

به کارگیری شبکه عصبی مصنوعی برای قیمت‌گذاری شناور مجوز طرح ترافیک تهران جهت مدیریت بهینه شهر با هدف کاهش آلودگی هوا

احسان اله اشتهاوردیان* - استادیار گروه مدیریت پروژه و ساخت، دانشکده هنر و معماری دانشگاه تربیت مدرس، تهران، ایران.
محمدعلی فاضلی‌راد - دانشجوی کارشناسی ارشد مدیریت صنعتی، دانشکده مدیریت و حسابداری دانشگاه علامه طباطبائی (ره)، تهران، ایران.

چکیده

آلودگی هوای شهر تهران، از معضلات اصلی این شهر به حساب آمده و آمار روزانه این آلودگی نشان می‌دهد که در بسیاری از شرایط، میزان آلاینده‌های هوای تهران در وضعیت ناسالم یا مخاطره‌آمیز به سر می‌برند. به عنوان ابزاری برای مدیریت شهری تهران، یکی از مهم‌ترین راهکارهای مقطعی برای جلوگیری از آلودگی هوا به همراه کاهش حجم ترافیک، ایجاد منطقه طرح ترافیک بوده که با فروش مجوز این طرح به صورت سالانه، هفتگی و ماهانه همراه است. از آنجاکه در هر سال، فقط یک قیمت ثابت برای این طرح وجود دارد، ضروری است که این قیمت بر اساس داده‌های آلودگی هوا منعطف شده و واقعیت موجود آلودگی را بر روی خود منعکس کند. از اینرو در این مقاله با خوشه‌بندی ماه‌های سال بر اساس آمار وضعیت آلاینده‌های هوای تهران در سال‌های ۹۰ تا ۹۲، یک مدل چند قیمتی برای طرح ترافیک غیرسالیانه در سال جدید پیشنهاد شده است. این خوشه‌بندی با شبکه عصبی SOM بر اساس آلاینده‌های نیتروژن دی‌اکسید، سولفور دی‌اکسید، کربن مونواکسید، ازن و ذرات معلق در هوا (PM) انجام شده و نتایج آن گردآوری شده است. استفاده از این روش قیمت‌گذاری سبب افزایش قیمت طرح ترافیک در ماه‌هایی که شاخص آلودگی بالاتر است، شده و در نهایت منجر به کاهش حجم ترافیک ورودی به منطقه طرح ترافیک و نهایتاً کاهش آلودگی میشود.

واژگان کلیدی: طرح ترافیک، شبکه عصبی مصنوعی (ANN)، خوشه‌بندی، نگاشت خودسازمان ده (SOM)، آلاینده هوا، قیمت‌گذاری.

Using Artificial Neural Network for float pricing of Tehran traffic tolls to improve urban management focused on decreasing air pollution

Abstract

Air pollution of Tehran is one the main urban concerns of the municipality and daily statistics of this pollution confirm the hazardous and unhealthy state of air contaminants of the city. A temporary tool of relieving air pollution through decreasing traffic jam is to develop traffic zones which their licenses may be sold for yearly, monthly or weekly periods. Currently, the prices are fixed whole throughout the period and this needs to be modified in order to take into account the varying prices in accordance with the varying level of air pollution.

So, this paper suggests a multi-price model for non-annual traffic toll by clustering months based on statistics of air contaminants of Tehran from 1390 to 1392. This clustering by SOM method is based on contaminants such as nitrogen dioxide (NO₂), sulfur dioxide (CO₂), carbon monoxide (CO), ozone (O₃) and suspended particulate matters (PMs). Exploiting this pricing method results in increase of the toll price during periods that level of pollution is high. This leads to decrease of traffic jam in that period which in turn decreases the level of air pollution.

Keywords: Artificial Neural Network (ANN), Clustering, Self-Organizing Map (SOM), Air Pollutant, Pricing

۲۰۰۷ در پایتخت سوئد اجرایی شد، علاوه بر بهبود ۲۰ درصدی ترافیک شهری، ۱۰ تا ۱۴ درصد آلودگی را نیز کاهش داده است (آرنولد و همکاران، ۲۰۱۰). بنابراین، موضوع طرح ترافیک رابطه تنگاتنگی با آلودگی هوا داشته و دارد؛ چه اینکه با شدت گرفتن آلودگی هوا در فصل سرما، طرح‌های ترافیک از محدوده مرکزی نیز فراتر رفته و گاهی سراسری می‌شود. این موضوع از آنجا ناشی می‌شود که علت اصلی آلودگی هوا در بسیاری از شهرهای بزرگ ایران، به ویژه ابرشهری چون تهران، اغلب احتراق سوخت‌های وسایل حمل و نقل است که موجب پراکنده شدن آلودگی در هوا می‌شود (عربان، ۱۳۸۸).

به نظر می‌رسد ارائه یک قیمت یکسان برای مجوز طرح ترافیک غیرسالیانه (هفتگی یا روزانه) طی تمامی طول سال، چندان با معیارهای زیست سازگار نیست. در این مقاله، با دخالت دادن تأثیر آلاینده‌های هوای تهران بر قیمت مجوز طرح ترافیک عملاً بر اساس رویکردی سخت‌گیرانه برای توسعه پایداری زیست محیطی در شهر تهران به مدل‌سازی ریاضی قیمت‌های چندگانه پرداخته شده است. به منظور ارائه هرچه دقیق‌تر این قیمت‌های چندگانه و همچنین با توجه به اینکه قیمت‌ها باید ثبات مشخصی داشته باشند، به خوشه‌بندی داده‌های ماهانه روی آورده شده است.

از آنجا که میزان آلودگی هوا عموماً بر اساس غلظت آلاینده‌هایی نظیر کربن مونواکسید، ازن، نیتروژن دی‌اکسید، سولفور دی‌اکسید و ذرات معلق در هوا (PM) محاسبه می‌شود (چان و جیان، ۲۰۱۳)، لذا در این پژوهش نیز داده‌های گردآوری شده بر اساس آلاینده‌های CO، O₃، NO₂، SO، PM_{۱۰}، PM_{۲٫۵} دسته‌بندی شده است که توسط شرکت کنترل کیفیت هوای تهران جمع‌آوری می‌گردد.

به منظور فرآیند خوشه‌بندی و تحلیل خوشه‌های ایجاد شده در این پژوهش از شبکه عصبی بهره‌گرفته شده است. شبکه‌های عصبی مصنوعی (ANN)، رویکرد متداولی هستند که برای تخمین و پیش‌بینی و ارزیابی سطوح آلاینده‌هایی هومورد استفاده قرار می‌گیرند. این شبکه‌ها یک روش یادگیری بدون نظارت هستند که با

یکی از چالش‌های مهم شهرهای بزرگ در دنیای امروز، آلودگی‌های زیست محیطی به ویژه تراکم آلاینده‌های هواست. این چالش اگرچه امروز بسیار مورد توجه و بررسی واقع شده است، اما همچنان درگسترش بوده و روزانه گروه‌های مختلفی را با خود درگیر می‌کند. غلظت‌های با آلودگی زیاد، تأثیرات سوء و مرگ زودرس گروه‌های حساس و آسیب‌پذیر جامعه را به دنبال دارد (تیتانن، ۱۹۹۹). از همین روی، آلودگی هوارا می‌تواند یک ریسک بزرگ محیط زیستی برای سلامتی افراد در شهرهای توسعه یافته یا در حال توسعه جهان نامید. (چان و جیان، ۲۰۱۳). آلاینده‌های هوا از دو منشأ طبیعی و فعالیت‌های انسانی سرچشمه می‌گیرند. شماری از آلاینده‌های جوی، آلاینده‌های اولیه به شمار می‌روند زیرا مستقیماً از دودکش‌ها، آگروزها و غیره وارد جو می‌شوند و دسته دیگر که آلاینده‌های ثانویه نام دارند از برهم‌کنش شیمیایی یک آلاینده اولیه با بعضی از اجزای هوا از قبیل بخار آب و یا آلاینده‌های دیگر ایجاد می‌شوند (اهرنس، ۱۹۹۸).

شلوغی و ازدحام بیش از حد مراکز شهری همراه با آلودگی هوا از پیامدهای مستقیم استفاده از وسائل نقلیه موتوری در شهرهاست. در بلندمدت، تداوم و افزایش شلوغی و ازدحام ترافیک شهرها از لحاظ اقتصادی، اجتماعی، سیاسی و به ویژه زیست محیطی قابل توجه نیست (عسگری و همکاران، ۱۳۹۱). از این رو، یکی از طرح‌هایی که هم از بُعد سهولت حمل و نقل شهری و هم از بُعد آلودگی هوا قابل تأمل است، طرح ترافیک شهری و محدودیت‌های عبور و مرور خودروها در برخی مناطق شهر است. این در حالی است که در محدوده مرکزی شهر به دلیل تمرکز سازمانها و ادارات دولتی، بازار و کاربری‌های عمده جذب سفر، این مشکلات حادثتر است (حبیبیان و همکاران، ۱۳۹۱).

پرداخت مالیات یا عوارض ورود به مناطق شلوغ مرکزی شهر، یکی از راه‌های مدیریت ترافیک برشمرده می‌شود که در بلندمدت علاوه بر ایجاد شرایط مطلوب ترافیکی، در بهبود شرایط زیست محیطی نیز می‌تواند چاره‌ساز گردد. به عنوان نمونه، محدوده طرح ترافیکی که از سال

یکی از مهم‌ترین فرآورده‌های شبکه عصبی مصنوعی، تحلیل خوشه‌ای و خوشه‌بندی با منطق تحت آن است. اگرچه دو روش مرسوم دیگر نیز برای خوشه‌بندی وجود دارند؛ یکی روش‌های سلسله‌مراتبی (مانند حداقل واریانس) و روش‌های غیرسلسله‌مراتبی (مانند روش K- میانگین) است (حسنقلی پور و همکاران، ۱۳۸۶) که مادر ادامه به بحث با محور شبکه‌های عصبی می‌پردازیم. تحلیل خوشه‌ای سنتی هنوز کاربردهای متعددی در عمل دارد اما یک شبکه عصبی خودسازمان‌ده (SOM) برتری‌های ویژه‌ای نسبت به خوشه‌بندی سنتی دارد (مازانک، ۱۹۹۲). مازانک، بیان می‌کند که توپولوژی حاصل از ویژگی‌های این شبکه، آن را از روش‌های سنتی خوشه‌بندی متمایز می‌سازد (جانانان، ۲۰۰۵).

۲-۲- الگوریتم نگاشت خودسازمان‌ده (SOM)
همان‌طور که ذکر شد، یکی از روش‌هایی که به منظور خوشه‌بندی با شبکه عصبی مصنوعی مورد استفاده قرار می‌گیرد، الگوریتم SOM است. این الگوریتم به طور معمول، متشکل از یک یا دو لایه نرون‌های ورودی و خروجی است (تیسان و کیرستیا، ۲۰۱۳). نگاشت خودسازمانده روابط غیرخطی و پیچیده‌ی اطلاعات با ابعاد زیاد را به رابطه‌ی ساده‌ی هندسی با ابعاد کم تبدیل می‌کند. با وجود آنکه در این روش، فشرده‌سازی اطلاعات انجام می‌شود، اما روابط مهم متریک و

فراهم آوردن داده‌های آلودگی هوا می‌توانند فرآیند یادگیری را برای ایجاد یک جعبه سیاه به منظور تخمین و ارزیابی آلاینده‌های هوا صورت دهند (چان و جیان، ۲۰۱۳).

۲- ادبیات و پیشینه پژوهش

۲-۱- شبکه عصبی مصنوعی و آلودگی هوا


در این پژوهش از شبکه عصبی مصنوعی به عنوان ابزاری برای خوشه‌بندی داده‌های آلودگی هوا استفاده شده است. شبکه عصبی مصنوعی، ابزاری ریاضی است که با تقلید از سیستم بیولوژیک ساخته شده است (فولاپ و همکاران، ۱۹۹۸). شبکه‌های عصبی مصنوعی مانند شبکه‌های عصبی بیولوژیک پیچیده نیستند، بلکه دو شباهت ساده به آنها دارند. نخست شباهت ساختمان کلی هر دو بوده و دیگر اینکه ارتباط بین نرون‌ها تعیین کننده شیوه کار شبکه است (هاگان و همکاران، ۲۰۰۲). به طور کلی، می‌توان گفت که شبکه‌های عصبی از لایه‌های نرونی تشکیل شده به طوری که این نرون‌ها از طریق ورودی‌های خود با جهان واقعی در ارتباط هستند و از طریق خروجی‌های خویش جهان واقعی را می‌سازند (تسای، ۲۰۰۹).

استفاده از شبکه‌های عصبی در مطالعات آلاینده‌های هوا سوابق متعددی دارد. پاره‌ای از این سوابق بر اساس آلاینده مورد نظر در جدول (۱) گردآوری شده است.

جدول ۱. کاربرد شبکه‌های عصبی در مجموعه داده‌های

آلاینده‌های هوا

| پژوهش | آلاینده |
|-------------------------|------------------|
| کاسترو و همکاران، ۲۰۰۳ | سولفور دی‌اکسید |
| ناگندرا و خاری، ۲۰۰۴ | کربن مونواکسید |
| نیسکا و همکاران، ۲۰۰۴ | ذرات معلق (PM) |
| گریواس و چالولاکو، ۲۰۰۶ | |
| پوپ و داگری، ۲۰۰۶ | |
| اسلینی و همکاران، ۲۰۰۶ | |
| ووو و همکاران، ۲۰۱۱ | اُژن |
| کوبورن و همکاران، ۲۰۰۰ | |
| دوتت و همکاران، ۲۰۰۷ | نیتروژن دی‌اکسید |
| چان و جیان، ۲۰۱۳ | |



شکل ۱. معماری یک شبکه SOM

ارائه شده است. اجزای این مدل بر اساس خوشه‌بندی و مقادیر متعلق به خوشه‌ها محاسبه شده و وزن‌ها نیز بر اساس نظرات خبرگان لحاظ می‌گردد.

$$P_k = P. + \sum_{i=1}^n \left(\alpha_i \sum_{j=1}^{12} w_{ijk} \cdot \bar{x}_{ijk} \right) \quad (2)$$

که در آن α_i نمایش دهنده ضرایب اهمیت آلاینده‌های ۱ تا n است که بر پایه نظرات خبرگان تعیین می‌گردد. همچنین w_{ijk} یک متغیر ۰ یا ۱ بوده که بر اساس قرارگیری ماه‌زام در خوشه k ام، برابر با ۱ می‌شود. \bar{x}_{ijk} نیز مقدار متوسط آلاینده i را در ماه j در خوشه k ام نشان می‌دهد. این مقدار متوسط، بر اساس میانگین مقدار ایستگاه‌های مختلف مورد بررسی به دست می‌آید.

به منظور آنکه جریمه راهنمایی و رانندگی برای خودروهایی که بدون مجوز طرح ترافیک در محدوده مشخص شده تردد می‌کند بی‌معنا نباشد، این جریمه باید از حداکثر میزان قیمت طرح ترافیک بالاتر بوده که این میزان با توجه به نظر خبرگان و عرف همیشگی قابل تعیین است. این مورد، در فرمول (۳) لحاظ شده است.

$$F = \beta + \max(P_k) \quad (3)$$

که در این عبارت F بیان‌گر مقدار جریمه راهنمایی و

رانندگی و β به عنوان تفاوت این میزان با حداکثر جریمه تلقی می‌شود. اگرچه می‌توان این میزان را نیز منعطف دانست و بر همین اساس جریمه خودروهای متخلف از طرح ترافیک را بر اساس خوشه‌ای که در آن قرار گرفته بررسی نمود:

$$F_k = \beta_k + P_k \quad (4)$$

۳-۲- داده‌های مورد مطالعه

داده‌های آلاینده‌های هوای تهران بر اساس اطلاعات شرکت کنترل کیفیت هوای تهران به دست آمده است. این داده‌ها بر اساس میزان اطلاعات موجود در این پایگاه و صحت‌یابی کلی آنها بر پایه ایستگاه‌های اقدسیه، پونک، ستاد مرکزی، شهرداری منطقه ۱۱، شهرداری منطقه ۱۶ و گلبرگ استخراج شد. مکان ایستگاه‌ها به تفکیک در شکل شماره ۲ به نمایش درآمده است.

داده‌های مورد استفاده در این مطالعه، در شش آلاینده CO ، O_3 ، NO_2 ، SO ، PM_{10} ، $PM_{2.5}$ خلاصه می‌شود که در جدول (۲) به صورت خلاصه نمایش داده شده‌اند. این جدول نمایان‌گر وضعیت میانگین شش آلاینده فوق در تمامی ایستگاه‌های مذکور طی دوازده ماه سال‌های ۹۰ تا ۹۲ است.

مدیریت شهری

فصلنامه مدیریت شهری
Urban Management
شماره ۳۶ پاییز ۱۳۹۳
No.36 Autumn 2014

۱۴۹



شکل ۳. ایستگاه‌های مورد بررسی برای وضعیت آلاینده‌های هوای تهران

جدول ۲. میانگین آلاینده‌ها بر اساس هریک از ایستگاه‌های مورد مطالعه

| تاریخ | PM _{۲٫۵} | PM _{۱۰} | SO _۲ | NO _۲ | O _۳ | CO |
|----------|-------------------|------------------|-----------------|-----------------|----------------|------|
| فروردین | ۲۶,۰۰ | ۵۸,۳۳ | ۲۱,۰۰ | ۳۵,۵۰ | ۳۳,۸۰ | ۲,۲۰ |
| اردیبهشت | ۲۲,۲۰ | ۴۹,۶۷ | ۲۶,۰۰ | ۳۵,۳۳ | ۲۶,۶۰ | ۲,۱۲ |
| خرداد | ۳۳,۶۰ | ۷۵,۱۷ | ۱۹,۰۰ | ۴۲,۰۰ | ۲۵,۴۰ | ۵,۴۸ |
| تیر | ۳۸,۸۰ | ۸۵,۳۳ | ۱۷,۵۰ | ۵۲,۸۳ | ۲۹,۴۰ | ۳,۵۷ |
| مرداد | ۴۱,۲۰ | ۸۹,۵۰ | ۱۸,۰۰ | ۴۸,۸۳ | ۲۶,۰۰ | ۲,۸۰ |
| شهریور | ۳۸,۲۵ | ۷۳,۳۳ | ۱۷,۰۰ | ۴۲,۵۰ | ۲۲,۸۰ | ۲,۸۸ |
| مهر | ۴۰,۷۵ | ۸۷,۴۰ | ۱۶,۲۰ | ۴۲,۸۳ | ۲۸,۶۰ | ۳,۰۵ |
| آبان | ۳۲,۰۰ | ۶۷,۲۰ | ۱۷,۲۰ | ۴۹,۳۳ | ۱۷,۲۰ | ۳,۱۵ |
| آذر | ۲۷,۶۰ | ۶۲,۱۷ | ۱۸,۱۷ | ۴۸,۶۷ | ۱۷,۷۵ | ۳,۱۵ |
| دی | ۳۵,۸۳ | ۶۷,۰۰ | ۲۰,۳۳ | ۵۴,۰۰ | ۲۸,۲۵ | ۳,۲۳ |
| بهمن | ۳۴,۰۰ | ۷۴,۵۰ | ۱۷,۱۷ | ۵۱,۸۰ | ۱۴,۵۰ | ۳,۳۸ |
| اسفند | ۲۸,۱۷ | ۶۷,۱۷ | ۱۵,۶۷ | ۴۸,۴۰ | ۲۰,۵۰ | ۲,۹۳ |


۴- یافته‌های پژوهش

هریک از آلاینده‌های شش‌گانه در طول ماه‌های سه سال ۹۱،۹۰ و ۹۲ برای شش ایستگاه فوق‌الذکر مورد بررسی قرار گرفته و میانگین مقادیر این ایستگاه‌ها در جدول (۲) درج شده است. این مقادیر بر حسب ماه‌ها تفکیک شده و همین ماه‌ها وارد فرآیند خوشه‌بندی با استفاده از الگوریتم SOM در شبکه عصبی می‌شوند. لازم به ذکر است که در این پژوهش، فرآیند محاسبات و پیش‌پردازش با استفاده از نرم‌افزار Excel ۲۰۱۳ و عملیات مربوط به تشکیل و اجرای شبکه عصبی SOM با نرم‌افزار

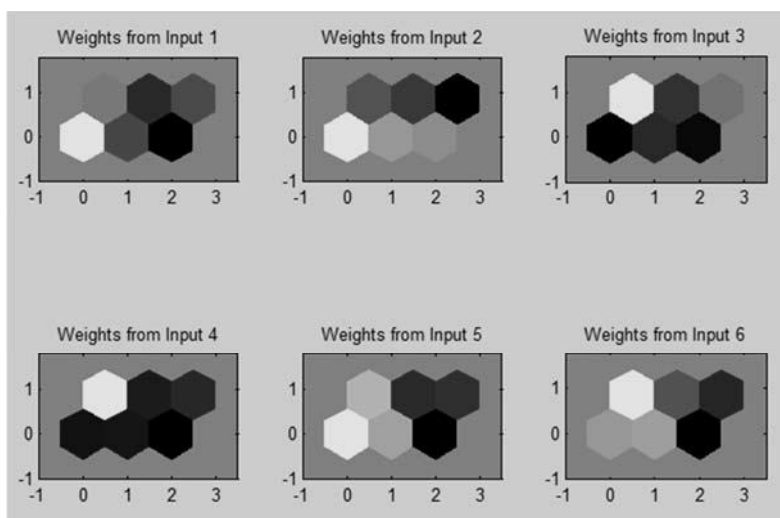
مدیریت شهری

فصلنامه مدیریت شهری
Urban Management
شماره ۳۶ پاییز ۱۳۹۳
No.36 Autumn 2014

■ ۱۵۰ ■



شکل ۴. معماری کلی SOM ایجاد شده با ۶ نورون



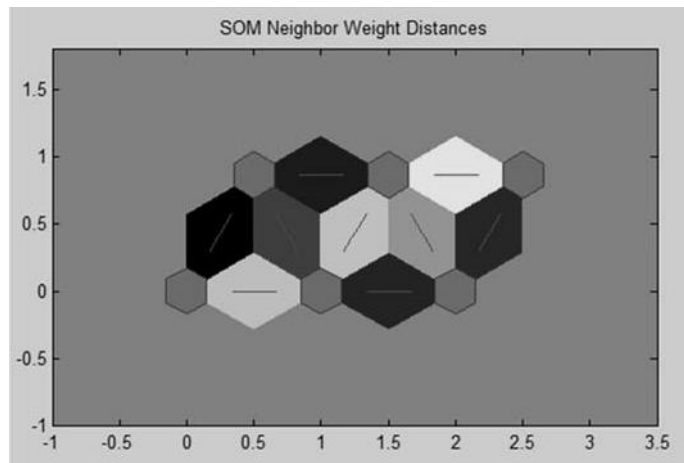
شکل ۵. صفحه وزن‌های ورودی‌های شش‌گانه

۲۰۱۳ MATLAB انجام شده است.


آلاینده‌های PM_{10} ، $PM_{2.5}$ هستند، شباهت زیادی به یکدیگر داشته و همین موضوع همبستگی بالای این دو آلاینده را نشان می‌دهد که منطقاً نیز همین طور است. در شکل (۶)، خروجی نهایی خوشه‌بندی با ۶ نرون ارائه شده است. این شکل خروجی را بر مبنای روابط بین نرون‌ها و میزان فاصله بین آنها نشان می‌دهد. شش ضلعی‌های آبی‌رنگ، نرون‌ها را نشان می‌دهد و خطوط قرمز، بیان‌گر اتصال بین نرون‌های همسایه است. رنگ نواحی متصل‌کننده همسایه به هم، میزان فاصله را نشان می‌دهد. هرچه این فاصله بیشتر باشد، رنگ به کار رفته بین نرون‌ها تیره‌تر می‌شود و هرچه این فاصله کمتر باشد، این رنگ روشن‌تر نشان داده می‌شود. فاصله‌های کمتر به معنای شدنی‌تر بودن ترکیب نرون‌ها با یکدیگر به منظور ایجاد خوشه‌های واحدتر است.

شبکه‌ای که برای این تحلیل خوشه این داده‌ها ساختار بندی شده یک شبکه ۶ نرونی است که مدل کلی آن در زیر مشهود است. لازم به ذکر است که این مدل شش نرونی با استفاده از تعریف ابعاد با اندازه 2×3 در تابع selforgmap شبکه SOM ایجاد شده است.

شکل (۵)، ورودی‌های خوشه‌بندی را نشان می‌دهد. این نمودار که به صفحه وزن‌ها معروف است، وزن‌های اتصالی بین نرون‌ها را نشان می‌دهد. رنگ‌های تیره، وزن‌های بالاتر را نشان می‌دهد. در صورتی که در برخی ورودی‌ها الگوهای اتصالی بین وزن‌ها بسیار شبیه باشند، می‌توان نتیجه گرفت که آنها دارای همبستگی بالایی با یکدیگر هستند. کما اینکه در این شکل، صفحه وزن‌های حاصل از ورودی ۵ و ۶ که به ترتیب نمایش دهنده



شکل ۶. فواصل بین نرون‌ها



شکل ۷. تعداد نمونه‌های هر نرون بر اساس خروجی الگوریتم SOM

شکل (۷)، تعداد داده‌های مرتبط با هر نرون را در ترکیب خوشه‌بندی نشان می‌دهد.

با توجه به شکل (۶)، می‌توان تحلیلی بر مبنای ترکیب نرون‌ها برای ایجاد خوشه‌بندی‌های متفاوت ارائه داد. بر همین اساس با استفاده از فرمول (۱) که منطق مجموع مربعات خطا را نمایش می‌دهد، می‌توان هریک از این تعداد خوشه‌ها را ارزیابی نموده و در نهایت بهترین تعداد را به عنوان برترین نوع خوشه‌بندی برگزید. از همین روی، جدول (۳) مقدار SSE را برای تعداد مختلف خوشه‌بندی نشان می‌دهد. همچنین برای استفاده از فرمول (۱)، مقادیر مربوط به مراکز خوشه‌ها با استفاده از دستور net.IW در نرم‌افزار متلب به دست آمده که خروجی این دستور در شکل (۸) نمایش داده شده است. با توجه به مقادیر SSE در جدول (۳)، کمترین مقدار مربوط به خوشه‌بندی با شش خوشه است. لذا الگوی نهایی برای خوشه‌بندی ماه‌های سال بر مبنای آلاینده‌های هوای تهران، در جدول زیر مشهود است. جدول (۴) عضویت هریک از ماه‌های دوازده‌گانه را در یکی از خوشه‌های مورد نظر نمایش می‌دهد.

جدول ۳. مقادیر SSE به ازای مقادیر مختلف تعداد خوشه‌ها

| تعداد خوشه‌ها | SSE |
|---------------|------------------------|
| ۶ | 0.757×10^{-3} |
| ۵ | 1.146×10^{-3} |
| ۴ | 1.522×10^{-3} |
| ۳ | 2.229×10^{-3} |

بنابراین با استفاده از میانگین آلاینده‌های هر خوشه که در جدول (۵) گردآوری شده است، می‌توان قیمت‌گذاری چندگانه را برای مجوزهای طرح ترافیک تهران مدل‌سازی نمود. این مدل‌سازی در بخش قبلی ارائه شده و فرمول (۲) کلیات آن را نشان می‌دهد. پس با استناد به داده‌های خوشه‌بندی شده در جدول (۵) و همچنین با کمک فرمول (۲) و (۴) می‌توان قیمت‌گذاری منعطف را هم در طرح ترافیک و هم در جریمه‌های راهنمایی و رانندگی فرموله نمود. البته باید تاکید نمود که ضرایب α_i و β_k که به ترتیب در فرمول (۲) و (۴) ذکر شد، نیازمند نظرات خبرگان است؛ به ویژه α_i که باید با محوریت زیست‌محیطی و سلامت نیز مورد بررسی قرارگیرد.

جدول ۴. خوشه‌بندی نهایی بر مبنای داده‌های سه ساله

| | فروردین | اردیبهشت | خرداد | تیر | مرداد | شهریور | مهر | آبان | آذر | دی | بهمن | اسفند |
|----------|---------|----------|-------|-----|-------|--------|-----|------|-----|----|------|-------|
| خوشه (۱) | | | | | | | | | | | | |
| خوشه (۲) | | | | | | | | | | | | |
| خوشه (۳) | | | | | | | | | | | | |
| خوشه (۴) | | | | | | | | | | | | |
| خوشه (۵) | | | | | | | | | | | | |
| خوشه (۶) | | | | | | | | | | | | |

```
>> net.IW{:}
ans =
0.1001    0.0999    0.0733    0.0805    0.0954    0.0893
0.0834    0.0917    0.0802    0.0809    0.0897    0.0899
0.0692    0.0905    0.0749    0.0776    0.0693    0.0667
0.0893    0.0841    0.0991    0.1021    0.0912    0.0967
0.0776    0.0792    0.0818    0.0820    0.0766    0.0823
0.0842    0.0667    0.0894    0.0840    0.0774    0.0743
```

شکل ۸. خروجی متلب در نمایش وزن‌های خوشه‌بندی شش‌تایی

جدول ۵. میانگین مقادیر آلاینده‌های هر خوشه

| خوشه | PM _{۲.۵} | PM _{۱۰} | SO _۲ | NO _۲ | O _۳ | CO |
|-------|-------------------|------------------|-----------------|-----------------|----------------|------|
| یکم | ۳۹,۲۰ | ۸۳,۹۴ | ۲۰,۹۸ | ۳۴,۲۸ | ۲۹,۸۱ | ۳,۴۵ |
| دوم | ۳۹,۴۸ | ۷۸,۹۶ | ۲۱,۰۸ | ۳۷,۵۰ | ۲۷,۳۶ | ۲,۸۷ |
| سوم | ۲۹,۳۰ | ۶۰,۹۸ | ۲۰,۲۰ | ۳۵,۰۲ | ۲۷,۰۰ | ۲,۳۹ |
| چهارم | ۴۲,۴۷ | ۸۰,۲۷ | ۲۶,۵۹ | ۴۶,۳۴ | ۲۵,۰۹ | ۳,۰۸ |
| پنجم | ۳۶,۱۳ | ۶۷,۳۹ | ۲۱,۳۷ | ۳۸,۲۸ | ۲۳,۶۳ | ۲,۶۸ |
| ششم | ۳۲,۶۴ | ۶۸,۱۱ | ۲۱,۸۷ | ۴۱,۸۲ | ۱۹,۹۱ | ۲,۹۰ |

۵- نتیجه‌گیری و جمع‌بندی

بر اساس یافته‌های این پژوهش، ماه‌های «اردیبهشت، تیر، مرداد و مهر»، در یک خوشه، ماه‌های «شهریور و اسفند» در یک خوشه و ماه‌های «آبان، آذر و بهمن» نیز در یک خوشه قرار گرفتند. بر همین پایه، سه ماه «فروردین»، «خرداد» و «دی» نیز هر یک در خوشه‌ای جداگانه قرار گرفتند. بر اساس شبکه عصبی SOM و همچنین مجموع مربعات خطا (SSE) تعداد بهینه برای خوشه‌بندی، عدد ۶ به دست آمد که بر همین اساس، دوازده ماه سال در این شش خوشه قرار گرفتند.

با نگاهی به این شش خوشه و ماه‌های مندرج در هر یک از آنها، شهود فردی نیز کاملاً بر این خوشه‌بندی صحه می‌گذارد. به عنوان مثال، شش‌ماهه دوم سال که عموماً در اواسط آن شرایط نامطلوب آلاینده‌های هوا اوج می‌گیرد، در این خوشه‌بندی کاملاً منطقی به نظر می‌رسند. ماه‌های آبان و آذر و بهمن در یک خوشه قرار گرفته و ماه دی که اوج آلودگی هواست در خوشه‌ای جداگانه دسته‌بندی شده است. از سوی دیگر در شهریورماه و اسفندماه نیز اگرچه شرایط سرمایی هوا کمتر حاکم است، اما حجم ترافیک پایانی تابستان و پیش از سال جدید تحصیلی و همچنین پیش از عید نوروز، حاکی از افزایش آلودگی هوا و تبیین منطق این خوشه‌بندی است.

دسته‌بندی داده‌ها در این شش خوشه، می‌تواند ۶ پله قیمتی را برای کارشناسان ایجاد کند که همه این سطوح قیمتی بر اساس میزان متوسط آلاینده‌های موجود در این خوشه‌ها به دست می‌آیند؛ که این امر نیز در فرمول‌های (۲) تا (۴) تشریح شده است. این موضوع می‌تواند اثرات زیست محیطی را هرچه بیشتر و با منطق

قوی‌تری در قیمت‌گذاری مجوز طرح ترافیک دخیل نماید. استفاده از این روش قیمت‌گذاری سبب افزایش قیمت طرح ترافیک در ماه‌هایی که شاخص آلودگی بالاتر است شده و در نهایت منجر به کاهش حجم ترافیک ورودی به منطقه طرح ترافیک و نهایتاً کاهش آلودگی می‌شود. به منظور توسعه این پژوهش، پیشنهادات زیر به طور اجمالی ارائه می‌گردد:

۱. تلاش برای غنی و گسترده‌سازی داده‌ها برای ترکیب رویکرد پیش‌بینی و خوشه‌بندی با استفاده از شبکه عصبی مصنوعی در حوزه قیمت‌گذاری سال آتی

۲. به‌کارگیری خوشه‌بندی فازی به منظور افزایش انعطاف تصمیم‌گیری

۳. استفاده از داده‌های روزانه به منظور گسترش و استحکام مدل فوق و خروج از پایه ماهانه

۴. بهره‌گیری از داده‌های لحظه‌ای آلاینده‌های هوا بر اساس به منظور ارائه طرح چند قیمتی در هر روز

منابع و ماخذ

۱. افسر، ا.، هوشدار محجوب، ر.، مینایی، ب. (۱۳۹۲) خوشه‌بندی اعتباری مشتریان برای ارائه تسهیلات متناسب. پژوهش‌های مدیریت در ایران، ۱۷(۴)، ۱-۲۴.
۲. حبیبیان، م.، دیباج، س.، رحمتی، ی. (۱۳۹۱) بررسی سیاست‌های مدیریت تقاضای حملونقل در سفرهای کوتاه کاری به محدوده مرکزی شهر تهران. دوازدهمین کنفرانس بین‌المللی مهندسی حمل و نقل و ترافیک (تهران).
۳. حسنقلی پور، ط.، میری، س.م.، مروتی شریف آبادی، ع. (۱۳۸۶) تقسیم بازار با استفاده از شبکه‌های عصبی مصنوعی مطالعه موردی: فرآورده‌های گوشتی (سوسیسی). مدرس علوم انسانی، ۵۵، ۵۹-۸۰.



3rd edition. Springer.

16. Mazanec, J. (1992). Classifying Tourist into Market Segments: A Neural Network Approach. *Journal of Travel and Tourism Marketing*, 1, 39-59.

17. Niska., H., Hiltunen. T., Karppinen, A., Ruuskanen, J., Kolehmainen, M. (2003). Evolving the neural network model for forecasting air pollution time series. *Engineering Applications of Artificial Intelligence* 17(2), 159-167.

18. Omondi, A.R., Rajapakse, J.C. (2006). FPGA Implementations of Neural Networks. Springer.

19. Pope., C.A., Dockery., D.W. (2006). Health effects of fine particulate air pollution: lines that connect. *Journal of the Air and Waste Management Association*, 56(6), 709-742.

20. Shiva Nagendra, S.M., Khare, M. (2004). Artificial neural network based line source models for vehicular exhaust emission predictions of an urban roadway. *Transportation Research Part D: Transport and Environment* 9(3), 199-208.

21. Slini., T. (2006). A Kaprara, K Karatzas. N. Moussiopoulos. PM(10) forecasting for Thessaloniki. Greece. *Environmental Modelling and Software*, 21(4), 559-565.

22. Tan, P-N., Steinbach, M., Kumar, V. (2006). *Introduction to Data Mining*. Pearson Addison-Wesley.

23. Tiittanen, P., Timonen, K.L., Ruuskanen, J., Mirme, A., Pekkanen, J. (1999). Fine particulate air pollution, resuspended road dust and respiratory health among symptomatic children. *European Respiratory Journal*, 13, 266-273.

24. Tisan, A., Cirstea, M. (2013). SOM neural network design -A new Simulink library based approach targeting FPGA implementation. *Mathematics and Computers in Simulation*, 91, 134-149.

25. Tsai, L. (2009). Customer churn prediction by hybrid neural networks. *Expert Systems with Applications*, 36, 12547-12553.

26. Wan, M., Wang, C., Li, L., Yang, Y. (2012). Chaotic ant swarm approach for data clustering. *Applied Soft Computing*, 12, 2387-2393.

27. Wu, S.J., Feng, Q., Du, Y., Li, X.D. (2001). Artificial neural network models for daily PM(10) air pollution index prediction in the urban area of Wuhan, China. *Environmental Engineering Science*, 28(5), 357-363.

۴. عربان، م. (۱۳۸۸) مهندسی ترافیک. گیلان: انتشارات دانشگاه گیلان.

۵. عسگری، ع.، معینی، س.م.، گلی، ع. (۱۳۹۱) بررسی ایجاد محدوده پیشنهادی طرح ترافیک شیراز از منظر ساکنین شهر. *مدیریت شهری و روستایی*، ۱۰(۲۹): ۱۶۵-۱۷۸.

6. Arnold, R., Smith Vance, C., Doan John, Q., Barry Rodney, N., Blakesley Jayme, L, DeCorla-Souza Patrick, T., Muriello Mark, F., Murthy Gummada, N., Rubstello Patty, K., Thompson Nick, A. (2010). Reducing Congestion and Funding Transportation Using Road Pricing in Europe and Singapore, report No. FHWA-PL-10-030.

7. Bloom Jonathan, Z. (2005). Market Segmentation, A Neural Network Application. *Annals of Tourism Research*, 32, 93-111.

8. Castro, B.M.F., Sanchez, J.M.P., Manteiga, W.G., Bande, M.F., Cela, J.L.B., Fernandez, J.J.H., (2003). Prediction of SO2 levels using neural networks. *Journal of the Air and Waste Management Association*, 53, 532-539.

9. Chan, K.Y., Jian, L. (2013). Identification of significant factors for air pollution levels using a neural network based knowledge discovery system. *Neurocomputing*, 99, 564-569.

10. Dutot, A.L., Rynkiewicz., J. Steiner., E.F., Rude, J. (2007). A 24-h forecast of ozone peaks and exceedance levels using neural classifiers and weather predictions. *Environmental Modelling & Software*, 22(9), 1261-1269.

11. Fulop, I. A., Jozsa, J., Karamer. T., 1998. A neural network application in estimating wind induced shallow lake motion, *Hydro informatics* 98, 2, 753-757.

12. Geoffrey Cobourn, W., Dolcine, L., French, M., Hubbard, M.C. (2000). A comparison of non- linear regression and neural network models for ground-level ozone forecasting. *Journal of the Air & Waste Management Association*, 50(11), 1999-2009.

13. Grivas, G., Chaloulakou, A. (2006). Artificial neural network models for prediction of PM10 hourly concentrations, in the Greater Area of Athens Greece, *Atmos Environ*, 40(7), 1216-1229.

14. Hagan, M.T., Demuth, H.B., Beal, M. (2002). *Neural Network Design*. Singapore: Thamson Asia Pte Ltd.

15. Kohonen, T. (2001). *Self Organizing Map*,



فصلنامه مدیریت شهری
Urban Management
شماره ۳۶ پاییز ۱۳۹۳
No.36 Autumn 2014

■ ۱۵۴ ■