



## پیش‌بینی آلودگی هوای شهر تهران با استفاده از ترکیب شبکه عصبی فازی- تطبیقی و آنالیز مؤلفه اصلی

زنیب قائمی<sup>۱\*</sup>، محمد طالعی<sup>۲</sup>، مهدی فرنقی<sup>۳</sup>، قاسم جوادی<sup>۴</sup>

۱. دانشجوی دکترای سیستم اطلاعات مکانی، دانشکده مهندسی زئودزی و ژئوماتیک دانشگاه صنعتی خواجه نصیرالدین طوسی

۲. دانشیار دانشکده مهندسی زئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی

۳. استادیار دانشکده مهندسی زئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی

۴. عضو هیئت علمی گروه مهندسی عمران، نقشه برداری، دانشکده فنی و مهندسی، دانشگاه بجنورد

تاریخ پذیرش مقاله: ۱۳۹۶/۸/۱۳

تاریخ دریافت مقاله: ۱۳۹۶/۰۳/۷

### چکیده

رشد و توسعه شهری و افزایش استفاده از وسائل نقلیه در سال‌های اخیر منجر به افزایش آلودگی هوای بهویژه در شهرهای بزرگ و صنعتی، شده است. با توجه به آثار نامطلوب آلودگی هوا در سلامت انسان‌ها و دیگر جانداران، پیش‌بینی و مدل‌سازی این پدیده پیچیده از دغدغه‌های اصلی محققان در سال‌های اخیر بوده است. هدف این تحقیق طراحی سیستمی است بهمنظور پیش‌بینی آلودگی هوای طی ۲۴ ساعت آینده، تا با شناسایی مناطق آلوده، به مدیران و برنامه‌ریزان شهری برای کنترل و کاهش میزان آلاینده‌ها کمک کند. در سیستم طراحی شده، از ترکیب آنالیز مؤلفه اصلی و شبکه عصبی فازی- تطبیقی (PCA-ANFIS)، بهمنظور پیش‌بینی آلودگی هوا در فصل‌های متفاوت، استفاده شده است. در این سیستم، داده‌های هواشناسی و غلظت آلاینده‌ها در روزهای گذشته، برای پیش‌بینی آلودگی هوای شهر تهران در ۲۴ ساعت آینده، به کار رفته است. همچنین، از پارامترهای مکانی مانند ارتفاع، توپوگرافی سطح زمین و فاصله از جاده بهمنظور مدل‌سازی مکانی پراکندگی آلودگی هوا استفاده شده است. نتایج حاصل از مقایسه روش ترکیبی PCA-ANFIS با روش ANFIS دقیق و سرعت بالاتر مدل ترکیبی طراحی شده را، بهنسبت روش ANFIS در پیش‌بینی آلودگی هوا طی ۲۴ ساعت آینده، بیان می‌کند.

**کلیدواژه‌ها:** پیش‌بینی آلودگی هوای شهری، شبکه عصبی فازی- تطبیقی، آنالیز مؤلفه اصلی، سامانه اطلاعات مکانی.

\* نویسنده عهده‌دار مکاتبات: تهران، خیابان ولی‌عصر، تقاطع میرداماد، رو به روی ساختمان اسکان، دانشکده زئودزی و ژئوماتیک دانشگاه صنعتی خواجه نصیرالدین طوسی. تلفن: ۸۸۷۷۹۴۷۳-۴

## ۱- مقدمه

پیچیدگی رفتار آلودگی هوای از سوی دیگر، موجب می‌شود روش‌های آمار معمول قادر به مدل‌سازی این پدیده پیچیده و غیرخطی نباشد (Moussiopoulos et al., 1993; Boznar et al., 1995; Kolehmainen et al., 2000) به همین دلیل، دانشمندان در بی روش‌های نوینی برای مدل‌سازی این پدیده پیچیده و غیرخطی اند. در این میان، روش‌های مبتنی بر هوش مصنوعی<sup>۲</sup>، به دلیل توانایی بالا در مدل‌سازی مسائل غیرخطی و پیچیده، در پیش‌بینی آلودگی هوای مورد استفاده گسترده‌ای قرار گرفته‌اند (Gorai et al., 2014; Brook et al., 2004). برای نمونه، در تحقیقی، فرناندو و همکاران<sup>۳</sup> (۲۰۱۲) از شبکه عصبی برای طراحی سیستم هشدار آلودگی هوای استفاده کرده‌اند. در این سیستم، غلظت آلاینده PM10 با استفاده از داده‌های هواشناسی و مقادیر PM10 در روزهای گذشته، پیش‌بینی شده و نتایج حاصل با سیستم محلی موجود در منطقه مقایسه شده است که عملکرد بهتر شبکه عصبی در پیش‌بینی میزان غلظت PM10 را بیان می‌کند. پرز و همکاران<sup>۴</sup> (۲۰۰۰) از داده‌های سرعت و جهت باد به همراه داده‌های مربوط به غلظت آلاینده‌ها در روزهای قبل، برای پیش‌بینی غلظت PM<sub>10</sub>، با استفاده از شبکه عصبی بهره برده‌اند. در این تحقیق، نتایج سه روش ماندگاری<sup>۵</sup>، رگرسیون خطی و شبکه عصبی چندلایه با یکدیگر مقایسه شده‌اند. نتایج نشان می‌دهد شبکه عصبی با سه لایه دقیقی بیشتر از دو مدل دیگر حاصل می‌کند.

اما با وجود توانایی بالای شبکه‌های عصبی در مدل‌سازی مسائل غیرخطی، این روش‌ها همچنان با محدودیت‌هایی همچون ناهمگرایی به بهینه‌جهانی<sup>۶</sup> مواجه‌اند (Singh et al., 2004; Niska et al., 2013). این مشکل به دلیل استفاده از روش‌های سعی و خطا

توسعه شهرنشینی، گسترش صنایع و افزایش بی‌رویه استفاده از وسایل نقلیه منجر به گسترش آلودگی هوای به‌ویژه در شهرهای بزرگ و صنعتی، شده است. آلودگی هوای، به دلیل آثار زیانبارش در سلامت انسان‌ها و سایر جانداران، اهمیت بسزایی دارد (Brunekreef and Holgate, 2002; Chan-Yeng, 2000; Combarro et al., 2013). تا کنون مطالعات بسیاری در زمینه بررسی ارتباط میان آلودگی هوای بیماری‌های قلبی-عروقی و تنفسی صورت گرفته (Gorai et al., 2014; Brook et al., 2004) که بیانگر تأثیرات منفی آلودگی هوای در سلامت افراد است. این امر موجب شده است در سال‌های اخیر، دانشمندان به دنبال طراحی سیستم‌هایی برای پیش‌بینی آلودگی هوای شهری برآیند تا به کمک آن بتوانند میزان آلودگی هوای را پیش‌بینی کنند و نتایج را در اختیار مدیران و برنامه‌ریزان شهری و نیز عموم افراد قرار دهند.

آلودگی هوای از جمله پدیده‌های پیچیده‌ای است که به صورت زمانی و مکانی تغییر می‌کند و عوامل بسیاری در آن دخیل‌اند. همبستگی میان این پارامترها موجب می‌شود نتایج به دست آمده از مدل‌سازی و پیش‌بینی آلودگی هوای قابلیت اطمینان بالای نداشته باشند (Sahoo et al., 2015; Nia et al., 2015). همچنین، تعداد بالای پارامترهای ورودی زمان پردازش‌ها را نیز افزایش می‌دهد. بنابراین، انتخاب مناسب عوامل ورودی نقش مهمی در زمان پردازش و دقت حاصل دارد. تا کنون، روش‌های گوناگونی برای انتخاب داده‌های ورودی مطرح شده است. یکی از این روش‌ها کاهش ابعاد داده‌های<sup>۷</sup> ورودی با استفاده از تحلیل مؤلفه اصلی است. با استفاده از تحلیل مؤلفه‌های اصلی می‌توان متغیرهای مستقل همبسته بسیاری را با تعداد محدودی متغیر مستقل جدید، که مؤلفه‌های اصلی نام دارند و به یکدیگر وابسته نیستند، جایگزین کرد (Statheropoulos et al., 1998).

1. data reduction  
3. Fernando et al.  
5. persistence

2. artificial intelligence (AI)  
4. Pérez et al.  
6. global minimum

بنابراین، با انتخاب تعداد بهینه خوش‌های، تعداد بهینه قوانین فازی نیز مشخص خواهد شد. برای انتخاب تعداد خوش‌های، از یک روش پارسیشن‌بندی اکتشافی<sup>۶</sup> برای تقسیم‌بندی ورودی خروجی اولیه (چند ورودی و یک خروجی)<sup>۷</sup> به چند زیردسته استفاده می‌شود. بنابراین، هر چند ورودی و یک خروجی به چندین تک‌ورودی-تک‌خروجی<sup>۸</sup> تبدیل می‌شود. برای هریک از این زیردسته‌ها، ارتباط میان ورودی و خروجی با استفاده از تکنیک fuzzy curve fitting به دست می‌آید و یکتابع خطی یک‌متغیره برای هریک از زیردسته‌ها حاصل می‌شود. در میان این توابع، تابعی انتخاب می‌شود که به بهترین شکل خروجی را تخمین می‌زند. درنتیجه، دقت کلی مجموعه ورودی‌ها و خروجی به دست می‌آید. این کار آنقدر تکرار می‌شود تا بهترین دقت حاصل شود. زمانی که روش پارسیشن‌بندی اکتشافی به پایان رسید، تعداد زیردسته‌ها به منزله تعداد قوانین فازی بهینه برای ANFIS در نظر گرفته می‌شود. متغیرهای ورودی انتخاب شده برای پارسیشن‌بندی در روش اکتشافی گزینه‌ای برای متغیرهای ورودی در نظر گرفته می‌شوند و اهمیت نسبی آنها براساس تعداد دفعات تقسیم‌بندی محاسبه می‌شود (برای اطلاعات بیشتر در زمینه فرمول‌ها و ورابط استفاده شده رک.: Shahraiyni et al., 2015). نتایج این تحقیق نشان می‌دهد استفاده از این روش موجب افزایش ۱۰درصدی دقت حاصل شده است. ساهو و همکاران (۲۰۱۵) از ANFIS برای پیش‌بینی شاخص کیفیت آب<sup>۹</sup> رودخانه‌ای در نزدیکی مناطق صنعتی استفاده کردند. همچنین در این تحقیق، از تحلیل آنالیز مؤلفه اصلی

1. linguistic information
2. evolutionary
3. adaptive neuro fuzzy inference system
4. clustering
5. fuzzy C-mean clustering
6. heuristic partitioning method
7. multi inputs-single output
8. single input-single output
9. water quality index

برای انتخاب تعداد لایه‌های پنهان و گره‌ها ایجاد می‌شود. همچنین، شبکه‌های عصبی قادر به تفسیر و تحلیل اطلاعات زبانی<sup>۱</sup> نیستند (Nunnari, 2000). مدل‌های فازی تا حدودی توانسته‌اند این محدودیت شبکه‌های عصبی را برطرف کنند. این مدل‌ها، با استخراج دانش موجود در داده‌های ورودی و درنظر گرفتن عدم اطمینان، قادرند اطلاعات زبانی را تفسیر کنند (Fisher, 2003; McKone and Deshpande, 2005; Ross, 2009). به همین دلیل، در سال‌های اخیر، مدل‌های ترکیبی که بر مبنای ترکیبی از شبکه‌های عصبی، روش‌های فازی و محاسبات تکاملی<sup>۲</sup> باشند برای حل و پیش‌بینی مسائل پیچیده و غیرخطی توسعه یافته‌اند. سیستم استنتاج عصبی فازی-طبیقی (ANFIS)<sup>۳</sup>، که از ترکیب سیستم‌های استنتاج فازی و شبکه‌های عصبی مصنوعی تشکیل شده است، ابزاری قدرتمند برای پیش‌بینی پدیده‌های پیچیده را فراهم می‌کند. این سیستم هم‌زمان از قابلیت‌های تفسیر زبانی مدل‌های فازی و قابلیت خودآموزی شبکه‌های عصبی بهره می‌برد (Jang, 1993). تا کنون تحقیقات متفاوتی Jane and Khare, 2003; Taylan, 2010; Morabito and Versaci, 2003; Taylan, 2017 در این زمینه انجام شده است (). در این میان، می‌توان به تحقیق خزانی و همکاران (۲۰۱۳) اشاره کرد که از دو روش سوگنو و ممدانی برای استخراج قوانین فازی استفاده و نتایج حاصل از مدل ANFIS را برای این قوانین، در پیش‌بینی غلظت مونوکسید کربن، با یکدیگر مقایسه کردند. در تحقیقی دیگر، شهرایینی و همکاران (۲۰۱۵) ساختاری جدید برای پیش‌بینی آلودگی هوا روی ایستگاه‌های سنجش آلودگی به روش ANFIS عرضه کردند. در این تحقیق، از یک روش خوش‌بندی<sup>۴</sup> برای انتخاب پارامترهای ورودی و نیز انتخاب تعداد قوانین فازی استفاده شده است. روش خوش‌بندی فازی C-Mean<sup>۵</sup> برای خوش‌بندی داده‌های آموزشی به کار رفته است. در این روش، هر خوش به منزله یک قانون در نظر گرفته می‌شود.

استفاده شده است. طراحی این سیستم از سه مرحله اصلی تشکیل شده است: در مرحله اول، ابعاد داده‌های ورودی که شامل یازده متغیر ورودی است، با استفاده از آنالیز مؤلفه اصلی به پنج مولفه اصلی تغییر کاهش پیدا می‌کند. کاهش ابعاد داده‌های ورودی موجب کاهش زمان پردازش‌ها می‌شود. سپس از سیستم استنتاج عصبی-فازی تطبیقی برای پیش‌بینی کلاس آلودگی هوا برای ۲۴ ساعت آینده استفاده می‌شود. به منظور ارزیابی کارآیی روش طراحی شده، نتایج حاصل از این روش و همچنین، روش ANFIS با مقدادیر واقعی مقایسه می‌شوند تا بررسی شود نتایج کدام روش به واقعیت نزدیکتر است. درنهایت، نتایج حاصل از سیستم استنتاج عصبی-فازی تطبیقی جهت پنهان‌بندی آلودگی هوا در سطح شهر تهران به کار می‌رود. همچنین به منظور مدل‌سازی دقیق‌تر آلودگی هوا و با توجه به رفتار متفاوت آلودگی هوا در فصل‌های گوناگون، مدل‌سازی برای فصل‌های مختلف انجام و نتایج به صورت فصلی عرضه می‌شود.

در ادامه، ساختار مقاله به این صورت خواهد بود: در بخش ۱، منطقه مطالعاتی و داده‌های استفاده شده معرفی می‌شود. همچنین شیوه نرمال‌سازی داده‌ها و مبانی نظری تحلیل مؤلفه اصلی و سیستم استنتاجی عصبی-فازی تطبیقی در این بخش توضیح داده شده است. سیستم طراحی شده برای پیش‌بینی آلودگی هوای شهری در بخش ۳ تشریح شده است. نتایج حاصل از اجرای مدل ارائه شده در بخش ۴ بحث می‌شود و در بخش ۵ نتیجه‌گیری و پیشنهادات مطرح می‌شود.

## ۲- مواد و روش‌ها

در این بخش منطقه مورد مطالعه و داده‌های

برای حذف همبستگی میان داده‌های ورودی و کاهش ابعاد داده‌های ورودی استفاده شده است. جین و همکارش<sup>۱</sup> نیز (۲۰۱۰) روش عصبی-فازی را برای پیش‌بینی یک ساعتۀ غلظت مونوکسید کربن در منطقه از شهر دهلی هند استفاده کردند. در این تحقیق، از داده‌های دو سال گذشته هواشناسی، به همراه داده‌های ترافیکی، برای پیش‌بینی غلظت این گاز استفاده شده است. در این تحقیق سه روش دلفی، ماتریس همبستگی و تحلیل مؤلفه اصلی، برای استخراج پارامترهای مؤثر در غلظت مونوکسید کربن، به کار رفته که نتایج هر سه روش تقریباً مشابه بوده است. نوع و تعداد توابع فازی در این تحقیق به صورت تجربی و به روش سعی و خطأ انتخاب و درنهایت، چهار ورودی با سه تابع فازی در نظر گرفته شده و همچنین، از تابع گوسین استفاده شده است. آموزش مدل روی یک ایستگاه برای هریک از فصل‌ها انجام شده و سپس مدل آموزش دیده روی ایستگاه دیگری سنجیده شده است. نتایج حاصل عملکرد مناسب مدل استفاده شده را نشان می‌دهد. نیز، مورابیتو و ورساچی<sup>۲</sup> (۲۰۰۳) یک سیستم عصبی-فازی برای پیش‌بینی میزان غلظت هیدروکربن توسعه دادند. در این تحقیق، از داده‌های توبوگرافی و ترافیک در کنار داده‌های غلظت آلاتی‌های داده‌های هواشناسی برای بهبود مدل استفاده شده است. در این تحقیق، ابتدا از شبکه عصبی و روش پرسپترون چندلایه<sup>۳</sup> برای پیش‌بینی غلظت هیدروکربن استفاده شده است. سپس از سیستم استنتاج فازی<sup>۴</sup> برای استخراج قوانین و تفسیر ارتباط میان ورودی‌ها بهره گرفته شده است. درنهایت، خروجی این مراحل برای ساخت یک سیستم خبره برای پیش‌بینی غلظت هیدروکربن‌ها به کار گرفته شده است.

هدف از این تحقیق طراحی سیستمی برای پیش‌بینی آلودگی هوای شهر تهران در ۲۴ ساعت آینده است. در این سیستم از ترکیب آنالیز مؤلفه اصلی و سیستم استنتاج عصبی-فازی تطبیقی برای ایجاد مدل ترکیبی PCA-ANFIS برای پیش‌بینی آلودگی هوا

1. Jain and Khare

2. Morabito and Versaci

3. multi-layer perceptron

4. fuzzy inference system

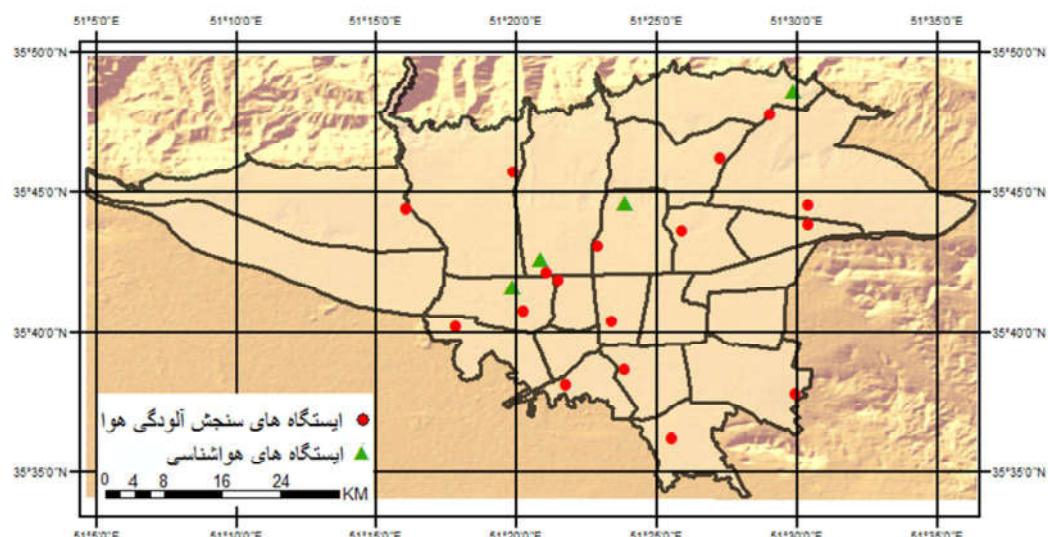
مدیران قرار دهد. همچنین، با آگاهسازی عموم و بهویژه افراد بیمار، از گسترش بیماری‌های ناشی از آلودگی هوا جلوگیری می‌شود.

شکل ۱ موقعیت جغرافیایی شهر تهران را به همراه شیوه توزیع ایستگاه‌های سنجش آلودگی هوا و هواشناسی در سطح شهر نمایش می‌دهد.

**۲-۲- شاخص آلودگی هوا<sup>۱</sup>**  
شاخص کیفیت هوا از جمله شاخص‌های اصلی در بیان میزان آلودگی هواست که امکان تفسیر آلودگی هوا را، با استفاده از مقداری عددی، فراهم می‌کند. به همین منظور، در این تحقیق، از این شاخص برای پیش‌بینی آلودگی هوای شهر تهران استفاده شده است. داده‌های ساعتی مربوط به غلظت آلاینده‌های  $SO_2$ ,  $NO_2$ ,  $PM_{10}$  و  $CO$  مربوط به ۲۱ ایستگاه سنجش آلودگی هوا از شرکت کنترل کیفیت هوای تهران در سال ۱۳۹۳ دریافت شده است. شاخص کیفیت هوا با استفاده از غلظت این آلاینده‌ها و با استفاده از رابطه (۱) محاسبه شده است (Mintz, 2012). پس از محاسبه شاخص

استفاده شده معرفی می‌شوند. همچنین، مبانی نظری روش‌های استفاده شده در این تحقیق در این بخش تشریح خواهد شد.

**۱-۲- منطقه مطالعاتی و داده‌های مورد استفاده**  
شهر تهران مرکز سیاسی و تجاری و پایتخت کشور ایران است که بالغ بر ۸.۵ میلیون نفر در آن ساکن‌اند. تهران از سمت شمال با رشته‌کوه‌های البرز و از سمت جنوب با دشت کویر احاطه شده است. محصوربودن در بین کوه‌ها از سه طرف، که مانع خروج آلودگی‌ها از شهر می‌شود، از یکسو، و افزایش بی‌رویه استفاده از وسائل نقلیه و گسترش صنایع، از سوی دیگر، از عوامل اصلی آلودگی هوا در شهر تهران به‌شمار می‌رود. این نکته باعث شده در برخی از روزهای سال، میزان آلودگی از حد استاندارد بالاتر رود و موجب تعطیلی کامل شهر شود؛ بنابراین، ضرورت طراحی سیستمی برای پیش‌بینی آلودگی هوای شهر تهران نمایان شده است. طراحی چنین سیستمی می‌تواند اطلاعات لازم را برای اقدامات مورد نیاز جهت کنترل آلودگی در اختیار



شکل ۱. موقعیت جغرافیایی شهر تهران و توزیع ایستگاه‌های هواشناسی و سنجش آلودگی هوا

1. air quality index (AQI)

است (Ghaemi et al., 2016).

#### ۴-۲- نرمال‌سازی داده‌ها

داده‌های آلودگی هوا، هواشناسی و داده‌های مکانی پیش از اینکه در جایگاه ورودی به مدل معرفی شوند، نرمال می‌شوند تا مرحله آموزش مدل بهتر انجام شود (Kumar and Goyal, 2011). نرمال‌سازی داده‌ها تمامی داده‌ها را بی‌ واحد و به بازه ۰ تا ۱ نگاشت می‌کند. به منظور نرمال کردن داده‌ها، از رابطه (۲) استفاده شده است:

$$X_{Normal} = \frac{(x_{max}-x)}{(x_{max}-x_{min})} \quad (2)$$

در این رابطه،  $x$  داده ورودی و  $x_{min}$  و  $x_{max}$  به ترتیب، بیشترین و کمترین مقدار داده‌اند.

#### ۵-۲- آزمون بارتلت<sup>۱</sup> و KMO

دو آزمون بارتلت و KMO<sup>۲</sup>، برای بررسی مناسب بودن داده‌ها برای تحلیل مؤلفه اصلی، استفاده می‌شود (Williams et al., 2010). از آزمون بارتلت برای بررسی کافی بودن نمونه‌ها در تحلیل عاملی اکتشافی<sup>۳</sup> استفاده می‌شود. تحلیل عاملی روشی ریاضی برای کاهش ابعاد داده‌هاست. در این آزمون، فرض صفر بدین معناست که نمونه‌های گرفته شده کافی نیستند و در مقابل، فرض یک بر این اساس است که نمونه‌های گرفته شده برای تحلیل عاملی متغیرهای مورد نظر کافی‌اند. در خروجی این آزمون، اگر میزان sig کمتر از ۵ درصد باشد، می‌توان نتیجه گرفت در سطح خطای ۵ درصد و یا سطح اطمینان ۹۵ درصد فرض صفر تأیید نشده و بنابراین، فرض یک، یعنی کافی بودن نمونه‌ها، پذیرفته می‌شود (Zhang et al., 2014). آزمون KMO نیز معیاری برای کافی بودن اندازه نمونه، برای تحلیل عاملی اکتشافی، در نظر گرفته شده است. ضریب آزمون

کیفیت هوا این شاخص، براساس جدول استاندارد طبقه‌بندی آلودگی هوا، به شش کلاس طبقه‌بندی می‌شود. درنهایت، این کلاس به منزله ورودی مدل برای پیش‌بینی آلودگی هوا به کار می‌رود.

$$I = \frac{I_{high} - I_{low}}{C_{high} - C_{low}} (C - C_{low}) + I_{low} \quad (1)$$

$I$  شاخص کیفیت هوا،  $C$  غلظت هربک از آلاینده‌های هوا،  $C_{high}$ ،  $C_{low}$ ،  $I_{high}$  و  $I_{low}$  نقاط انصال مربوط به آلاینده محسب می‌شوند. منظور از نقاط انصال نقاط جداسازی بازه‌های در نظر گرفته شده برای هر کلاس از آلودگی است که از جدول‌هایی که سازمان حفاظت محیط‌زیست در اختیار قرار داده است استخراج می‌شوند (Mintz, 2012).

#### ۳-۲- انتخاب داده‌های ورودی

مطالعات گذشته نشان می‌دهد غلظت آلاینده‌ها در هر روز با توجه به شرایط آب و هوایی (داده‌های هواشناسی) و میزان آلودگی هوا در روزهای گذشته مشخص می‌شود (Ziomas et al., 1995; Robeson and Steyn, 1990). شهر تهران پنج ایستگاه هواشناسی دارد که داده‌های مربوط به وضعیت آب و هوای را گرد می‌آورند و این داده‌ها، از طریق اداره کل هواشناسی استان تهران، در دسترس قرار می‌گیرند. در این مطالعه، داده‌های دما، فشار، سرعت وزش باد، میزان پوشش ابر و رطوبت به منزله پارامترهای تأثیرگذار در آلودگی هوا به کار رفته‌اند. این داده‌ها در بازه زمانی سه ساعتی برداشت شده و به سال ۱۳۹۳ متعلق‌اند. همچنین، مطالعات گذشته نشان می‌دهد میزان آلودگی در سه روز گذشته بیشترین تأثیر را در میزان آلودگی هوا در ۲۴ ساعت آینده دارد (Ghaemi et al., 2016). به همین منظور، داده‌های مربوط به شاخص کیفیت هوا در سه روز گذشته نیز تأثیر بسیار زیادی در توزیع آلاینده‌ها دارد (Zheng et al., 2013). بنابراین، برای مدل‌سازی توزیع مکانی آلاینده‌ها، از پارامترهای مکانی همچون ارتفاع، توپوگرافی سطح زمین و فاصله از جاده استفاده شده

1. Bartlett  
2. Kaiser-Meyer-Olkin  
3. exploratory factor analysis

$$PC_2 = C_{21}X_1 + C_{22}X_2 + C_{23}X_3 + \dots +$$

$$C_{2p}X_p \quad (\text{محور } Y_2)$$

...

$$PC_p = C_{p1}X_1 + C_{p2}X_2 + C_{p3}X_3 + \dots +$$

$$C_{pp}X_p \quad (\text{محور } Y_p)$$

ضریب مؤلفه متغیر  $b$  روی مؤلفه اصلی محور  $Y_a$  است. آنالیز مؤلفه اصلی مجموعه‌ای از متغیرهای  $Y_1, Y_2, \dots, Y_p$  را به متغیرهای جدید ( $X_1, X_2, \dots, X_p$ ) تبدیل کند، که با یکدیگر همبستگی ندارند، تبدیل می‌کند.

**۷-۲- سیستم استنتاج عصبی-فازی تطبیقی**  
در این تحقیق، برای پیش‌بینی آلودگی هوای از سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) استفاده شده است. در این سیستم استنتاجی، ترکیب شبکه عصبی و منطق فازی به منظور نگاشت غیرخطی بین داده‌های ورودی و خروجی به کار می‌رود که ابزاری قدرتمند برای پیش‌بینی پدیده‌های پیچیده را فراهم می‌کند (Jang, 1992; Güler and Übeyli, 2005).

برای نمایش ساختار ANFIS، دو قانون اگر-آن گاه فازی مربوط به مدل سوگنو درجه یک، در ادامه، بیان شده است:

$$\text{If } X \in \mu_{A_1}(x) \text{ and } Y \in \mu_{B_1}(y) \text{ then } f_1 = p_1X + q_1Y + r_1$$

$$\text{If } X \in \mu_{A_2}(x) \text{ and } Y \in \mu_{B_2}(y) \text{ then } f_2 = p_2X + q_2Y + r_2$$

و  $\mu_{B_i}(y)$  توابع عضویت و  $\mu_{A_i}(x)$  مقادیر ثابت‌اند.

همان‌طور که در شکل ۲ نشان داده شده، یک سیستم استنتاج عصبی-فازی تطبیقی از پنج لایه اصلی تشکیل شده است. در این شکل، لایه‌های ثابت با دایره و لایه‌های تطبیقی با مربع نمایش داده شده‌اند.

- 
1. principal component analysis (PCA)
  2. data reduction

KMO همواره بین ۰ و ۱ در نوسان است. در صورتی که مقدار آن کمتر از ۰/۵ باشد، داده‌ها برای تحلیل عاملی مناسب نخواهند بود و در صورتی که مقدار آن بزرگ‌تر از ۰/۷ باشد، همبستگی‌های موجود در بین داده‌ها برای تحلیل مناسب خواهند بود. مقادیر بین ۰/۵ تا ۰/۶۹ نیز بیانگر میانگین میزان تناسب داده‌ها برای تحلیل است (Mostafaeipour et al., 2017). بنابراین، پیش از تحلیل مؤلفه اصلی، با انجام دادن این دو آزمون باید بررسی شود که آیا داده‌ها برای تحلیل مؤلفه اصلی مناسب‌اند یا خیر.

## ۶-۲- تحلیل مؤلفه اصلی<sup>۱</sup>

زمانی که تعداد پارامترهای ورودی اندک است، مدل به راحتی و بدون صرف زمان زیادی اجرا می‌شود. اما به محض اینکه تعداد متغیرهای ورودی افزایش یابد، پیچیدگی مدل بیشتر می‌شود و زمان انجام دادن پردازش‌ها نیز بهشت افزایش می‌یابد. برای این منظور، می‌توان از تکنیک‌های کاهش داده<sup>۲</sup>، مانند تحلیل مؤلفه اصلی برای استخراج مؤلفه‌های اصلی که همبستگی ندارند، استفاده کرد (Alizadeh et al., 2012; Sindelar and Babuska, 2004). با استفاده از تحلیل مؤلفه‌های اصلی، می‌توان متغیرهای مستقل همبسته بسیاری را با تعداد محدودی متغیر مستقل جدید که مؤلفه‌های اصلی نامیده می‌شوند و با یکدیگر وابسته نیستند، جایگزین کرد. مؤلفه‌های غیرهمبسته به دست آمده مؤلفه‌های اصلی (PC) نامیده می‌شوند که از بردارهای ویژه ماتریس کوواریانس یا ماتریس همبستگی متغیرهای اصلی به دست می‌آیند. مزیت اصلی این روش از بین بردن هم خطی در مدل، به علت تعداد زیاد متغیرهای مؤثر در مدل است. در حالت کلی، آنالیز مؤلفه اصلی بدین صورت نوشته می‌شود (Ul-Saufie et al., 2013)

$$PC_1 = C_{11}X_1 + C_{12}X_2 + C_{13}X_3 + \dots +$$

$$C_{1p}X_p \quad (\text{محور } Y_1)$$

شکل ۲. معماری یک سیستم استنتاج عصبی- فازی تطبیقی

منبع: Sahoo et al., 2015

گره‌ها، در لایه سوم نیز، گره‌های ثابت‌اند. در این لایه، مقادیر  $w_i$ ‌ها به صورت زیر نرمال می‌شود:

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i = 1, 2 \quad \text{(رابطه ۷)}$$

گره‌های لایه چهارم گره‌های تطبیقی<sup>۳</sup> به شمار می‌روند. خروجی لایه چهارم نیز بدین صورت است:

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i), \quad i = 1, 2 \quad \text{(رابطه ۸)}$$

خروجی هر گره، در این لایه، محصولی از خروجی لایه سوم و رابطه پلی‌نومیال درجه یک است (برای مدل سوگنو درجه یک).

درنهایت، لایه پنجم، که تنها یک گره ثابت است، خروجی نهایی را محاسبه می‌کند و هدف آن جمع‌بندی تمامی ورودی‌ها به این لایه است. خروجی نهایی از رابطه (۹) حاصل می‌شود:

$$O_i^5 = \sum_{i=1}^2 \bar{w}_i f_i = \frac{\sum_{i=1}^2 w_i f_i}{w_1 + w_2} \quad \text{(رابطه ۹)}$$

همان‌طور که مشاهده شد، در ساختار ANFIS، دو لایه تطبیقی وجود دارد: لایه نخست و لایه چهارم. در لایه اول، سه پارامتر قبل تعديل<sup>۴</sup> { $a_i, b_i, c_i$ } وجود

خروجی لایه اول درجه توابع عضویت<sup>۱</sup> ورودی‌هاست:

$$O_i^1 = \mu A_i(x), \quad i = 1, 2 \quad \text{(رابطه ۳)}$$

$$O_i^1 = \mu B_i(y), \quad i = 1, 2 \quad \text{(رابطه ۴)}$$

در این روابط،  $\mu$  وزن محاسبه شده براساس توابع عضویت فازی است. برای نمونه، اگر از تابع عضویت زنگوله‌ای استفاده شود، مقدار  $(x)$  از رابطه (۵) به دست می‌آید:

$$\mu A_i(x) = \frac{1}{1 + \left( \frac{x - c_i}{a_i} \right)^2} \quad \text{رابطه (۵)}$$

که در آن  $a_i$ ،  $b_i$  و  $c_i$  پارامترهای تابع عضویت‌اند. پارامترهای توابع عضویت در این لایه پارامترهای مقدم<sup>۲</sup> شناخته می‌شوند.

گره‌ها، در لایه دوم، گره‌های ثابت‌اند. در این لایه، توابع عضویت استخراج شده از لایه نخست در یکدیگر ضرب می‌شوند و خروجی لایه دوم از رابطه (۶) حاصل می‌شود. درواقع، با ضرب مقایر ورودی به هر گره در یکدیگر، وزن هر قانون به دست می‌آید.

$$O_i^2 = w_i = \mu A_i(x) = \mu B_i(y) \quad \text{رابطه (۶)}$$

1. membership functions

2. premise parameters

3. adaptive

4. modifiable

دارد که مربوط به تابع عضویت ورودی‌اند. این پارامترها «پارامترهای مقدم» نام دارند. در لایه چهارم، سه پارامتر قابل تعدیل  $\{p_i, q_i, r_i\}$  وجود دارد که مربوط به رابطه پلی‌نومیال می‌شوند. این پارامترها «پارامترهای تالی»<sup>۱</sup> نامیده می‌شوند (Güler and Übeyli, 2005; Jang, 1992). هدف اصلی آموزش ANFIS تنظیم درست این پارامترهاست؛ به گونه‌ای که خروجی ANFIS با داده‌های آموزشی سازگار شود.

در شکل ۳ نشان داده شده است.

$$L_{d+1}^h = f(AQI_d^h, AQI_{d-1}^h, AQI_{d-2}^h, T_{d+1}^h, RH_{d+1}^h, P_{d+1}^h, C_{d+1}^h, WS_{d+1}^h, DR_i, LH_i, SC_i) \quad (۱۰)$$

در این ساختار، اندیس‌های  $d$  و  $h$  به ترتیب روز و ساعت را مشخص می‌کنند. سه پارامتر ابتدایی شاخص آلودگی هوا در سه روز قبل و  $T_{d+1}^h$ ،  $RH_{d+1}^h$  و  $P_{d+1}^h$ ،  $WS_{d+1}^h$ ، به ترتیب، دما، رطوبت نسبی، فشار و سرعت باد را نشان می‌دهند. سه پارامتر انتهایی نیز، به ترتیب،  $SC_i$ ،  $DR_i$ ، فاصله از جاده،  $LH_i$ ، میانگین ارتفاع منطقه و  $TS_i$ ، توپوگرافی سطح زمین را نمایش می‌دهند.  $n$  شماره ایستگاه سنجش آلودگی است.  $L_{d+1}^h$  نیز کلاس آلودگی هوای مربوط به این پارامترها در ۲۴ ساعت بعد را مشخص می‌کند.

مراحل طراحی سیستم نیز در شکل ۶ نمایش داده شده است. پس از شناسایی پارامترهای مؤثر در پیش‌بینی آلودگی هوا، داده‌های گردآوری شده، براساس آنچه در بخش ۲-۴ گفته شد، نرمال‌سازی می‌شوند. سپس تحلیل مؤلفه اصلی، به‌منظور استخراج مؤلفه‌های اصلی، انجام می‌گیرد. پس از استخراج و انتخاب تعداد مؤلفه‌های اصلی و نگاشت داده‌ها به فضای مؤلفه‌ها، داده‌های ورودی به دو دسته آموزش و آزمون تقسیم می‌شوند. ۸۰٪ از داده‌های ورودی برای آموزش و ۲۰٪ برای آزمایش الگوریتم به کار می‌روند. داده‌های آموزشی برای آموزش ANFIS و داده‌های آزمون به‌منظور ارزیابی الگوریتم آموزش دیده استفاده می‌شوند.

#### 1. consequent parameters

پس از تقسیم داده‌ها، تمامی داده‌های آموزشی و

دارد که مربوط به تابع عضویت ورودی‌اند. این پارامترها «پارامترهای مقدم» نام دارند. در لایه چهارم، سه پارامتر قابل تعدیل  $\{p_i, q_i, r_i\}$  وجود دارد که مربوط به رابطه پلی‌نومیال می‌شوند. این پارامترها «پارامترهای تالی»<sup>۱</sup> نامیده می‌شوند (Güler and Übeyli, 2005; Jang, 1992). هدف اصلی آموزش ANFIS تنظیم درست این پارامترهاست؛ به گونه‌ای که خروجی ANFIS با داده‌های آموزشی سازگار شود.

### ۳- طراحی سیستم پیش‌بینی آلودگی هوای شهری با استفاده از مدل ترکیبی PCA-ANFIS

هدف این تحقیق مطرح کردن سیستمی برای پیش‌بینی آلودگی هوای شهر تهران طی ۲۴ ساعت آینده است. در این سیستم، ابتدا پیش‌بینی روی ایستگاه‌های سنجش آلودگی هوا انجام گرفته و سپس، از روش‌های درونیابی به‌منظور پنهان‌بندی آلودگی در سایر مناطق استفاده شده است. در این سیستم، مدل ترکیبی PCA-ANFIS برای پیش‌بینی آلودگی هوا به کار رفته است. از تحلیل مؤلفه اصلی برای کاهش ابعاد داده‌های ورودی استفاده شده که، افزون‌بر کاهش ابعاد داده‌های ورودی و درنتیجه، کاهش زمان محاسبات، همبستگی میان متغیرهای مستقل ورودی را نیز از بین می‌برد. داده‌های هواشناسی شامل دما، رطوبت، فشار، میزان پوشش ابر و سرعت باد، داده‌های مربوط به غلظت آلاینده‌ها در سه روز گذشته به همراه پارامترهای ارتفاع، توپوگرافی سطح زمین و فاصله از جاده، برای طراحی سیستم پیش‌بینی آلودگی هوا، به کار رفته‌اند. برای محاسبه فاصله از جاده، از داده‌های OSM استفاده شده است. جاده‌ها، براساس نوع و عرضشان، وزن دهی می‌شوند و با استفاده ازتابع کرنل، یک رستر استخراج می‌شود که مقدار هر پیکسل بیانگر میزان اهمیت آن پیکسل به‌نسبت جاده است. نقشه ارتفاع با استفاده از داده‌های SRTM با قدرت تفکیک ۹۰ متری تهیه شده است. اثر توپوگرافی براساس میزان تحدب و تقریز زمین بررسی شده است. برای این منظور، از افزونه

ورودی و یک خروجی در شکل ۴ نمایش داده شده است. از آنجاکه هر قانون یک خروجی گستته<sup>۱</sup> دارد، خروجی کلی از میانگین وزن دار<sup>۲</sup> هریک از خروجی‌ها به دست می‌آید. استفاده از این روش موجب کاهش زمان پردازش می‌شود. پس از آموزش، داده‌های تست برای بررسی کارآیی مدل به کار می‌روند. درنهایت، نتایج حاصل از پیش‌بینی برای پهنه‌بندی آلودگی هوا در سطح شهر تهران استفاده می‌شود.

تست در ابزار ANFIS نرم‌افزار متلب، نسخه ۲۰۱۳، بارگذاری می‌شوند. داده‌های آموزشی ابتدا وارد سیستم می‌شوند. با تعیین نوع و تعداد توابع عضویت ورودی و نوع توابع عضویت خروجی، یک سیستم استنتاج فازی از نوع سوگنو با یک خروجی از مدل ایجاد می‌شود. همچنین، تابع خطی بهمنزله تابع عضویت خروجی انتخاب شده است. یک سیستم فازی سوگنو با دو

شکل ۳. ساختار PCA-ANFIS برای پیش‌بینی آلودگی هوای شهری

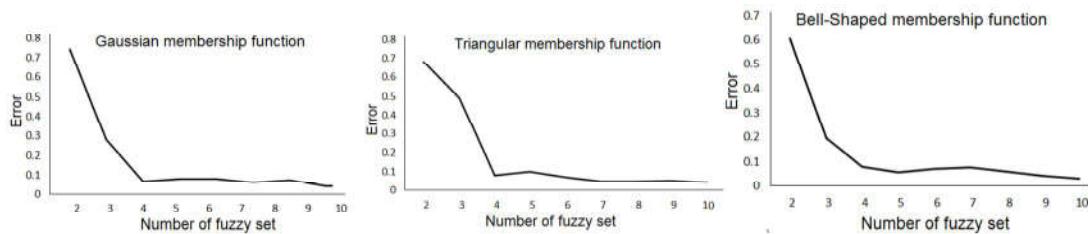
شکل ۴. یک سیستم فازی سوگنو با دو ورودی و یک خروجی

منبع: Riahi-Madvar et al., 2009

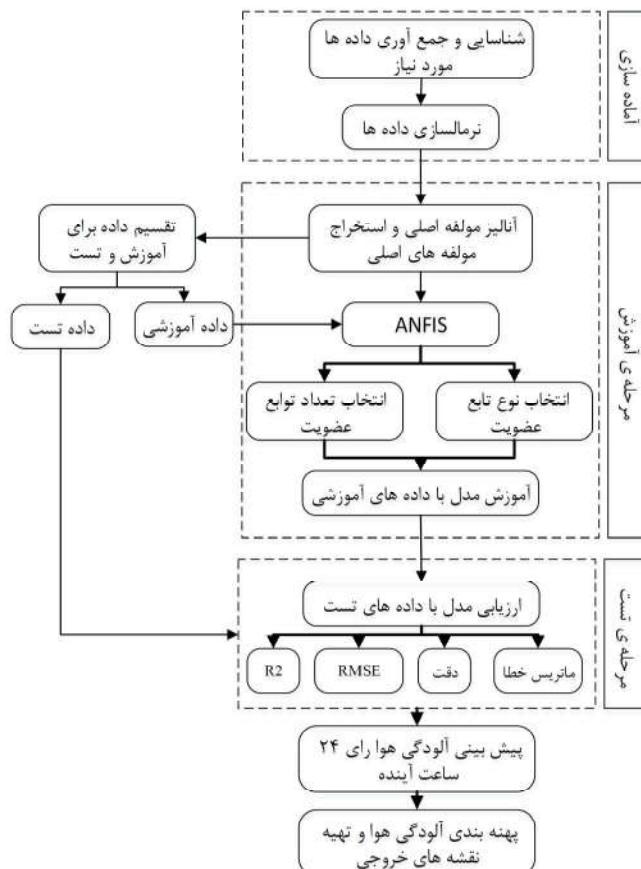
- 
- 1. crisp output
  - 2. weighted average

عضویت، تعداد قوانین به صورت نمایی افزایش می‌یابد و موجب افزایش زمان محاسبات می‌شود و از سویی دیگر، چون با افزایش تعداد این توابع، دقیق حاصل تغییر چشمگیری ندارد؛ بهمنظور کاهش زمان محاسبات، از چهار تابع عضویت برای آموزش شبکه عصبی-فازی طبیعی استفاده شده است. همچنین، از میان این سه تابع عضویت بررسی شده، تابع گوسین دقیق بهتری به دست داده است. بنابراین، از این تابع برای اجرای مدل استفاده می‌شود.

**۱-۳- انتخاب تعداد و نوع تابع عضویت ورودی**  
به منظور تعیین بهترین تابع عضویت و تعداد توابع عضویت، به دلیل زمان برپویان محاسبات، بخشی از داده‌ها برای نمونه انتخاب شدند. سپس سه تابع عضویت پرکابرد مثلثی، زنگوله‌ای و گوسی، با تعداد توابع عضویت بین ۲ تا ۱۰، مورد بررسی قرار گرفتند. نتایج حاصل در شکل ۵ نمایش داده شده است. همان‌طور که در این شکل مشاهده می‌کنید، هر سه تابع، با چهار تابع عضویت، به دقیق مناسبی می‌رسند. از آنجاکه با افزایش تعداد توابع



شکل ۵. مقایسه خطای حاصل از توابع فازی با تغییر تعداد توابع عضویت ورودی



شکل ۶. ساختار سیستم طراحی شده به منظور پیش‌بینی آلودگی هوای شهر تهران برای ۲۴ ساعت آینده

جدول ۱ ماتریس خطای با دو کلاس را نمایش می‌دهد. مقادیر این ماتریس را به صورت زیر می‌توان تفسیر کرد (Athanasiadis et al., 2003):

- a: تعداد نمونه‌های به درستی پیش‌بینی شده، زمانی که نمونه مورد نظر منفی است.
- b: تعداد نمونه‌های منفی که به اشتباه در کلاس مثبت پیش‌بینی شده‌اند.
- c: تعداد نمونه‌های منفی که مثبت‌اند اما به اشتباه در کلاس منفی پیش‌بینی شده‌اند.
- d: تعداد نمونه‌های مثبتی که به درستی پیش‌بینی شده‌اند.

جدول ۱. ماتریس خطا

پیش‌بینی		مشاهداتی
مثبت	منفی	
b	a	منفی
d	c	مثبت

#### ۴- نتایج و تحلیل

در این بخش، نتایج حاصل از اجرای مدل ترکیبی PCA-ANFIS برای پیش‌بینی آلودگی هوای شهر تهران، طی ۲۴ ساعت آینده، تشریح می‌شود. از آنجاکه آلودگی هوا در فصل‌های گوناگون رفتاری متفاوت دارد، آزموزش و سنجش مدل برای چهار فصل جداگانه صورت می‌گیرد و نتایج حاصل بیان می‌شوند.

#### ۵- ماتریس همبستگی

جدول ۲ میزان همبستگی شاخص کیفیت هوا را با پارامترهای هواشناسی، میزان آلودگی در روزهای گذشته و پارامترهای مکانی نشان می‌دهد. همان‌طور که مشاهده می‌کنید، شاخص کیفیت هوا با پارامترهای توپوگرافی، دما، فشار، سرعت باد و پوشش ابر همبستگی منفی و با پارامترهای غلظت آلاینده‌ها در روزهای قبل، ارتفاع، فاصله از جاده و رطوبت همبستگی مثبت دارد.

1. accuracy
2. root mean square error (RMSE)
3. Rsquared
4. confusion matrix

در این تحقیق، با تعیین نوع و تعداد توابع عضویت ورودی، یک سیستم استنتاج فازی از نوع سوگنو ایجاد شده است. ورودی این سیستم مؤلفه‌های استخراج شده از مرحله تحلیل مؤلفه اصلی‌اند و خروجی آن کلاس آلودگی هوا برای ۲۴ ساعت آینده محاسبه می‌شوند.

#### ۶- ارزیابی نتایج

سیستم استنتاج عصبی فازی- تطبیقی با اختصاص وزن‌های تصادفی شروع به آموزش می‌کند. بنابراین، خروجی شبکه ممکن است با مقدار مشاهداتی اختلاف زیادی داشته باشد. زمانی که آموزش ادامه می‌یابد، وزن‌های شبکه به تدریج تعدیل می‌شوند و خروجی سیستم به مقادیر مشاهداتی نزدیک می‌شود. اختلاف مقادیر مشاهداتی و محاسبه شده میزان خطای سیستم را مشخص می‌کند که به روش‌های گوناگونی می‌توان آن را ارزیابی کرد. در این تحقیق، از پارامترهای دقت طبقه‌بندی<sup>۱</sup>، خطای جذر میانگین مربعات<sup>۲</sup>، ضریب تعیین<sup>۳</sup> و ماتریس خطأ<sup>۴</sup> به منظور ارزیابی نتایج استفاده شده است. روابط (۱۱)، (۱۲) و (۱۳)، به ترتیب، شیوه محاسبه پارامترهای دقت، خطای محدود میانگین مربعات و ضریب تعیین را بیان می‌کنند:

دقت = تعداد نمونه‌های تست که به درستی پیش‌بینی شده‌اند / تعداد کل نمونه‌های تست

رابطه (۱۱)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n |Y_i - \bar{Y}_i|^2} \quad \text{رابطه (۱۲)}$$

$$R^2 = 1 - \sum_{i=1}^n (Y_i^* - \bar{Y})^2 / \sum_{i=1}^n (Y_i - \bar{Y})^2 \quad \text{رابطه (۱۳)}$$

در معادلات (۱۲) و (۱۳)،  $\bar{Y}_i^*$  مقدار پیش‌بینی شده و  $\bar{Y}_i$  مقدار مشاهداتی‌اند و در رابطه (۱۳)،  $\bar{Y}$  میانگین مقادیر مشاهداتی است.

ماتریس خطای شامل اطلاعاتی در مورد مقادیر مشاهده شده و پیش‌بینی شده از طریق سیستم‌های طبقه‌بندی است. میزان کارآیی سیستم، با توجه به اطلاعات موجود در این ماتریس، قابل ارزیابی است.

**۲-۴- آزمون بارتلت و KMO**

همچنین، در این جدول‌ها، شاخص KMO نیز نمایش داده شده است. میزان عددی بالای ۶/ برای این شاخص، در تمامی فصل‌ها، نشان از کفايت مناسب نمونه‌گیری برای تحلیل مؤلفه اصلی دارد.

میزان Sig حاصل از نتایج آزمون بارتلت (جدول ۳) نشان می‌دهد فرضیه صفر (وجودنداشتن همبستگی) برای مجموعه داده‌های ورودی رد می‌شود. میزان sig برای هر چهار فصل کمتر از ۵٪ است که به معنای ارتباط قوی بین متغیرهاست.

جدول ۲. ماتریس همبستگی میان پارامترهای ورودی

	AQI <sub>d</sub>	AQI <sub>d-1</sub>	AQI <sub>d-2</sub>	LH	DR	C	T	P	RH	WS	CC
<b>AQI<sub>d</sub></b>	1.000										
<b>AQI<sub>d-1</sub></b>	.467	1.000									
<b>AQI<sub>d-2</sub></b>	.384	.485	1.000								
<b>LH</b>	.125	.127	.122	1.000							
<b>DR</b>	.068	.067	.069	.466	1.000						
<b>SC</b>	-.002	.000	.000	.167	.099	1.000					
<b>T</b>	-.029	-.022	-.042	-.001	.028	.021	1.000				
<b>P</b>	-.014	-.006	.017	-.007	-.030	-.010	-.446	1.000			
<b>RH</b>	.012	-.008	.020	-.007	-.008	-.018	-.761	.278	1.000		
<b>WS</b>	-.002	.002	.001	-.002	.003	.004	.143	-.263	-.204	1.000	
<b>C</b>	-.031	-.051	-.031	-.002	.005	-.012	-.202	-.107	.368	.055	1.000

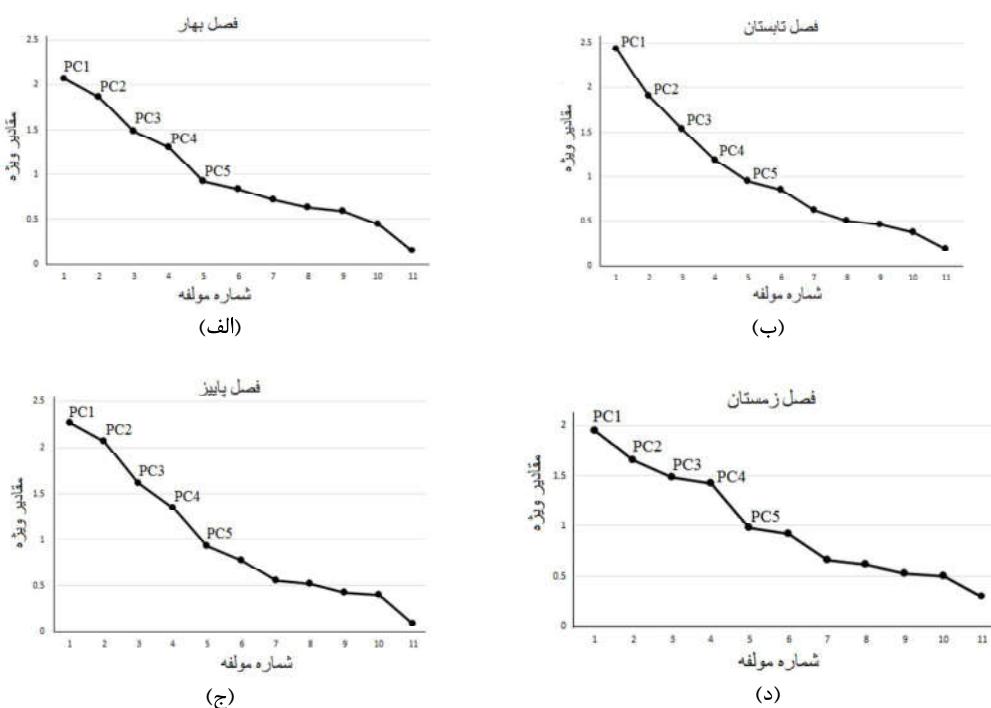
جدول ۳. تست بارتلت و KMO مربوط به داده‌های فصل‌های گوناگون

Spring	Kaiser-Meyer-Olkin Measure of Sampling Adequacy.	.659
	Bartlett's Test of Sphericity	.000
Summer	Kaiser-Meyer-Olkin Measure of Sampling Adequacy.	.671
	Bartlett's Test of Sphericity	.000
Fall	Kaiser-Meyer-Olkin Measure of Sampling Adequacy.	.685
	Bartlett's Test of Sphericity	.000
Winter	Kaiser-Meyer-Olkin Measure of Sampling Adequacy	.618
	Bartlett's Test of Sphericity	.000

در یازده مؤلفه اصلی به دست آمده برای فصل‌های گوناگون در شکل ۷ نمایش داده شده است. با توجه به جدول بردارهای ویژه عناصر در مؤلفه‌های اصلی، پنج مؤلفه اصلی نخست برای پیش‌بینی آلودگی هوا مناسب تشخیص داده شدند. همان‌طور که در جدول ۴ آمده است؛ این پنج مؤلفه، در مجموع، دربردارنده٪۷۰ تغییرات در فصل بهار، ٪۷۳ در فصل تابستان، ٪۷۵ در فصل پاییز و ٪۶۸ درصد تغییرات در فصل زمستان اند. همچنین، جدول ۵ درصد تغییرات مربوط به یازده مؤلفه اصلی استخراج شده را در فصل‌های گوناگون نمایش می‌دهد.

#### ۴-۳- تخمین تعداد مؤلفه‌های اصلی

تعداد کل مؤلفه‌های استخراج شده با تعداد متغیرهای اولیه برابر است. اما برای اجرا، می‌توان تعداد مشخصی از این مؤلفه‌ها را انتخاب کرد. معمولاً دو یا سه مؤلفه اول مقدار چشمگیری از پراکنده‌گی داده‌ها را در نظر می‌گیرد. در این تحقیق، یازده پارامتر ورودی وجود دارد؛ بنابراین، یازده مؤلفه اصلی خواهیم داشت. برای انتخاب مؤلفه‌ها، از مؤلفه‌هایی استفاده شده که مقدار ویژه آنها بیش از یک است. همچنین، مؤلفه‌هایی که مقدار ویژه ۰.۹ دارند نیز، به دلیل نزدیکبودن به مقدار یک، در نظر گرفته می‌شوند. سهم اطلاعات و متغیرها



شکل ۷. مقدار ویژه مؤلفه‌های اصلی برای (الف) فصل بهار؛ (ب) فصل تابستان؛ (ج) فصل پاییز؛ (د) فصل زمستان

جدول ۴. مجموع درصد تغییرات مربوط به پنج مؤلفه اول

فصل سال	درصد تغییرات	بهار	تابستان	پاییز	زمستان
		٪۷۰	٪۷۳	٪۷۵	٪۶۸

زینب قائمی و همکاران

جدول ۵. درصد تغییرات مربوط به هر مؤلفه اصلی برای فصل‌ها گوناگون سال

زمستان	پاییز	تابستان	بهار	فصل	
				شماره مؤلفه	
%۱۸	%۲۱	%۲۲	%۱۹	PC1	
%۱۵	%۱۹	%۱۷	%۱۷	PC2	
%۱۳	%۱۵	%۱۴	%۱۳	PC3	
%۱۳	%۱۲	%۱۱	%۱۲	PC4	
%۹	%۸	%۹	%۸	PC5	
%۸	%۷	%۸	%۸	PC6	
%۶	%۵	%۶	%۶	PC7	
%۶	%۵	%۵	%۶	PC8	
%۵	%۴	%۴	%۵	PC9	
%۵	%۴	%۳	%۴	PC10	
%۳	%۱	%۲	%۱	PC11	

پنج مؤلفه اصلی نخست برای فصل بهار، با توجه به مقادیر جدول ۷، با استفاده از معادلات زیر محاسبه می‌شوند:

جدول ۶ تا جدول ۹ ماتریس مؤلفه‌ها برای فصل‌های گوناگون را نمایش می‌دهند. با استفاده از این ماتریس می‌توان مؤلفه‌ها را محاسبه کرد. برای نمونه،

$$\begin{aligned} PC_1 = & 0.859 * Temp - 0.857 * Hum + 0.198 * AQI^{d-1} + 0.132 * AQI^{d-2} + 0.217 * AQI + \\ & 0.209 * DR + 0.235 * LH - 0.156 * CC - 0.415 * Press + 0.427 * WS + 0.106 * Curv \end{aligned} \quad (رابطه ۱۴)$$

$$\begin{aligned} PC_2 = & -0.324 * Temp + 0.269 * Hum + 0.644 * AQI^{d-1} + 0.618 * AQI^d \\ & + 0.607 * AQI + 0.353 * DR + 0.544 * LH - 0.093 * CC + 0.053 * Press - 0.128 * WS + 0.262 * Curv \end{aligned} \quad (رابطه ۱۵)$$

$$\begin{aligned} PC_3 = & 0.004 * Temp + 0.034 * Hum - 0.398 * AQI^{d-1} - 0.353 * AQI^{d-2} - 0.377 * AQI + 0.742 * DR + \\ & 0.621 * LH + 0.046 * CC + 0.106 * Press - 0.114 * WS + 0.303 * Curv \end{aligned} \quad (رابطه ۱۶)$$

$$\begin{aligned} PC_4 = & -0.171 * Temp + 0.283 * Hum + 0.014 * AQI^{d-1} - 0.103 * AQI^d \\ & + 0.056 * AQI + 0.034 * DR + 0.037 * LH + 0.719 * CC - 0.644 * Press - 0.489 * WS + 0.076 * Curv \end{aligned} \quad (رابطه ۱۷)$$

$$\begin{aligned} PC_5 = & -0.04 * Temp - 0.038 * Hum - 0.026 * AQI^{d-1} + 0.027 * AQI^{d-2} - 0.052 * AQI - 0.276 * DR - \\ & 0.164 * LH + 0.043 * CC + 0.055 * Press - 0.056 * WS + 0.9 * Curv \end{aligned} \quad (رابطه ۱۸)$$

جدول ۸. ماتریس پنج مؤلفه اصلی اول، فصل پاییز

	Component				
	1	2	3	4	5
AQI <sub>d-1</sub>	0.734	-0.169	0.257	-0.183	0.011
AQI <sub>d</sub>	0.682	-0.112	0.25	-0.161	-0.114
AQI <sub>d-2</sub>	0.656	-0.178	0.268	-0.17	0.164
P	-0.125	-0.822	-0.132	0.009	-0.124
C	-0.023	0.713	0.378	-0.122	-0.329
H	-0.403	0.115	0.777	-0.279	0.102
T	0.485	0.454	-0.505	0.172	-0.387
LH	0.202	-0.071	0.328	0.708	-0.062
DR	-0.071	0.045	0.273	0.7	0.01
WS	0.216	0.395	-0.224	0.092	0.802
SC	0.096	-0.108	0.179	0.458	0.068

جدول ۹. ماتریس پنج مؤلفه اصلی اول، فصل پاییز

	ent	Compo			
	1	2	3	4	5
RH	-0.883	0.35	-0.035	0.044	-0.028
T	0.875	-0.33	0.013	0.131	0.016
AQI <sub>d-1</sub>	0.341	0.756	-0.167	-0.051	0.001
AQI <sub>d-2</sub>	0.308	0.728	-0.148	-0.008	-0.001
AQI <sub>d</sub>	0.324	0.718	-0.152	-0.126	0.016
DR	0.045	0.086	0.85	0.037	-0.287
LH	0.112	0.331	0.808	0.012	-0.14
P	-0.062	-0.165	0.076	-0.704	-0.054
WS	0.342	-0.135	-0.023	0.695	-0.025
C	-0.515	0.223	-0.042	0.572	-0.105
SC	-0.071	0.096	0.396	0.059	0.903

روش ANFIS مقایسه شد. پارامترهای دقت، خطای جذر میانگین مربعات و ضریب تعیین به دست آمده برای فصل های متفاوت، با استفاده از داده های تست برای این دو روش، در جدول ۱۰ آمده است. طبق این جدول، روش ترکیبی PCA-ANFIS توانسته دقت بالاتری را در پیش‌بینی آلودگی هوای در فصل های متفاوت حاصل کند. دلیل آن ممکن است حذف همبستگی میان پارامترهای ورودی باشد که در نتایج تأثیر دارد. شکل ۷ زمان پردازش دو روش PCA-ANFIS و ANFIS را، در فصل های

جدول ۶. ماتریس پنج مؤلفه اصلی اول، فصل تابستان

	Component				
	1	2	3	4	5
T	-0.702	0.585	-0.077	0.076	-0.057
AQI <sub>d-1</sub>	0.696	0.498	-0.092	-0.008	0.092
AQI <sub>d-2</sub>	0.665	0.49	-0.102	0.101	0.043
AQI <sub>d</sub>	0.606	0.511	-0.085	0.1	0.033
RH	0.532	-0.569	0.147	0.385	0.001
P	0.466	-0.518	0.04	-0.164	0.137
DR	-0.064	0.11	0.841	0	-0.223
LH	0.15	0.309	0.792	-0.011	-0.112
CC	-0.115	-0.158	0.117	0.86	0.077
SC	-0.07	-0.067	0.364	-0.304	0.777
WS	-0.308	0.293	-0.02	0.381	0.493

جدول ۷. ماتریس پنج مؤلفه اصلی اول، فصل بهار

	Component				
	1	2	3	4	5
T	0.859	-0.324	0.004	-0.171	0.04
H	R-	0.269	0.034	0.283	-0.038
AQI <sub>d-1</sub>	0.198	0.644	-0.398	0.014	-0.026
AQI <sub>d-2</sub>	0.132	0.618	-0.353	-0.103	0.027
AQI <sub>d</sub>	0.217	0.607	-0.377	0.056	-0.052
DR	0.209	0.353	0.742	0.034	-0.276
LH	0.235	0.544	0.621	0.037	-0.164
C	-0.156	-0.093	0.046	0.719	0.043
P	-0.415	0.053	0.106	-0.644	0.055
WS	0.427	-0.128	-0.114	0.489	-0.056
SC	0.106	0.262	0.303	0.079	0.9

به همین ترتیب و براساس ماتریس مؤلفه های مربوط به هر فصل، مؤلفه های اصلی برای فصل های دیگر نیز به دست می آیند.

۴-۴- مقایسه نتایج روش ترکیبی PCA-ANFIS و ANFIS برای فصل های گوناگون برای ارزیابی کارآیی روش ترکیبی PCA-ANFIS نتایج حاصل از این روش، از نظر دقت و زمان پردازش، با

خطای جذر میانگین مربعات را دارد؛ یعنی مدل ترکیبی توانسته است، در این فصل، آلودگی هوا را با دقت بالاتری پیش‌بینی کند. جدول ۱۱ تا جدول ۱۴ به ترتیب، ماتریس خطای حاصل برای فصل‌های بهار، پاییز، پاییز و زمستان را نشان می‌دهد. ستون آخر هریک از این جدول‌ها دقت حاصل برای هریک از کلاس‌های آلودگی هوا را بیان می‌کند. همچنین، جدول ۱۵ دقت به دست آمده برای کلاس‌های متفاوت در فصل‌های گوناگون را نمایش می‌دهد. مطابق این جدول، دقت به دست آمده برای کلاس‌های ۵ و ۶ در تابستان، پاییز و زمستان صفر و در بهار نیز بسیار پایین است. همچنین، با توجه به ماتریس‌های خطا در فصل‌های گوناگون و توجه به تعداد نمونه‌ها در هر کلاس، مشخص می‌شود که با کاهش تعداد نمونه‌ها در کلاس‌های متفاوت، دقت حاصل نیز کاهش می‌یابد. بنابراین، به دلیل تعداد پایین نمونه‌ها در کلاس‌های ۵ و ۶، مدل PCA-ANFIS نتوانسته به درستی این کلاس‌ها را پیش‌بینی کند. مقایسه جدول ۱۰ و جدول ۱۱ با یکدیگر نیز نشان می‌دهد، با وجود اینکه مدل-PCA-ANFIS بالاترین دقت کلی را در پیش‌بینی آلودگی هوا در فصل زمستان داشته است، در فصل بهار توانسته تا حدودی کلاس‌های آلودگی ۵ و ۶ را نیز پیش‌بینی کند.

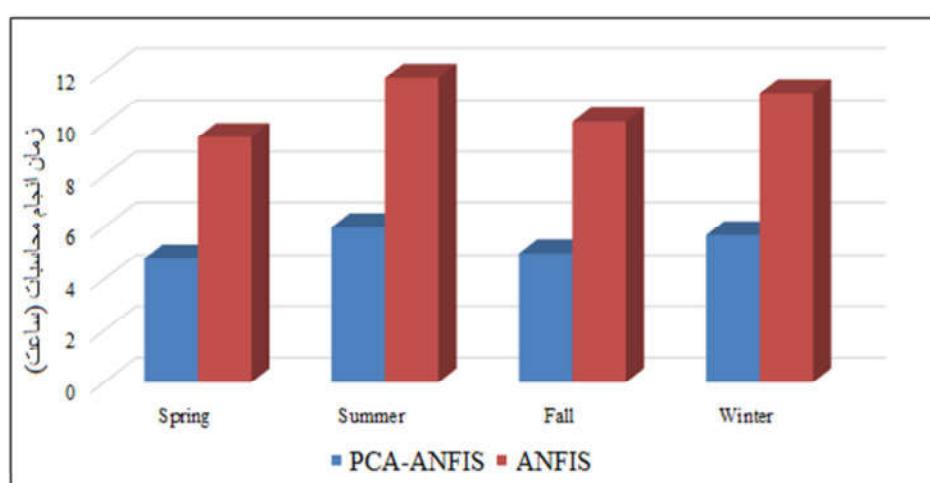
گوناگون، با یکدیگر مقایسه می‌کند. همان‌گونه که مشاهده می‌کنید، وقتی از روش ANFIS استفاده شده است، به دلیل افزایش تعداد پارامترهای ورودی، زمان پردازش تا حدود دوبرابر افزایش یافته است. بنابراین، روش ترکیبی PCA-ANFIS افزون بر افزایش دقت توانسته است با سرعت بالاتری محاسبات را انجام دهد.

جدول ۱۰. پارامترهای ارزیابی به دست آمده برای داده‌های تست در فصل‌های گوناگون، در دو روش ANFIS و PCA-ANFIS

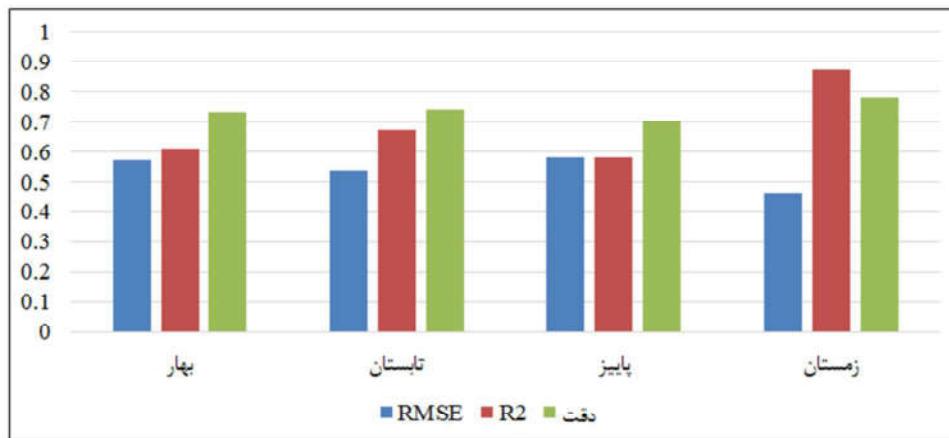
	ANFIS			PCA-ANFIS		
	RMSE	R2	دقت	RMSE	R2	دقت
بهار	۰/۶۸	۰/۵۵	۰/۶۵	۰/۵۷	۰/۶۱	۰/۷۳
تابستان	۰/۶۳	۰/۶۰	۰/۶۷	۰/۵۴	۰/۶۷	۰/۷۴
پاییز	۰/۶۲	۰/۵۳	۰/۵۹	۰/۵۸	۰/۶۸	۰/۷
زمستان	۰/۵۲	۰/۶۶	۰/۶۴	۰/۴۶	۰/۸۷	۰/۷۸

#### ۴-۱-۴- تحلیل نتایج حاصل از روش ترکیبی PCA-ANFIS

دقت، خطای جذر میانگین مربعات و ضریب تعیین به دست آمده برای فصل‌های گوناگون، در روش PCA-ANFIS، در شکل ۹ آمده است. مشخص است که فصل زمستان بالاترین دقت و ضریب تعیین و کمترین میزان



شکل ۸. مقایسه زمان پردازش برای دو روش ANFIS و PCA-ANFIS



شکل ۹. مقایسه دقت، ضریب تعیین و خطای جذر میانگین مربعات در فصل‌های گوناگون، برای روش PCA-ANFIS

جدول ۱۱. ماتریس خطای فصل بهار

دقت کلاس	تعداد نمونه در هر کلاس	پیش‌بینی									مشاهداتی
		۶	۵	۴	۳	۲	۱	۰	۱	۲	
۰/۶۹	۱۶۰۸	۰	۰	۱	۱۲	۴۹۸	۱۱۰۲	۱			
۰/۸۳	۲۰۲۶	۰	۰	۰	۱۴۰	۱۶۷۵	۲۱۱		۲		
۰/۶۰	۲۴۳	۰	۰	۴	۱۴۷	۸۹	۳		۳		
۰/۳۹	۶۴	۰	۰	۲۵	۲۲	۱۷	۰		۴		
۰/۲۱	۳۳	۱	۷	۴	۱۴	۷	۰		۵		
۰/۰۵	۲۱	۱	۱	۲	۱۶	۱	۰		۶		

جدول ۱۲. ماتریس خطای فصل تابستان

دقت کلاس	تعداد نمونه در هر کلاس	پیش‌بینی									مشاهداتی
		۶	۵	۴	۳	۲	۱	۰	۱	۲	
۰/۶۲	۲۰۶۸	۰	۰	۰	۱۰	۷۶۵	۱۲۹۳	۱			
۰/۸۸	۴۰۹۷	۰	۱	۱	۱۱۰	۳۶۳۴	۳۵۱	۲			
۰/۳۹	۷۸۵	۱	۰	۶	۳۰۷	۴۵۴	۱۷		۳		
۰/۳۲	۳۷	۰	۰	۱۲	۱۰	۱۴	۱		۴		
۰	۱۰	۰	۰	۲	۳	۳	۲		۵		
۰	۱	۰	۱	۰	۰	۰	۰		۶		

زینب قائمی و همکاران

جدول ۱۳. ماتریس خطای فصل پاییز

دقت کلاس	تعداد نمونه در هر کلاس	پیش‌بینی							مشاهداتی
		۶	۵	۴	۳	۲	۱		
۰/۶۶	۲۱۳۸	۰	۰	۰	۳۷	۶۹۶	۱۴۰۵	۱	
۰/۷۸	۳۰۳۸	۰	۰	۳	۱۸۱	۲۳۶۸	۴۸۶	۲	
۰/۵۵	۷۱۰	۰	۰	۵۴	۳۹۲	۲۵۳	۱۱	۳	
۰/۳۵	۸۸	۰	۰	۳۱	۳۳	۲۲	۲	۴	
۰	۱۷	۰	۰	۲	۱۱	۲	۲	۵	
۰	۷	۰	۰	۰	۵	۲	۰	۶	

جدول ۱۴. ماتریس خطای فصل زمستان

دقت کلاس	تعداد نمونه در هر کلاس	پیش‌بینی							مشاهداتی
		۶	۵	۴	۳	۲	۱		
۰/۷۱	۲۵۱۷	۰	۱	۵	۱۳	۶۹۲	۱۸۰۶	۱	
۰/۸۵	۳۷۱۸	۰	۳	۷	۱۳۵	۳۱۸۶	۳۸۷	۲	
۰/۶۷	۶۷۷	۰	۱	۶	۴۶۰	۱۸۴	۲۶	۳	
۰/۳۷	۶۹	۰	۱	۲۶	۱۹	۲۰	۳	۴	
۰	۱۰	۰	۰	۰	۵	۵	۰	۵	
۰	۶	۰	۶	۰	۳	۳	۰	۶	

جدول ۱۵. دقت به دست آمده برای هر کلاس در فصل‌های گوناگون

۶	۵	۴	۳	۲	۱	کلاس		فصل
						۰/۰۵	۰/۲۱	
۰/۰۵	۰/۲۱	۰/۳۹	۰/۶	۰/۸۳	۰/۶۹			بهار
۰	۰	۰/۳۲	۰/۳۹	۰/۸۸	۰/۶۲			تابستان
۰	۰	۰/۳۵	۰/۵۵	۰/۷۸	۰/۶۶			پاییز
۰	۰	۰/۳۲	۰/۶۷	۰/۸۵	۰/۷۱			زمستان

می‌توان نواحی آلودگی را، در روزهای مورد نظر، شناسایی کرد و راهکارهایی را برای کاهش آلودگی هوا در این مناطق پیشنهاد داد. افراد بیمار و گروههای حساس نیز می‌توانند، با مراجعه به نقشه‌های خروجی، فعالیت‌های خود را در مناطق آلوده کاهش دهند.

شکل ۱۳ تا شکل ۱۶، به ترتیب، مقایسه مقادیر PCA-ANFIS پیش‌بینی شده را، با استفاده از دو روش PCA-ANFIS، با مقادیر واقعی برای بهار، تابستان، پاییز و زمستان نمایش می‌دهد. برای مقایسه مقادیر پیش‌بینی شده با مقادیر واقعی، مجموع اختلاف کلاس‌های پیش‌بینی شده با مقادیر واقعی، برای هر دو روش در فصل‌های مختلف، محاسبه شده است. نتایج حاصل در جدول ۱۶ ارائه شده‌اند. همان‌طور که دیده می‌شود، اختلاف مقادیر مشاهده شده با استفاده از روش PCA-ANFIS با مقادیر واقعی در سه فصل بهار، تابستان و پاییز کمتر از اختلاف مقادیر پیش‌بینی شده به روش ANFIS با مقادیر واقعی است و در فصل زمستان، اختلاف مقادیر پیش‌بینی شده با دو روش با مقادیر واقعی برابر است.

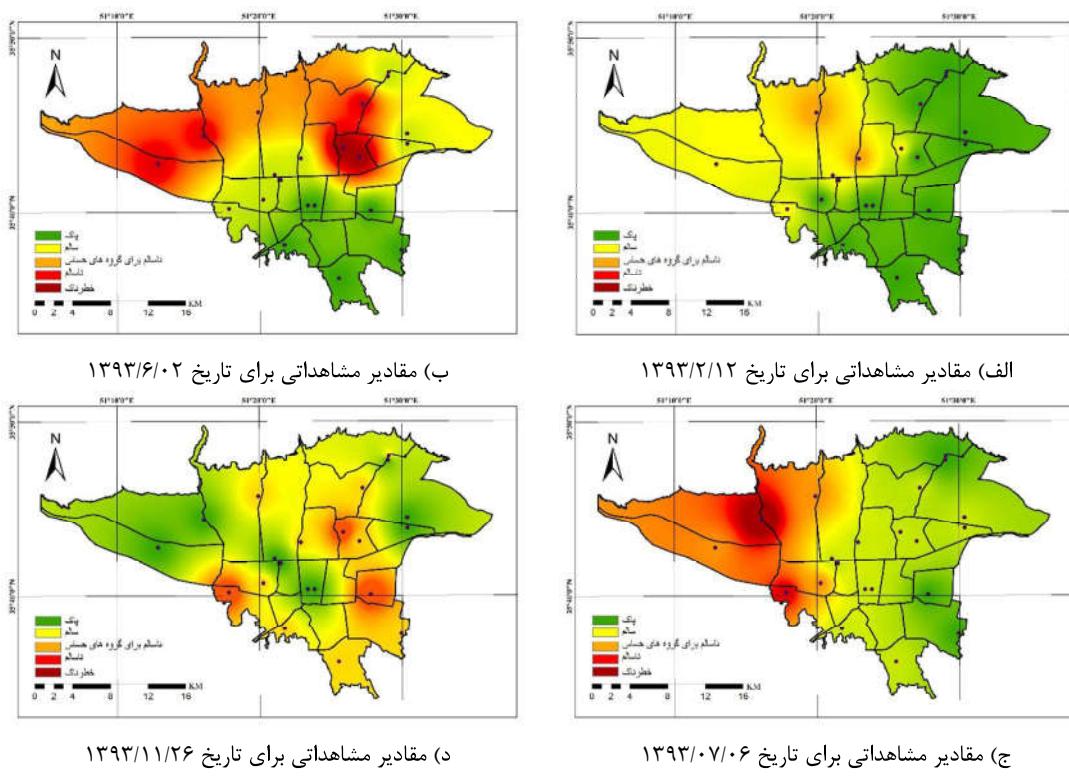
جدول ۱۶. اختلاف میان مقادیر واقعی کلاس آلودگی هوا با مقادیر پیش‌بینی شده، با استفاده از دو روش PCA-ANFIS و ANFI

فصل سال	بهار	تابستان	پاییز	زمستان	
اختلاف با مقادیر					واقعی
۶	۸	۸	۷	PCA-ANFIS	
۶	۱۱	۹	۸	ANFIS	

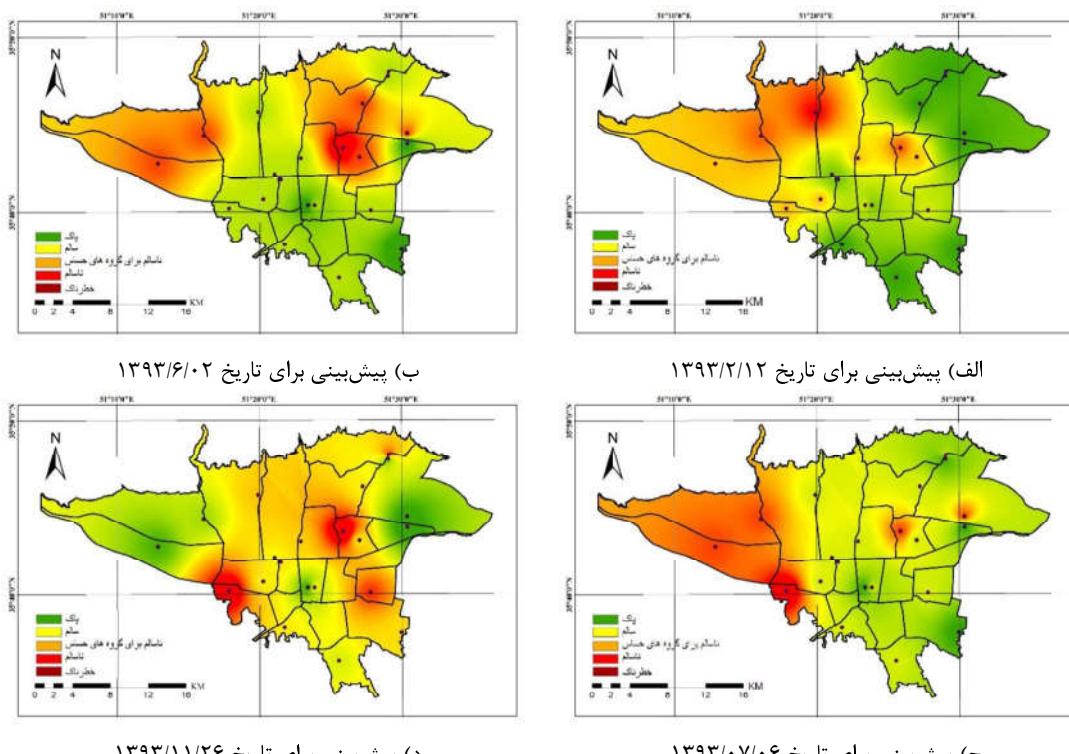
#### 1. inverse distance weighting (IDW)

پس از آموزش مدل و پیش‌بینی آلودگی هوای تهران در ۲۴ ساعت آینده، با استفاده از مدل PCA-ANFIS می‌توان از نتایج به دست آمده برای پهنه‌بندی آلودگی هوا در مناطق گوناگون استفاده کرد. بدین‌منظور، پس از پیش‌بینی روی ایستگاه‌های سنجش آلودگی هوا، برای به دست آوردن میزان آلودگی هوا در مناطقی غیر از ایستگاه‌های سنجش آلودگی هوا، از روش درونیابی معکوس فاصله وزن دار<sup>۱</sup> استفاده شده است. شکل ۱۱ نتایج حاصل از پیش‌بینی آلودگی هوا با استفاده از روش ترکیبی PCA-ANFIS و شکل ۱۲ نیز نتایج حاصل از پیش‌بینی آلودگی هوا در تاریخ‌های مشخص شده را با استفاده از روش ANFIS، در فصل‌های گوناگون، نمایش می‌دهد. مقادیر واقعی آلودگی هوا برای این تاریخ‌ها در شکل ۱۲ نمایش داده شده است. با مقایسه نقشه‌های خروجی با مقادیر واقعی می‌توان به این نتیجه رسید که نقشه‌های حاصل از خروجی روش PCA-ANFIS به نقشه‌های مقادیر واقعی نزدیک‌تر است. مسئله دیگری که می‌توان به آن پرداخت علت بالابودن آلودگی هوا در برخی مناطق شهر است. این امر می‌تواند به عوامل متفاوتی، از جمله شدت و جهت وزش باد، میزان ترافیک و محل صنایع آلوده‌کننده ربط داشته باشد. برای نمونه، بررسی پارامترهای ورودی برای تاریخ ۹۳/۰۶/۰۲ نشان داد، در این تاریخ، جهت باد از سمت جنوب بوده که موجب شده آلودگی به بخش مرکزی شهر منتقل شود. همچنین، تمرکز بیشتر جاده‌ها در بخش مرکزی وجود اتوبان و صنایع آلوده‌کننده در بخش‌های غربی شهر موجب تمرکز بیشتر آلودگی در این نواحی شده است. بدین ترتیب، با بررسی پارامترهای ورودی، می‌توان ارتباط میان آلودگی هوا در مناطق گوناگون با این پارامترها را استخراج کرد و برنامه‌ریزی‌های لازم را، به منظور کاهش میزان آلودگی در این مناطق، اتخاذ کرد. همچنین، با استفاده از نقشه‌های تولید شده

## زینب قائمی و همکاران

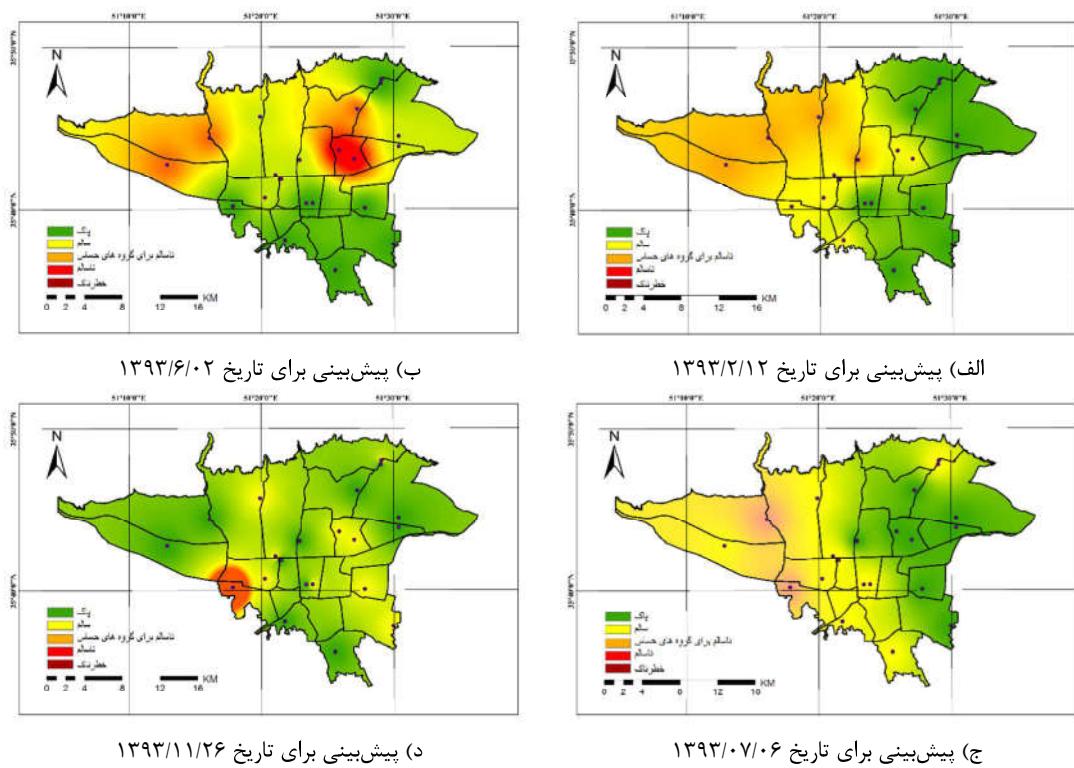


شکل ۱۰. مقدار مشاهداتی آلودگی هوا برای فصل بهار (الف)؛ فصل تابستان (ب)؛ فصل پاییز (ج)؛ فصل زمستان (د)

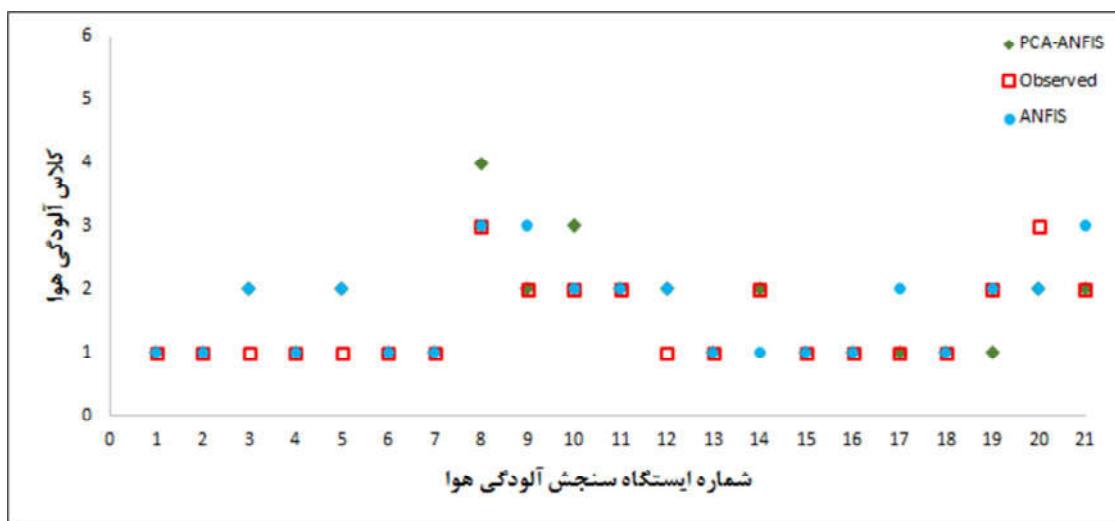


شکل ۱۱. پیش‌بینی آلودگی هوا برای فصل بهار (الف)؛ فصل تابستان (ب)؛ فصل پاییز (ج)؛ و فصل زمستان (د) با استفاده از روش PCA-ANFIS

پیش‌بینی آلودگی هوای شهر تهران با استفاده از ترکیب ...

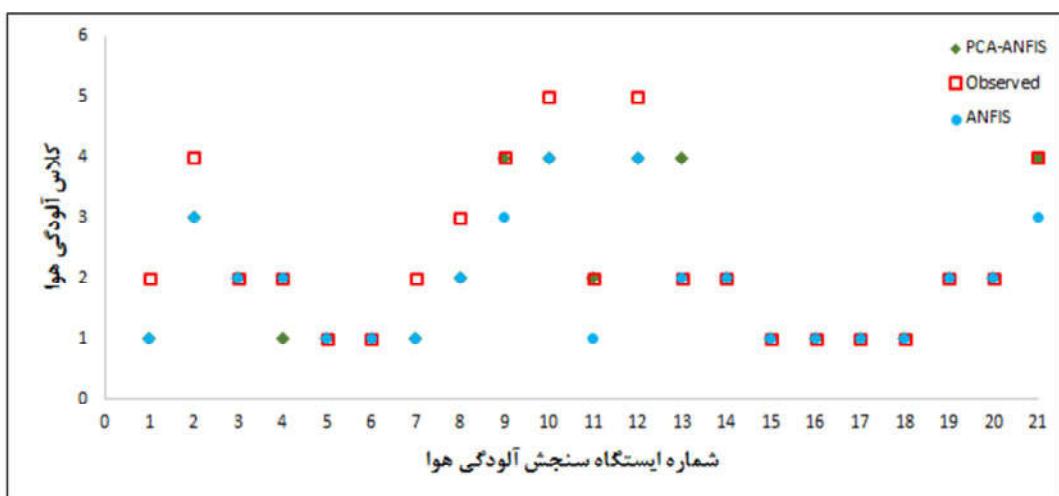


شکل ۱۲. پیش‌بینی آلودگی هوای برای فصل بهار (الف)؛ فصل تابستان (ب)؛ فصل پاییز (ج)؛ فصل زمستان (د) با استفاده از روش ANFIS

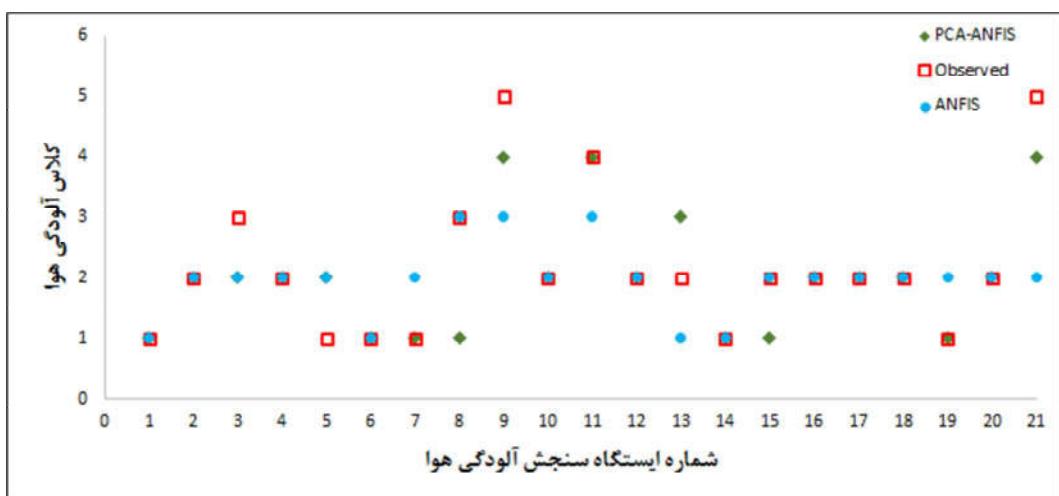


شکل ۱۳. مقایسه مقادیر مشاهداتی و پیش‌بینی شده برای تاریخ ۱۳۹۳/۲/۱۲

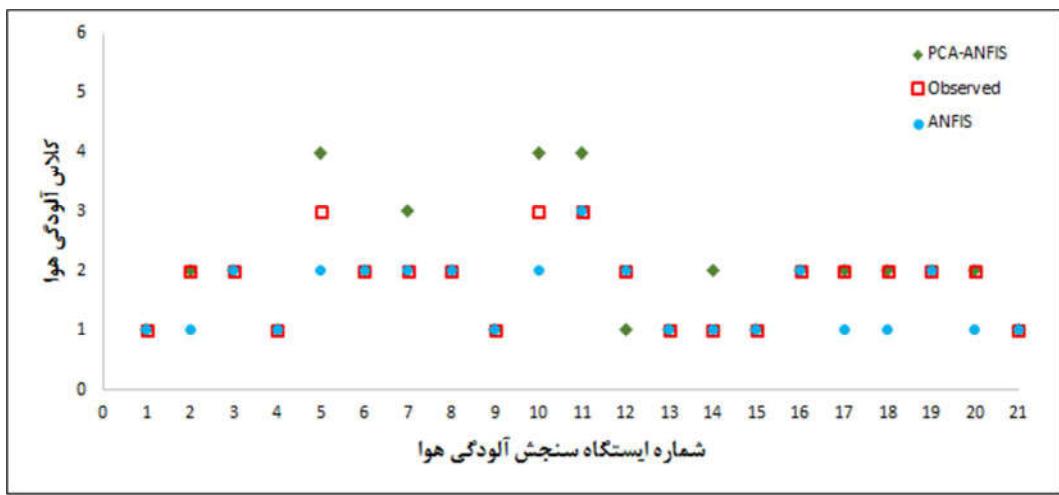
### زینب قائمی و همکاران



شکل ۱۴. مقایسه مقادیر مشاهداتی و پیش‌بینی شده برای تاریخ ۱۳۹۳/۶/۰۲



شکل ۱۵. مقایسه مقادیر مشاهداتی و پیش‌بینی شده برای تاریخ ۱۳۹۳/۷/۰۶



شکل ۱۶. مقایسه مقادیر مشاهداتی و پیش‌بینی شده برای تاریخ ۱۳۹۳/۱۱/۲۶

## مقایسه دو روش مدل‌سازی با استفاده از شبکه عصبی-فازی در پیش‌بینی غلظت آلاینده

مونوکسید کربن، محیط‌شناسی، دوره ۳۸، شماره ۴.

- Alizadeh, M., Jolai, F., Aminnayeri, M. & Rada, R., 2012, **Comparison of Different Input Selection Algorithms in Neuro-Fuzzy Modeling**, Expert Systems with Applications, 39(1), PP. 1536–1544.
- Athanasiadis, I.N., Kaburlasos, V.G., Mitkas, P.A. & Petridis, V., 2003, **Applying Machine Learning Techniques on Air Quality Data for Real-Time Decision Support**, First International NAISO Symposium on Information Technologies in Environmental Engineering (ITEE'2003), Gdansk, Poland.
- Boznar, M., Lesjak, M. & Mlakar, P., 1993, **A Neural Network-Based Method for Short-Term Predictions of Ambient SO<sub>2</sub> Concentrations in Highly Polluted Industrial Areas of Complex Terrain**, Atmospheric Environment, Part B: Urban Atmosphere, 27(2), PP. 221–230.
- Brook, R.D., Franklin, B., Cascio, W., Hong, Y., Howard, G., Lipsett, M., Luepker, R., Mittleman, M., Samet, J. & Smith, S.C., 2004, **Air Pollution and Cardiovascular Disease**, Circulation 109(21), PP. 2655–2671.
- Brunekreef, B. & Holgate, S.T., 2002, **Air Pollution and Health**, The Lancet 360(9341), PP. 1233–1242.
- Chan-Yeung, M., 2000, **Air Pollution and Health**, Hong Kong Medical Journal 6(4), PP. 390–398.
- Fernando, H.J., Mammarella, M., Grandoni, G., Fedele, P., Di Marco, R., Dimitrova, R. & Hyde, P., 2012, **Forecasting PM 10 in Metropolitan Areas: Efficacy of Neural Networks**, Environmental Pollution 163, PP. 62–67.
- Fisher, B., 2003, **Fuzzy Environmental Decision-Making: Applications to Air Pollution**, Atmospheric Environment 37(14), PP. 1865–1877.
- García Nieto, P.J., Combarro, E.F., del Coz Díaz, J.J. & Montañés, E., 2013, **A SVM-Based Regression Model to Study the Air Quality at Local Scale in Oviedo Urban Area (Northern Spain): A Case Study**, Applied Mathematics and Computation 219(17), PP. 8923–8937.

## ۵- نتیجه‌گیری

هدف این پژوهش عرضه سیستمی برای پیش‌بینی آلودگی هوای شهر تهران طی ۲۴ ساعت آینده است. این سیستم می‌تواند داده‌های ایستگاه‌های سنجش آلودگی هوای ایستگاه‌های سنجش آلودگی هوای پیش‌بینی کند. با توجه به زیان آلودگی هوای برای سلامت انسان و میزان خسارتی که به طبیعت و جامعه وارد می‌کند، استفاده از این سیستم پیش‌بینی آلودگی هوای ضروری می‌نماید. به منظور پیش‌بینی، مدل ترکیبی PCA-ANFIS طراحی شده است. استفاده از تحلیل مؤلفه اصلی موجب حذف همبستگی میان پارامترهای ورودی و افزایش قابلیت اطمینان نتایج حاصل می‌شود. همچنین، با استفاده از این تحلیل، با وجود اینکه ابعاد داده‌های ورودی کاهش می‌یابد، مقدار معنابهی از پراکندگی موجود در داده‌های ورودی حفظ می‌شود. کاهش ابعاد داده‌های ورودی زمان محاسبات را نیز کاهش می‌دهد. برای ارزیابی روش طراحی شده، این مدل با روش ANFIS در پیش‌بینی آلودگی هوای مقایسه شد که نتایج آن دقیق‌تر و سرعت بالاتر روش ترکیبی PCA-ANFIS را، در مقایسه با روش ANFIS، نشان می‌دهد. همچنین، نتایج به دست آمده بیان می‌کند مدل، در فصل زمستان، بالاترین دقیق‌تر کلی را حاصل می‌کند. اما در فصل بهار، توانسته در پیش‌بینی هریک از کلاس‌ها بهتر عمل کند.

یکی از مشکلات مدل توسعه یافته عملکرد ضعیف آن در پیش‌بینی کلاس‌هایی است که تعداد نمونه‌های اندکی دارند. استفاده از راهکارهایی با هدف حل این محدودیت گام بعدی است که برای این پژوهش در نظر گرفته شده است. استفاده از دیگر روش‌ها در پیش‌بینی آلودگی هوای مقایسه نتایج حاصل از مدل مطرح شده با روش‌های دیگر نیز در دستور کار قرار دارد.

## ۶- منابع

خزاعی، ا، آل شیخ، ع.ا، کریمی، م، وحیدنیا، م.ح، ۲۰۱۳،

- Ghaemi, Z., Farnaghi, M. & Alimohammadi, A., 2016, **An Online Approach for Spatio-Temporal Prediction of Air Pollution in Tehran Using Support Vector Machine**, Journal of Geospatial Information Technology, 3(4): PP. 43–63.
- Gorai, A.K., Tuluri, F. & Tchounwou, P.B., 2014, **A GIS Based Approach for Assessing the Association between Air Pollution and Asthma in New York State, USA**, International Journal of Environmental Research and Public Health, 11(5), PP. 4845–4869.
- Güler, I. & Übeyli, E.D., 2005, **Adaptive Neuro-Fuzzy Inference System for Classification of EEG Signals Using Wavelet Coefficients**, Journal of Neuroscience Methods, 148(2), PP. 113–121.
- Jain, S. & Khare, M., 2010, **Adaptive Neuro-Fuzzy Modeling for Prediction of Ambient CO Concentration at Urban Intersections and Roadways**, Air Quality, Atmosphere & Health, 3(4), PP. 203–212.
- Jang, J.-S., 1992, **Self-Learning Fuzzy Controllers Based on Temporal Backpropagation**, IEEE Transactions on Neural Networks, 3(5), PP. 714–723.
- Jang, J.-S., 1993, **ANFIS: Adaptive-Network-Based Fuzzy Inference System**, IEEE Transactions on Systems, Man, and Cybernetics, 23(3), PP. 665–685.
- Kolehmainen, M., Martikainen, H., Hiltunen, T. & Ruuskanen, J., 2000, **Forecasting Air Quality Parameters Using Hybrid Neural Network Modelling**, Urban Air Quality: Measurement, Modelling and Management, Springer, PP. 277–286.
- Kumar, A. & Goyal, P., 2011, **Forecasting of Air Quality in Delhi Using Principal Component Regression Technique**, Atmospheric Pollution Research, 2(4), PP. 436–444.
- McKone, T.E. & Deshpande, A.W., 2005, **Can Fuzzy Logic Bring Complex Environmental Problems into Focus?**, ACS Publications.
- Mintz, D., 2012, **Technical Assistance Document for the Reporting of Daily Air Quality—the Air Quality Index (AQI)**, US Environmental Protection Agency, Office of Air Quality Planning and Standards.
- Morabito, F.C. & Versaci, M., 2003, **Fuzzy Neural Identification and Forecasting Techniques to Process Experimental Urban Air Pollution Data**, Neural Networks, 16(3), PP. 493–506.
- Mostafaeipour, A., Zarezade, M., Goudarzi, H., Rezaei-Shouroki, M. & Qolipour, M., 2017, **Investigating the Factors on Using the Solar Water Heaters for Dry Arid Regions: A Case Study**, Renewable and Sustainable Energy Reviews, 78, PP. 157–166.
- Moussiopoulos, N., Sahm, P. & Kessler, C., 1995, **Numerical Simulation of Photochemical Smog Formation in Athens, Greece—a Case Study**, Atmospheric Environment, 29(24), PP. 3619–3632.
- Nia, A.M., Alimohammadi, A., Habibi, R. & Shirzadi, M., 2015, **Spatial and Statistical Analysis of Leptospirosis in Guilan Province, Iran**, The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, 40(1), P. 497.
- Niska, H., Hiltunen, T., Karppinen, A., Ruuskanen, J. & Kolehmainen, M., 2004, **Evolving the Neural Network Model for Forecasting Air Pollution Time Series**, Engineering Applications of Artificial Intelligence, 17(2), PP. 159–167.
- Nunnari, G., 2000, **Simplified Fuzzy Modelling of Pollutant Time Series**, Neural Network World, 10(6), PP. 983–1000.
- Pérez, P., Trier, A. & Reyes, J., 2000, **Prediction of PM 2.5 Concentrations Several Hours in Advance Using Neural Networks in Santiago, Chile**, Atmospheric Environment, 34(8), PP. 1189–1196.
- Riahi-Madvar, H., Ayyoubzadeh, S.A., Khadangi, E. & Ebadzadeh, M.M., 2009, **An Expert System for Predicting Longitudinal Dispersion Coefficient in Natural Streams by Using ANFIS**, Expert Systems with Applications, 36(4), PP. 8589–8596.
- Robeson, S. & Steyn, D., 1990, **Evaluation and Comparison of Statistical Forecast Models for Daily Maximum Ozone Concentrations**, Atmospheric Environment, Part B, Urban Atmosphere, 24(2), PP. 303–312.
- Ross, T.J., 2009, **Fuzzy Logic with Engineering Applications**, John Wiley & Sons.
- Sahoo, M.M., Patra, K. & Khatua, K., 2015, **Inference of Water Quality Index Using ANFIA and PCA**, Aquatic Procedia, 4: PP. 1099–1106.
- Shahraiyni, H.T., Sodoudi, S., Kerschbaumer, A. & Cubasch, U., 2015, **A New Structure**

- Identification Scheme for ANFIS and its Application for the Simulation of Virtual Air Pollution Monitoring Stations in Urban Areas**, Engineering Applications of Artificial Intelligence, 41, PP. 175–182.
- Sindelar, R. & Babuska, R., 2004, **Input Selection for Nonlinear Regression Models**, IEEE Transactions on Fuzzy Systems, 12(5), PP. 688–696.
- Singh, K.P., Gupta, S. & Rai, P., 2013, **Identifying Pollution Sources and Predicting Urban Air Quality Using Ensemble Learning Methods**, Atmospheric Environment, 80, PP. 426–437.
- Statheropoulos, M., Vassiliadis, N. & Pappa, A., 1998, **Principal Component and Canonical Correlation Analysis for Examining Air Pollution and Meteorological Data**, Atmospheric Environment, 32(6), PP. 1087–1095.
- Taylan, O., 2017, **Modelling and Analysis of Ozone Concentration by Artificial Intelligent Techniques for Estimating Air Quality**, Atmospheric Environment, 150, PP. 356–365.
- Ul-Saufie, A.Z., Yahaya, A.Z., Ramli, N.A., Rosaida, N. & Hamid, H.A., 2013, **Future Daily PM 10 Concentrations Prediction by Combining Regression Models and Feedforward Backpropagation Models with Principle Component Analysis (PCA)**, Atmospheric Environment, 77, PP. 621–630.
- Williams, B., Onsman, A. & Brown, T., 2010, **Exploratory Factor Analysis: A Five-Step Guide for Novices**, Australasian Journal of Paramedicine, 8(3).
- Zhang, J., Wang, C.-m., Liu, L., Guo, H., Liu, G.-d., Li, Y.-w. & Deng, S.-h., 2014, **Investigation of Carbon Dioxide Emission in China by Primary Component Analysis**, Science of The Total Environment, 472, PP. 239–247.
- Zheng, Y., Liu, F. & Hsieh, H.-P., 2013, **U-Air: When Urban Air Quality Inference Meets Big Data**, Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, ACM.
- Ziomas, I.C., Melas, D., Zerefos, C.S., Bais, A.F. & Paliatsos, A.G., 1995, **Forecasting Peak Pollutant Levels from Meteorological Variables**, Atmospheric Environment, 29(24), PP. 3703–3711.