خوشه بردار نمونه الگوهای ورودی پیوند یافته با آن خوشه به شمار می آید. لازم به ذکر است که الگوریتم ژنتیک NSGA-II بعد از عملیات استخراج ویژگی، شروع به دادن ویژگی ها به الگوریتم ازدحام ذرات بهینه دودویی توسعه یافته جهت پیش بینی داده ها خواهد نمود. اما در این گام ها نیز چند چالش پیش رو است. اول انتخاب داده ها مورد نیاز و حذف داده های پرت جهت استخراج ویژگی که در خود





دو بخش اصلی یعنی کاهش ابعاد و انتخاب ویژگی و در نهایت استخراج ویژگی را دارد، سپس انتخاب تعداد کلاس ها و به موازات آن، انتخاب روشی به عنوان معیار فاصله برای داده های ترکیبی است. اگر داده های قرار گرفته در یک کلاس دارای ویژگی های نشان داده شده در جدول (1) با مشخصات تعیین شده باشند، مقدار این ویژگی ها در هر کلاس مربوطه در جدول (2) نشان داده شده است.

جدول 1. مثالی از یک اطلاعاتی مربوط به داده های قرار گرفته در یکی از کلاس ها

ویژگی 4	ویژگی 3	ویژگی 2	ویژگی 1	ویژگی خصوصیت
عددی	عددی	رسته ای	رسته ای	نوع
0.4	0.1	-	-	میانگین
		{v <sub>2,1</sub> , ..., v <sub>2,M</sub> }	{v <sub>1,1</sub> , ..., v <sub>1,N</sub> }	دامنه مقادیر
-	-	v <sub>2,4</sub>	v <sub>1,1</sub>	مقدار با بیشینه تکرار

جدول 2. مقادیر ویژگی های هر کلاس

ویژگی 4	ویژگی 3	ویژگی 2	ویژگی 1
0.4	0.1	v <sub>2,4</sub>	v <sub>1,1</sub>

علاوه بر این تعریف برای جایگزین شدن با رقابتی ساده، یکی دیگر از مواردی که در مورد کلاس بندی پیشنهاد می شود تا مطابق شرایط حاصل از وجود داده های ترکیبی شود، تعریف معیار فاصله مناسب بوده است. اگر دو داده  $X = \{x_1, x_2, \dots, x_N\}$  و  $Y = \{y_1, y_2, \dots, y_N\}$  در نظر گرفته شود، معیار فاصله تعریف شده برای این دو داده که بسطی بر رابطه اقلیدسی بوده است به صورت رابطه (1) تعریف می گردد.

$$d(X, Y) = \alpha \cdot distance(num(X), num(Y)) + \beta \cdot diff(cat(X), cat(Y)) \quad (1)$$

که در رابطه (1)،  $distance(num(.))$  فاصله اقلیدسی میان دو داده با ویژگی های عددی را محاسبه می نماید، داده هایی که توسط تابع  $num(.)$  حاصل می گردند. در حقیقت تابع  $num(.)$  از یک داده، تنها ویژگی های عددی آن را نگاه می دارد و می توان آن را به صورت رابطه (2) نشان داد.

$$num(X) = \{x_i \in feature_{set}(X) | x_i \text{ is numerical}; i \in [1, |X|]\} \quad (2)$$

همچنین در رابطه (2)، تابع  $cat(X)$  از یک داده، تنها ویژگی های رسته ای آن را نگاه می دارد و می توان آن را به صورت رابطه (3) تعریف نمود.

$$num(X) = \{x_i \in feature_{set}(X) | x_i \text{ is categorial}; i \in [1, |X|]\} \quad (3)$$

در نتیجه تابع  $diff(X)$  فاصله میان ویژگی های رسته ای را محاسبه می نماید که می توان بهترین مسیر را انتخاب نمود. این محاسبه بدین صورت است که تعداد ویژگی های نظیر به نظیر که مقادیر متفاوتی با یکدیگر دارند، شمرده شده و حاصل تقسیم بر تعداد این ویژگی ها می شود. در رابطه (3)، پارامترهای  $\alpha, \beta \in [0, 1]$  وزن هر یک از دو بخش عددی و رسته ای را در تعیین فاصله داده ها تعیین می نمایند. تا به این جا، استخراج ویژگی با الگوریتم ژنتیک NSGA-II انجام می شود. لازم به ذکر است که پس از تفکیک ویژگی ها به کلاس های مختلف، در مورد این که با هر



کلاس چگونه رفتار شود، بایستی عملیاتی انجام پذیرد. با مشاهده انواع مسیرها مربوط به هر گروه، تعیین می شود که بایستی داده ها و معیارها در چه گروهی قرار بگیرند. بدین منظور کلاس ها، به درستی پیش بینی می شوند. نیاز است تا ویژگی ها استخراج شده، یک بار آموزش ببینند و بهترین ویژگی ها که با الگوریتم ژنتیک NSGA-II مشخص شده اند، مورد آزمون نیز واقع شوند. از این رو، یک شبکه عصبی ساده به نام شبکه عصبی احتمالاتی<sup>1</sup> به نمایش گذارده می شود تا یک آموزش اولیه بر روی ویژگی های استخراج شده نیز صورت بگیرد. شبکه عصبی احتمالاتی از 4 لایه تشکیل شده است: لایه ورودی<sup>2</sup>، لایه الگو<sup>3</sup>، لایه اجماع<sup>4</sup> و لایه خروجی<sup>5</sup>. لایه ورودی، نمونه های آموزش دیده شده را که توسط همان بردار بردار ویژگی از شبکه تصویب می شود را دریافت می کند و تعداد آن از نرون های عصبی برابر با ابعاد بردار نمونه ورودی است. جستجوی رابطه بین بردار ویژه ورودی<sup>6</sup> و هر مدل در مجموعه آموزش در لایه الگو که تعداد آن ها برابر با بُعد بردارهای نمونه است، محاسبه می شود و خروجی لایه از هر واحد با توجه به رابطه (4) و (5) می باشد. در رابطه (4) پارامتر هموارسازی،  $X_{ij}$  بردار نرون است و  $d$  نشان دهنده بُعد بردار الگو است. لایه اجماع به منظور به دست آوردن تخمین چگالی احتمال<sup>7</sup> هر حالت و خروجی آن متناسب با تخمین واحدهای مختلف چگالی احتمال بر پایه هسته است. نرون لایه جمع حداکثر احتمال الگوی  $x$  در حال طبقه بندی که در  $C_i$  هستند، توسط خلاصه سازی و میانگین گرفتن خروجی را محاسبه می کند.

$$\phi_{ij}(x) = \frac{1}{(2\pi)^{\frac{d}{2}} \sigma^d} \exp \left[ -\frac{(x-x_{ij})^T (x-x_{ij})}{2\sigma^2} \right] \quad (4)$$

در رابطه (5)،  $N_i$  نشان دهنده تعداد کل نمونه ها در کلاس  $C_i$  است. اگر احتمال پیش بینی برای هر کلاس مشترک باشد و ضررهای مرتبط با ساخت یک تصمیم نادرست برای هر کلاس مشترک باشد، واحد لایه تصمیم گیری اقدام به طبقه بندی الگوی  $x$  مطابق با قانون تصمیم گیری بیزین<sup>8</sup> بر پایه خروجی از تمام نرون های لایه جمع استفاده خواهد کرد.

$$p_i(x) = \frac{1}{(2\pi)^{\frac{d}{2}} \sigma^d} \frac{1}{N_i} \sum_{j=1}^{N_i} \exp \left[ -\frac{(x-x_{ij})^T (x-x_{ij})}{2\sigma^2} \right] \quad (5)$$

لایه خروجی، حداکثر چگالی احتمال پیشین از نرون ها به عنوان خروجی کل سیستم در تخمین چگالی احتمال را انتخاب می کند. نرون های لایه خروجی نوعی نرون های رقابتی هستند که هر نرون به یک نوع داده که بخشی از طبقه بندی است تعلق دارد و به آن پاسخ می دهد. در شبیه سازی پروژه، ظرفیت طبقه بندی غیرخطی قدرتمند شبکه عصبی احتمالاتی به منظور ارتقای کارایی آموزش داده ها به کار رفته است. بعد از عملیات استخراج ویژگی مبتنی بر الگوریتم ژنتیک NSGA-II و آموزش مبتنی بر شبکه عصبی احتمالاتی، نیاز است تا پیش بینی با تصمیم گیری چندمعیاره مبتنی بر الگوریتم ازدحام ذرات بهینه دودویی توسعه یافته جهت ترکیب این دو بخش با هم و همچنین تعیین معیارها و سپس دسته بندی با هدف پیش بینی بهترین مسیر، انجام شود. پس از تعیین نزدیک ترین کلاس و

1 Probabilistic Neural Network (PNN)  
2 Input Layer  
3 Pattern Layer  
4 Summation Layer  
5 Output Layer  
6 Eigenvector  
7 Probability Density Function (PDF)  
8 Bayesian Decision Rule



متمرکز شدن بر روی داده هایی با شباهت بالا به داده جدید، آن گاه بر این اساس تصمیمی را که برای داده جدید مناسب است، ارائه داده می شود. علت این که تعداد نزدیک ترین داده ها به عنوان فرد در نظر گرفته شود و دلیل آن این بوده است که بتوان میان آن ها رای گیری نمود. همچنین علت این که بیش از یک داده به عنوان نزدیک ترین داده های موثر در تصمیم گیری انتخاب می شود، کاهش اثرات ناشی از وجود نویز و یا داده های دور افتاده بوده یا پرت است. اما این که چگونه بیان شود که یک داده، رای به پیشنهاد یک تصمیم بر اساس سیستم تصمیم گیری چند معیاره می دهد، تنها بدین سادگی نیست که در صورتی که برای آن داده تصمیم خاصی گرفته شده باشد، آن پیشنهاد داده می شود و برعکس. بلکه رفتار بدین صورت است که اگر برای داده  $l_k$  تصمیم  $d$  اتخاذ شده باشد، یک قانون به شکل تصمیم گیری الگوریتم ازدحام ذرات بهینه دودویی توسعه یافته تولید می گردد و سپس استحکام آن را با یافتن احتمالات در مسیریابی مورد سنجش قرار می گیرد. محاسبه احتمالات در میان کل مجموعه داده انجام نمی شود، بلکه تنها از داده های موجود در همان کلاس از مسیر استفاده می گردد تا این مقادیر محاسبه شود. احتمالات برای بخش استخراج ویژگی با قانون  $R = X \rightarrow Y$  به صورت رابطه (6) می باشد.

$$P_{PSO}(R) = \frac{P(XY)}{|D|} \quad (6)$$

و احتمالات برای پیش بینی مبتنی بر الگوریتم ازدحام ذرات بهینه دودویی توسعه یافته و ترکیب با تصمیم گیری چندمعیاره که مبتنی بر عملیات استخراج ویژگی انجام شده با ژنتیک NSGA-II و سپس پیش بینی صحیح با الگوریتم ازدحام ذرات بهینه دودویی توسعه یافته است، به شکل رابطه (7) می باشد.

$$P_{\text{Features,Class}}(R) = \frac{P(XY)}{P(X)} \quad (7)$$

که در فرمول های فوق،  $P(\cdot)$  برابر با تعداد داده هایی از کل مجموعه  $D$  است که در آن ها  $X$  و  $Y$  هر دو وجود دارند. در روش پیشنهادی،  $D$  برابر با کلاس هایی است که نزدیک ترین داده ها از آن انتخاب شده اند. اما یک نکته مهم دیگر که در مورد این قوانین هنوز به آن اشاره نشده است، نحوه تولید آن ها و محاسبه احتمالات با توجه به نوع داده های مد نظر است، که در ادامه به آن ها پرداخته می شود. با توجه به هر یک از داده ها  $l_k$  از مجموعه نزدیک ترین ویژگی ها، یک قانون به شکل تصمیم گیری چندمعیاره الگوریتم ازدحام ذرات بهینه دودویی توسعه یافته تولید می شود. اگر ویژگی های  $l_k$  به دو بخش تصمیم و خصوصیات تفکیک شود، آن گاه می توان کل مجموعه ویژگی ها را به صورت  $I_k = [f_1, \dots, f_n, d_1, \dots, d_m]$  نمایش داد. در این بازنمایی،  $f_i$  نشان دهنده ویژگی هایی نظیر نوع اتصال و  $d_i$  نشان دهنده تصمیم گرفته شده بوده و مقدار 0 یا 1 را می پذیرد. البته بدیهی است که برای هر داده تنها یک تصمیم گرفته شده است و لذا از میان  $d_i$  تا  $d_m$  تنها یکی از آن ها می تواند 1 باشد. حال برای این داده ها تمامی قوانین به شکل رابطه (8) تولید می شود.

$$\begin{aligned} R_1: f_1, \dots, f_n &\rightarrow S_i \\ R_2: f_1, \dots, f_n &\rightarrow S_i \\ &\vdots \\ R_{2n+1}: f_1, \dots, f_n &\rightarrow S_i \\ i &\in [1, m] \end{aligned} \quad (8)$$



همان طور که از رابطه (8) مشخص است، ممکن است برای چند داده یک تصمیم گرفته شده باشد. ارزیابی هر قانون به کمک محاسبه مقادیر احتمالات انجام می پذیرد. در حقیقت فرمول های بیان شده در مورد محاسبه احتمالات، مناسب داده های رسته ای می باشند و در این جا داده های عددی مشکل ساز می شوند. بر اساس این روش، می توان داده های جدید که در مجموعه داده نیستند و تناسبی با مسیرها ندارند را شناسایی نمود و از بین داده های موجود به عنوان مسیرها، بهترین مسیر را انتخاب کرد.

#### 4- شبیه سازی و نتایج

متن داده ها به صورت کلی دارای 48565 سطر و 11 ستون می باشند. داده ها برگرفته از خط 1 و 2 متروی تهران می باشد که برای یک ماه است. در این مجموعه داده، ویژگی هایی چون ترافیک زمانی، حجم انتقال مسافران در یک سری ایستگاه خاص، تعداد متروهای موجود در خط، فاصله بین ایستگاه ها و وجود یا عدم وجود خط دیگر در یک خط به سمت خطوط دیگر، در نظر گرفته شده است. لازم به ذکر است که در ابتدا ذکر شود پارامترهای الگوریتم ژنتیک NSGA-II و الگوریتم ازدحام ذرات بهینه دودویی توسعه یافته به صورت ترکیبی دارای مقادیر به شرح جدول (3) هستند. قابل ذکر است که این پارامترها به صورت کد شده هستند و بعضی از آن ها نیز در خروجی، قابل تغییر است. اما به صورت پیش فرض، مقادیر ذیل در این شبیه سازی و ارائه نتایج آن، تاثیر گذار بوده است.

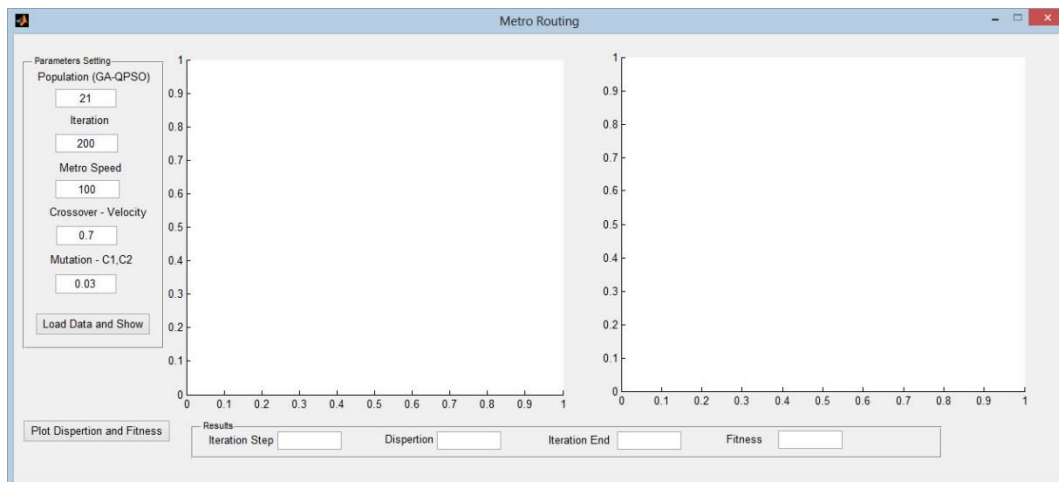
جدول 3. پارامترهای الگوریتم ژنتیک NSGA-II و الگوریتم ازدحام ذرات بهینه دودویی توسعه یافته

21	جمعیت اولیه کروموزوم - جمعیت اولیه ذرات
0.7	نرخ ترکیب کروموزوم ها در تکرار - نرخ سرعت ذرات
0.03	نرخ جهش کروموزوم ها در تکرار - نرخ C1 و C2
30	اندازه ازدحام در حالت الگوریتم ازدحام ذرات بهینه دودویی توسعه یافته
بین بازه 100 الی 1500	تعداد دور تکرار دو الگوریتم
$C2 = 0.5C1 = 1.5$	نرخ تغییرات C1 و C2 در حالت کوانتومی بودن

یکی از مهمترین بخش هایی که در جدول (3) مقداردهی شده است، جمعیت اولیه کروموزوم - جمعیت اولیه ذرات می باشد که در واقع بر اساس تعداد ایستگاه ها در هر خط می باشد. یعنی در هر خط 21 ایستگاه، فرض شده است. همچنین سرعت مترو را نیز بین 100 الی 250 فرض می کنیم. تعداد مسیرهای متصل به هم در خطوط مترو نیز 5 خط است. روش انتخاب الگوریتم ژنتیک NSGA-II نیز به صورت چرخ رولت<sup>1</sup> است. پنجره خروجی برنامه به صورت کلی به شکل (1) است.


<sup>1</sup> Roulette Wheel






شکل 1. پنجره خروجی و تنظیمات پارامتری متغیرها

بعد از مقداردهی پارامترها، اجرا انجام می شود که در زمان اجرا، پنجره سمت چپ در شکل (1) به نمایش تعداد ایستگاه به همراه خطوطی که مسیرهای مترو در ایستگاه را نشان می دهد، می پردازد و با تنظیمات اولیه که در شکل (1) مشخص است، اجرا انجام می شود که در شکل (2) می توان استقرار موقعیت ایستگاه را مشاهده نمود.



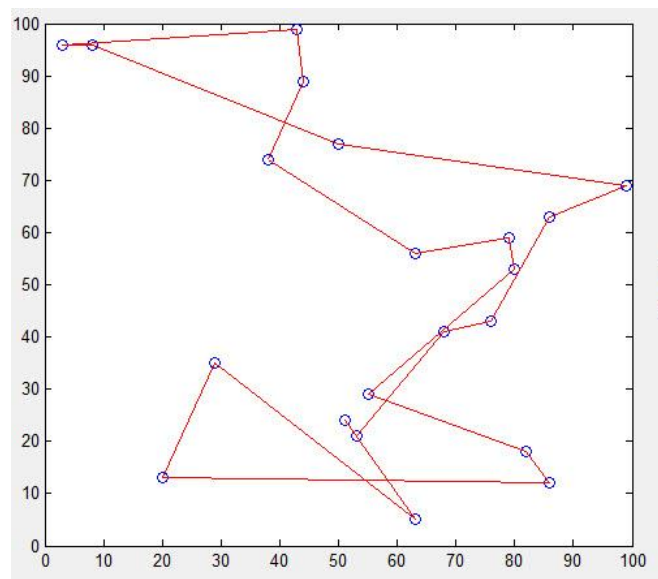
شکل 2. تعداد ایستگاه ها و استقرار آن ها

سپس شبکه عصبی احتمالاتی با آموزش ویژگی های استخراج شده توسط الگوریتم ژنتیک NSGA-II، وارد عمل می شود. ساختار شبکه عصبی احتمالاتی به صورت شکل (3) است.



شکل 3. ساختار شبکه عصبی احتمالاتی ارائه شده


روش آموزش از نوع لونیگ مارکارد<sup>1</sup> در نظر گرفته شده است. هدف از استفاده از این نوع روش آموزش، به منظور ارزیابی کارایی در کاهش خطا در زمان آموزش داده است. تعداد تکرار شبکه عصبی 33 دور و زمان فرایند آموزش و طبقه بندی 4 ثانیه می باشد. مقدار گرادیان برابر 0.00019174 در 33 دور تکرار، مقدار نرخ جهش شبکه عصبی احتمالاتی در آموزش برابر عدد صحیح 0.07 در 33 دور تکرار و اعتبارسنجی برابر 0 در 33 دور تکرار می باشند. نتایج آموزشی نشان می دهد که رویکرد ارائه شده در شبکه عصبی احتمالاتی، نتایج قابل ملاحظه ای داشته است. در شکل (4) پیش بینی مسیریابی بهینه مترو در بین خطوط و ایستگاه ها، مشخص شده اند.



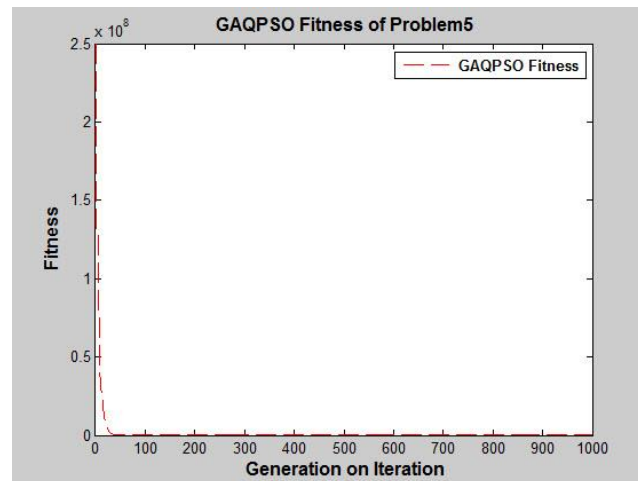
شکل 4. مسیریابی مترو در بین خطوط و ایستگاه ها

زمانی که از الگوریتم های تکاملی و هوش ازدحامی استفاده می شود، نمایش خروجی پراکندگی<sup>2</sup> میزان برازش<sup>3</sup>، دارای اهمیت است. شکل (5) نمودار پراکندگی در زمان مسیریابی بهینه مترو و شکل (6) نیز نمودار برازش در زمان مسیریابی بهینه مترو را نشان می دهد.

<sup>1</sup> Levenberg Marquardt  
<sup>2</sup> Dispersion  
<sup>3</sup> Fitness



شکل 5. نمودار پراکندگی در زمان مسیریابی بهینه مترو



شکل 6. نمودار برازش در زمان مسیریابی بهینه مترو

در ادامه از یک سری معیارهای ارزیابی استفاده می شود که بر اساس فرمول های پایه، محاسبه می شوند. نتایج ارزیابی را می توان در جدول (4) بر اساس معیارهای دقت، حساسیت، میانگین مربعات خطا، اوج نسبت سیگنال به نویز و نسبت سیگنال به نویز، مشاهده نمود.

جدول 4. نتایج ارزیابی روش ارائه شده

Accuracy (Error Rate %)	Sensitivity (Error Rate %)	MSE	PSNR (dB)	SNR (dB)
6.0606	0.7248	0.2000	55.1205	5.5918

همان طور که از نتایج جدول برمی آید، مقدار خطای دقت بر حسب درصد، 6.0606٪ است، یعنی رویکرد ارائه شده 93.9394٪ دارای دقت صحیح در پیش بینی مسیر بهینه برای مترو در بین خطوط (21 ایستگاه) می باشد. همچنین نرخ خطای حساسیت آن نیز 0.7248٪ است که برابر 99.2752٪ حساسیت می باشد. یک مقایسه بر اساس معیار دقت بین روش های ارائه شده پیشین با رویکرد این مقاله صورت پذیرفته است که در جدول (5) نمایش



داده شده است. البته به صورت دقیق نمی توان به این مقایسه استناد کرد، زیرا داده هر تحقیق، مختلف بوده و تعداد ویژگی، حجم نمونه و روش ها، متنوع می باشند.

جدول 5. نتایج ارزیابی رویکرد ارائه شده با سایر پژوهش ها بر حسب دقت

پژوهش	روش	دقت (%)
Eleni I. Vlahogiann, 2008	شبکه عصبی احتمالاتی بهینه شده	88.3500
Wen Huiying et al., 2011	انتروپی و شبکه عصبی احتمالاتی	90.5400
Sharma S. C. et al., 1999	شبکه عصبی متناوب	89.6302
رویکرد این تحقیق	الگوریتم ترکیبی ژنتیک NSGA-II و الگوریتم ازدحام ذرات بهینه دودویی توسعه یافته	93.9394

### 5- نتیجه گیری

با ایجاد خطوط مترو، زمان کمتری صرف ترافیک جاده ای می شود و با توجه به امتیازات عملکردی مترو نسبت به سایر سیستم های حمل و نقل، از اهمیت بالایی برخوردار است. برای ایجاد شبکه مناسب مترو، مسیریابی و مکان یابی مناسب خطوط و ایستگاه ها امری ضروری می باشد. از متداول ترین روش ها در مسیریابی خطوط، استفاده از نظریات کارشناسان، قضاوت مهندسی و مطالعات میدانی در راستای کریدورهای منتخب مطالعات جامع حمل و نقل و ترافیک، می باشد. روش دیگر مسیریابی استفاده از مدل های ریاضی بوده که در این روش سلاقی و نظرات شخصی راه نداشته و تمامی فرآیند مسیریابی، توسط داده ها و روش های ریاضی انجام می گیرد. این تحقیق نیز با ارائه یک روش بهینه، سعی در بهبود مسیریابی در شبکه های مترو را دارد تا کوتاه ترین مسیر با بهترین زمان و دقت کافی در عملکرد، انجام شود. روش ارائه شده بدین صورت است که از الگوریتم ترکیبی ژنتیک NSGA-II و الگوریتم ازدحام ذرات بهینه دودویی توسعه یافته استفاده می کند.

### منابع

- Bruno, G., Gendreau, M., and Laporte, G. (2002). A heuristic for the location of a rapid transit line. *Computer & Operations Research*, Vol. 29, Issue 1, pp 1-12.
- Bruno, G., Ghiani, G., Improta, G. (1998). A multi-modal approach to the location of a rapid transit line. *European Journal of Operational Research*, Vol. 104, Issue 2, pp 321-332.
- Current, J. R., Revelle, C. S., and Cohon, J. L. (1985). The maximum covering/ shortest problem: A multiobjective network design and routing formulation. *European Journal of Operational research*, Vol. 21, Issue 2, pp 189-199.
- Decesare. (1970), PhD thesis.
- Dufourd, H., Gendreau, M., and Laporte, G. (1996). Locating a transit line using tabu search, *Lcation Science*, Vol. 4, Issue 1-2, pp 1-19.
- Eleni I. Vlahogiann. "Prediction of non-recurrent short-term traffic patterns using genetically optimized probabilistic neural networks." *Operational Research Journal*. Springer-Verlag Volume 7, Issue 2, pp 171-184, 2007.
- Huiying, Wen, Jun, Luo, Xiaolong, Chen, and Xiaohui, Guo. (2011). Real-time highway accident prediction based on grey relation entropy analysis and probabilistic neural network. *IEEE International Conference on Electric Technology and Civil Engineering (ICETCE)*, pp. 1420 – 1423.
- Laporte, G., Mesa, J. A., Ortec, F. A., and Sevilano, I. (2005). Maximizing trip coverage in the location of a single rapid transit alignment. *Annals of Operations Research*, Vol. 136, pp 49-63.
- Neveu, A. (1983). Quick response procedures to forecast rural traffic. In *Transportation Research Record 944*, pp. 47-53. Washington DC: Transportation Research Board.





# Systems Thinking In Practice

2nd  
National Conference on

دومین کنفرانس ملی (مجازی)

تفکر سیستمی در عمل



- Raveau, Sebastián, Guo, Zhan, Muñoz, Juan Carlos, and Wilson, Nigel H. M. (2014). A behavioural comparison of route choice on metro networks: Time, transfers, crowding, topology and socio-demographics. *Transportation Research Part A: Policy and Practice*, Vol. 66, pp. 185-195.
- Sharma, S. C., Lingras, P. Xu, and F., Liu G. X. (1999). Neural networks as alternative to traditional approach of annual average daily traffic estimation from traffic counts. In *Transportation research record 1660*. pp. 24-31. Washington, DC: Transportation Research Board.
- Street Design and Community Livability. (2000). *Proceedings of Urban Transportation*. Cambridge, UK.
- Vlahogiann, Eleni I. (2008). Optimization Prediction of non-recurrent short-term traffic patterns using genetically optimized probabilistic neural networks." *Operational Research Journal*. Springer-Verlag Volume 7, Issue 2, pp 171-184.
- Wang, Guang, Xu, Tianhua, Tang, Tao, Yuan, Tangming, and Wang, Haifeng. (2017). A Bayesian network model for prediction of weather-related failures in railway turnout systems. *Expert Systems with Applications*, Vol. 69, pp. 247-256.
- Zhao, F., and Chung, S. (2001). Contributing factors of annual average daily traffic in a Florida county: Exploration with geographical information system and regression model." In *Transportation research record 1769*. pp. 113-122. Washington DC: Transportation Research Board.
- Zhu, Wei, Xu, Ruihua. (2016). Generating route choice sets with operation information on metro networks. *Journal of Traffic and Transportation Engineering (English Edition)*, Vol. 3, Issue 3, pp. 243-252.
- Zhuang, He, Feng, Liping, Wen, Chao, Peng, Qiyuan, and Tang, Qizhi. (2016). High-Speed Railway Train Timetable Conflict Prediction Based on Fuzzy Temporal Knowledge Reasoning. *Engineering*, Vol. 2, Issue 3, pp. 363-373.



### (Intelligent metro management in Mashhad based on optimized Swarm Intelligence algorithms)

**Negin Heshmati<sup>1</sup>**

Bachelor student, Department of railway engineering, Faculty of engineering management, Kermanshah university of technology, Kermanshah, Iran

**Mehdi Fallahi<sup>2\*</sup>**

Faculty member, Department of railway engineering, Faculty of engineering management, Kermanshah university of technology, Kermanshah, Iran

#### Abstract

Nowadays, the subway is regarded as the most effective and fastest public transportation that various countries seek to pave the way to develop the subway. The use of the subway is considerably cost-effective and environmentally friendly in developed and developing countries because of reduced transport network traffic and environmental pollution, reduced costs, increased passenger transportation. Thus, it is necessary to develop intelligent systems for efficient subway management. In Iran, the subway is developing in different cities, and its intelligent management with respect to routing problem demands more careful and detailed considerations to minimize time and cost for subway users. Thus, for the routing problem of the subway in Mashhad, Iran, as well as to establish a precise structure to achieve the aims and challenges, providing an intelligent management method was considered with evolutionary and swarm intelligence algorithms. In the present study, the proposed algorithm is a hybrid algorithm based on elitist non-dominated sorting genetic algorithm (NSGA-II) genetic and optimal binary particle swarm optimization (PSO) algorithms.

**Keywords:** Intelligent Management, Metro Routing, Machine Learning, Binary particle swarm optimization algorithm .

---

<sup>1</sup> Negin.heshmati78@gmail.com

<sup>2\*</sup> Mehdi.fallahi@gmail.com