

پیش بینی روزانه غلظت کربن منوکسید با استفاده از مدل تلفیقی انتخاب پیشرو- عصبی

فازی براساس تحلیل پایداری جو؛ بررسی موردی: شهر تهران

خسرو اشرفی^۱، غلامعلی هشیاریپور^{۲*}، بابک نجار اعرابی^۳ و هما کشاورزی شیرازی^۴

^۱ استادیار، دانشکده محیط زیست، دانشگاه تهران، ایران

^۲ دانشجوی دکتری، موسسه ژئوفیزیک، دانشگاه هامبورگ، آلمان

^۳ دانشیار، گروه مهندسی برق و کامپیوتر، دانشکده فنی، دانشگاه تهران، ایران

^۴ استادیار، دانشکده محیط زیست، دانشگاه تهران، ایران

(دریافت: ۸۸۲/۱۶، پذیرش نهایی: ۹۰/۱/۱۱)

چکیده

امروزه، آلودگی هوای کلان‌شهرها به یک چالش زیست‌محیطی اساسی تبدیل شده است. در مورد شهر تهران، که ۹۰ درصد از وزن کل آلاینده‌های هوای آن از خودروها منتشر می‌شود، کربن منوکسید نسبت به بقیه آلاینده‌های هوا اهمیت بیشتری دارد، به طوری که بیش از ۷۵ درصد وزن آلاینده‌های این شهر را دربر می‌گیرد. با توجه به اینکه تحلیل پایداری لایه سطحی جو، درحکم شاخص وضعیت تلاطمی آن، بیشترین اثر را در پراکنش آلاینده‌های هوا دارد، می‌تواند در پیش‌بینی آلودگی هوا مورد توجه قرار گیرد. در این تحقیق به منظور تحلیل وضعیت پایداری جو نزدیک سطح زمین، دو نگرش مورد توجه قرار گرفته است: در نگرش اول سرعت باد، درحکم شاخص تلاطم مکانیکی و تابش خورشیدی درحکم شاخص تلاطم همرفتی منظور شده و در نگرش دوم، مقیاس سرعت اصطکاکی، به‌منزله شاخص تلاطم مکانیکی و گرادیان دما، به‌منزله شاخص تلاطم همرفتی مورد توجه قرار گرفته است. براساس این دو نگرش، دو مجموعه مدل عصبی- فازی به‌منظور پیش‌بینی غلظت روزانه کربن منوکسید در جو تهران توسعه داده شده‌اند که در هر مجموعه یک مدل بدون اعمال انتخاب ورودی و یک مدل با اعمال انتخاب ورودی در نظر گرفته شده است. انتخاب ورودی مدل‌ها با استفاده از روش انتخاب پیشرو صورت گرفته است تا تعداد ورودی‌های مدل تا حد امکان کاهش یابد. پس از مقایسه نتایج پیش‌بینی مدل‌ها، مشخص شد که اعمال روش انتخاب پیشرو با کاهش تعداد ورودی‌ها نه فقط حجم محاسبات را کاهش می‌دهد بلکه بر دقت مدل نیز می‌افزاید. درنهایت، مدل توسعه داده‌شده براساس گرادیان باد و گرادیان دما درحکم مدل برتر معرفی شده است.

واژه‌های کلیدی: عصبی-فازی، پایداری جو، انتخاب پیشرو، کربن منوکسی

Prediction of daily carbon monoxide concentration using hybrid FS-ANFIS model based on atmospheric stability analysis; case study: city of Tehran

Ashrafi, K.¹, Hoshyaripour, GH.², Nadjar Araabi, B.³ and Keshavarzi Shirazi, H.⁴

¹ Assistant Professor, Graduate Faculty of Environment, University of Tehran, Iran

² PhD student, Institute of Geophysics, University of Hamburg, Germany

³ Associate Professor, School of Electrical and Computer Engineering, College of Engineering, University of Tehran, Iran

⁴ Assistant Professor, Graduate Faculty of Environment, University of Tehran, Iran

(Received: 6 May 2009, Accepted: 31 Jan 2012)

Abstract

In big cities, air pollution has become a great environmental issue nowadays. In city of Tehran, 90% of air pollutants are generated from traffic, among which carbon monoxide (CO) is the most important one because it constitutes more than 75% by weight of total air pollutants. This study aims to predict daily CO concentration of the urban area of Tehran using a hybrid forward selection- ANFIS (adaptive neuro-fuzzy inference system)

model based on atmospheric stability analysis.

Atmospheric stability is the most important parameter affecting dilution of air pollutants. It plays a central role in the investigation of parameters that affect ambient pollutant concentrations. Therefore, it can be considered as an input parameter for developing air pollution prediction models. Although different methods are used for stability determination with varying degrees of complexity, most of them incorporate considerations of both mechanical and buoyant turbulence. In this study two aspects for atmospheric stability analysis are considered and thus, two models are developed.

ANFIS1: frictional wind velocity and temperature gradient are used for representing mechanical and buoyant turbulence, respectively. For predicting CO concentration at a certain time step (CO (t)), total candidates for inputs are: CO (t-1), u10(t), u10(t-1), rad(t), rad(t-1).

ANFIS2: wind velocity and solar radiation are considered as the indicators of mechanical and buoyant turbulence, respectively. For predicting CO concentration at a certain time step (CO(t)), there are 9 candidates for the inputs: CO (t-1), u10(t), u10(t-1), u24(t), u24(t-1), temp(t), temp (t-1), dtemp(t), dtemp(t-1).

Input selection is a crucial step in ANFIS implementation. This technique is not engineered to eliminate superfluous inputs. In the case of a high number of input variables, irrelevant, redundant, and noisy variables might be included in the data set, simultaneously; meaningful variables could be hidden. Moreover, high number of input variables may prevent ANFIS from finding the optimized models. Therefore, reducing input variables is recommended even though this causes some of the information to be omitted. In this research, input selection is carried out based on forward selection (FS) procedure. When the number of candidate covariates (N) is small, one can choose a prediction model by computing a reasonable criterion (e.g., RMSE, SSE, FPE or cross-validation error) for all possible subsets of the predictors. However, as N increases, the computational burden of this approach increases very quickly. This is one of the main reasons why step-by-step algorithms like forward selection are popular. In this approach, which is based on linear regression model, first step is ordering of the explanatory variables according to their correlation with the dependent variable (from the most to the least correlated variable). Then, the explanatory variable, which is best correlated with the dependent variable, is selected as the first input. All remained variables are then added one by one as the second input according to their correlation with the output and the variable which most significantly increases the correlation coefficient (R^2) is selected as the second input. This step is repeated $N-1$ times for evaluating the effect of each variable on model output. Finally, among N obtained subsets, the subset with optimum R^2 is selected as the model input subset. The optimum R^2 is integral to a set of variables after which adding new variable dose not significantly increase the R^2 .

FS is applied on the input sets of this study which reduces the inputs of the models to 5 and 4 for ANFIS1 and ANFIS2, respectively. In order to identify the effect of FS on modeling results, the complete input sets are considered. Thus, 4 models are defined: ANFIS1, ANFIS2, FS- ANFIS1 and FS-ANFIS2. The selected inputs are used for Neuro-fuzzy modeling approach. Neuro-fuzzy modeling refers to the method of applying various learning techniques developed in the neural network literature to fuzzy modeling or Fuzzy Inference System (FIS). A specific approach in neuro-fuzzy development is ANFIS (adaptive neuro-fuzzy inference system), which has shown significant results in modeling nonlinear functions. ANFIS uses a feed forward network to optimize parameters of a given FIS to perform well on a given task. The learning algorithm for ANFIS is a hybrid algorithm, which is combination of the gradient descent and least squares methods. The used FIS here is the Sugeno first-order fuzzy model with its equivalent ANFIS

architecture.

Results show that the forward selection reduces not only calculation burden but also the output error. FS-ANFIS models produce more accurate results with R^2 of 0.52 and 0.41 for FS-ANFIS1 and FS-ANFIS2, respectively. Moreover, although both models can satisfactorily predict trends in CO concentration level, FS-ANFIS2, which is based on temperature and wind speed gradients, is the superior model.

Key words: Neuro-fuzzy, Atmospheric stability, Forward selection, Carbon monoxide

۱ مقدمه

که دسترسی به آنها در بیشتر موارد با مشکلاتی همراه است، نیازی ندارند، نسبت به مدل‌های قطعی ساختار ساده‌تری نیز دارند.

روش‌های آماری متعددی برای پیش‌بینی غلظت آلاینده‌های هوا وجود دارد. از میان این روش‌ها تا به حال مدل‌های رگرسیون خطی و غیرخطی (نوری و همکاران، ۲۰۱۰، ۱۳۸۷؛ نوناری و همکاران، ۱۹۹۸)، شبکه‌های عصبی مصنوعی (نوری و همکاران، ۱۳۸۷؛ بزنانر و همکاران، ۱۹۹۳؛ فینزی و همکاران، ۱۹۹۸؛ گاردنر و همکاران، ۱۹۹۸؛ نانری و همکاران، ۱۹۹۸)، سامانه استنتاج فازی (پوکروفسکی و همکاران، ۲۰۰۲؛ گلورنک، ۲۰۰۲) و سامانه استنتاج تطبیقی عصبی-فازی (مورایتو و ورساچی، ۲۰۰۳؛ یلدریم و بایرامقلو، ۲۰۰۶) در پژوهش‌های مربوط به آلودگی هوا، به‌طور موفقیت‌آمیزی مورد استفاده قرار گرفته‌اند. یک مدل آماری که اخیراً توجه بسیاری را به خود معطوف کرده‌است، سامانه عصبی-فازی است. این مدل مزایای خاص خود را دارد که از آن جمله می‌توان به توانایی شبیه‌سازی سامانه‌های غیرخطی، دقت زیاد و زمان کمتر ساخت مدل و محاسبات آن اشاره کرد (عقیل و همکاران، ۲۰۰۷a؛ نایاک و همکاران، ۲۰۰۴). در روش عصبی-فازی، از ترکیب منطق فازی (زاده، ۱۹۶۵) و شبکه‌های عصبی استفاده می‌شود که در آن از سامانه استنتاج فازی برای مدل کردن پدیده، و از قابلیت یادگیری شبکه تطبیقی به‌منظور بهینه‌سازی پارامترهای آن استفاده می‌شود (یانگ،

امروزه مشکلات ناشی از آلودگی هوا در کلان‌شهرها به یک چالش زیست‌محیطی اساسی تبدیل شده است. این مشکل در مورد شهر تهران به دلیل حجم ترافیکی سنگین ناشی از ترابری، استفاده از خودروهای غیراستاندارد، احتراق ناقص سوخت‌های مورد استفاده خودروها و بی‌توجهی که طی سال‌های گذشته نسبت به آلودگی هوا در آن صورت گرفته، اهمیت ویژه‌ای دارد (نوری و همکاران، ۲۰۱۰ و ۱۳۸۷). پیش‌بینی غلظت روزانه آلاینده‌های هوا اولین گام اساسی در برنامه‌ریزی کاهش اثرات آنها است. بدین‌منظور تاکنون روش‌های زیادی برای پیش‌بینی غلظت آلاینده‌های هوا مطرح شده است که آنها را می‌توان به دو دسته قطعی و آماری تقسیم کرد. توسعه مدل‌های قطعی برای مدل‌سازی کیفی آلودگی هوا پیچیدگی‌های زیادی دارد و ایجاد روابط بین تولید و انتشار آلاینده کارچندان ساده‌ای نیست. این عامل باعث وابستگی زیاد این مدل‌ها به تحلیل دقیق انتشار و نیز هواشناسی شده است که به نوبه خود عدم قطعیت قابل‌توجهی دارند. روش‌های آماری با استفاده از داده‌های موجود هواشناسی و آلودگی و تحلیل ارتباط آماری بین آنها، راهکارهای ساده‌تری برای پیش‌بینی غلظت آلاینده‌ها به‌شمار می‌روند و تحقیقات صورت گرفته نیز در زمینه پیش‌بینی کوتاه‌مدت آلاینده‌های هوا با استفاده از روش‌های آماری، سودمندی این روش‌ها را به اثبات رسانده است (گیلبرت، ۱۹۸۷؛ زانتی، ۱۹۹۰). روش‌های آماری علاوه بر اینکه به اطلاعات انتشار و ضرایب انتشار،

انتخاب شده و سایر داده‌های دارای همبستگی با آن، از ورودی حذف شود تا علاوه بر بهینه‌سازی جواب‌های مدل، زمان اجرای آن را کاهش دهد. روش‌های متعددی به‌منظور پیش‌پردازش داده‌ها و یا انتخاب ورودی مدل پیشنهاد شده است که معروف‌ترین آنها عبارت‌اند از انتخاب پیشرو، حذف پسرو و آنالیز مولفه‌های اصلی (یانگ، ۱۹۹۳). در این تحقیق از روش انتخاب پیشرو استفاده شده که بر مبنای روش رگرسیون خطی استوار است.

در مورد کلان شهر تهران، تحقیقات قبلی بیانگر وجود همبستگی بین آلودگی هوا با الگوی فشار (علی‌جانی و صفوی، ۱۳۸۵)، مشخصه‌های هواشناسی (شرعی‌پور و بیدختی، ۱۳۸۴) و حرکات جوّی در مقیاس همدیدی (بیدختی و شرعی‌پور، ۱۳۸۸) است. پژوهش اشرفی و هشجاری‌پور (۲۰۰۸) نشان می‌دهد که ارتباط معنی‌داری بین پایداری و ناپایداری جوّ و غلظت آلاینده‌های هوا وجود دارد، به‌طوری‌که ارتباط آلودگی با پارامترهای مؤثر در پایداری جوّ درحکم مهم‌ترین عامل پراکنش آلاینده‌ها (Pollutant dispersion) را می‌توان به روش‌های آماری پیشرفته مانند عصبی-فازی مورد بررسی قرار داد. این مسئله در تحقیقات قبلی کمتر مورد توجه قرار گرفته است. بنابراین در این تحقیق با استفاده از مدل عصبی-فازی و تحلیل پایداری جوّ، مدلی مناسب به‌منظور پیش‌بینی روزانه غلظت کربن منوکسید در هوای شهر تهران عرضه می‌شود. بدین‌منظور، ابتدا با تحلیل نقش پایداری و ناپایداری جوّ در پراکنش آلاینده‌ها، پارامترهای پایداری مورد استفاده در مدل‌سازی تبیین می‌شود. در ادامه ساختار و قواعد حاکم بر مدل عصبی-فازی و معیارهای مورد استفاده در ارزیابی آن تشریح خواهد شد. سپس روش انتخاب پیشرو در انتخاب ورودی‌های مدل تبیین خواهد شد. در بخش بعد، پس از تشریح منطقه مورد بررسی و تحلیل کمی و کیفی

مرسوم‌ترین دیدگاه توسعه مدل عصبی-فازی، سامانه استنتاج تطبیقی عصبی-فازی (ANFIS, Adaptive Neuro-Fuzzy Inference System) است که نتایج خوبی در مدل‌سازی فرایندهای غیرخطی آشکار ساخته است (عقیل و همکاران، ۲۰۰۷b). مورابیتو و ورساچی (۲۰۰۳) از دستگاه عصبی-فازی برای پیش‌بینی غلظت آلاینده‌های شاخص در جنوب ایتالیا استفاده کردند. ورودی‌های دستگاه در این پژوهش شامل اطلاعات ترافیکی، آلودگی و هواشناسی بود. پوکروفسکی و همکاران (۲۰۰۲) برهم‌کنش آلاینده‌های ثانویه و پارامترهای هواشناسی را از طریق منطق فازی مورد تجزیه و تحلیل قرار دادند. یلدریم و بایرامقلو (۲۰۰۶) با استفاده از مدل تطبیقی عصبی-فازی، غلظت روزانه گوگرد دیوکسید و ذرات معلق را در یک شهر ساحلی در ترکیه پیش‌بینی کردند. در این پژوهش، دما، سرعت باد، فشار، رطوبت نسبی، تابش خورشیدی، بارش و آلودگی روز قبل به‌منزله ورودی در نظر گرفته شد که قابلیت پیش‌بینی با همبستگی ۸۰ و ۹۰ درصد را به ترتیب برای گوگرد دیوکسید و ذرات معلق نشان داد.

یکی از مهم‌ترین مسائل در توسعه مدل‌های آماری، انتخاب ورودی‌های مدل است که هدف آن عبارت از انتخاب حداقل تعداد ورودی به‌منظور دست‌یابی به بهترین نتایج است. به عبارت دیگر از میان همه ورودی‌های محتمل به یک مدل، بخشی انتخاب می‌شود که بیشترین تاثیر را در نتایج داشته باشد؛ زیرا بعضاً برخی از داده‌ها به دلیل وجود نوفه و یا سایر عوامل نه فقط اثر مستقیم چندانی بر خروجی مدل ندارند بلکه باعث کاهش اثر سایر داده‌ها نیز خواهند شد و این ممکن است به یک مدل‌سازی نامناسب منجر شود. درعین حال بخشی از داده‌ها ممکن است با یکدیگر همبستگی نشان دهند و اعمال همه آنها به مدل صرفاً به افزایش ابعاد و زمان اجرای مدل منجر شود. لذا بهتر است در برخورد با این‌گونه داده‌ها، موثرترین داده

تلاطم همرفتی با جریان همرفتی و نیز تحت تأثیر جغرافیای محلی به وجود می‌آید. همرفت وقتی رخ می‌دهد که هوا از پایین با سطح گرم زمین که اغلب پوشیده از ساختمان و یا پوشش‌های دیگر است، گرم شود. تلاطم مکانیکی از نیروی بُرشی حاصل از وزش باد بر سطح زمین ناشی می‌شود. در سطح زمین، سرعت باد صفر است و در فاصله گاه تا صدها متری زمین، به حداکثر خود می‌رسد. تلاطم مکانیکی با افزایش سرعت باد، افزایش می‌یابد و روی سطوح زبر بیشتر از سطوح هموار است (شنل و دی، ۲۰۰۰).

برخی از متداول‌ترین روش‌های تحلیل پایداری در تحقیقات پراکنش در جو عبارت‌اند از: طبقه‌بندی پاسکویل - گیفورد (PGM)، طبقه‌بندی پاسکویل - ترنر (PTM)، عدد ریچاردسون و طول مونین - ابوخوف (سینفلد و پن‌دیس، ۲۰۰۶؛ زانتی، ۱۹۹۰). PGM و PTM وضعیت پایداری جو را براساس سرعت باد درحکم شاخص تلاطم مکانیکی و تابش خورشیدی درحکم شاخص تلاطم همرفتی به صورت گروه‌های هفت‌گانه از بسیار پایدار تا بسیار ناپایدار به صورت کیفی بیان می‌کنند. درحالی‌که عدد ریچاردسون و طول مونین - ابوخوف، به ترتیب با استفاده از گرادیان و مقیاس سرعت باد اصطکاکی به منزله شاخص تلاطم مکانیکی و گرادیان و مقیاس دمای پتانسیل به منزله شاخص تلاطم همرفتی، وضعیت پایداری جو را به صورت کمی نشان می‌دهند. لذا با توجه به جدول ۱ که مقایسه روش‌های تحلیل پایداری پیش‌گفته را با یکدیگر نشان می‌دهد، متغیرهای هواشناسی تعیین‌کننده در تحلیل پایداری را می‌توان به دو صورت در نظر گرفت:

- ۱- مقیاس سرعت اصطکاکی، به منزله شاخص تلاطم مکانیکی و گرادیان دما، به منزله شاخص تلاطم همرفتی
- ۲- سرعت باد، درحکم شاخص تلاطم مکانیکی و تابش خورشیدی درحکم شاخص تلاطم همرفتی

داده‌های مورد استفاده، روش اعمال شده در تعیین ساختار و انتخاب ورودی‌های مدل عصبی - فازی بیان می‌شود. درنهایت، نتایج مدل‌سازی مورد بحث و بررسی قرار می‌گیرد و مدل بهینه تعیین می‌شود. شایان ذکر است که هدف از این تحقیق پیش‌بینی دقیق آلودگی هوا نیست بلکه هدف آن است تا با امکان‌سنجی به کارگیری پارامترهای موثر در تحلیل پایداری جو به منزله ورودی‌های مدل عصبی - فازی، مدل مناسبی برای پیش‌بینی روند روزانه آلودگی تدوین شود به طوری که بتوان در سامانه مدیریت شهری به صورت ابزاری برای پیش‌بینی روزهای وقوع اوج آلودگی آن را به کار برد.

۲ روش تحقیق

۲-۱ تحلیل پایداری لایه سطحی جو و نقش آن در پراکنش آلاینده‌های هوا

از میان پارامترهای هواشناسی گوناگون، پارامترهایی از قبیل سرعت و جهت باد افقی، پایداری جو، ارتفاع از سطح زمین، شدت وارونگی دمایی ارتفاع‌یافته و حرکت قائم جو در اثر سامانه‌های پرفشار و کم‌فشار بیشترین تأثیر را روی پدیده آلودگی هوا دارند (زانتی، ۱۹۹۰). در این بین، تأثیرگذارترین عامل در پراکنش آلاینده‌ها، پایداری جو است و به طور گسترده‌ای در تحقیقات پراکنش در جو با هدف تعیین وضعیت تلاطم و یا قابلیت‌های پراکنشی آن مورد استفاده قرار می‌گیرد (زانتی، ۱۹۹۰؛ موهان و سدیکی، ۱۹۹۸). می‌توان گفت پایداری برای بیان کیفی شتاب حرکت قائم یک بسته هوا در جو به کار می‌رود که اگر این شتاب مثبت باشد، جو ناپایدار، اگر صفر باشد، خنثی و اگر منفی باشد، پایدار است (موهان و سدیکی، ۱۹۹۸). روش‌های متفاوتی برای تحلیل پایداری جو وجود دارد که اغلب بر مبنای مقایسه اهمیت نسبی تلاطم همرفتی و مکانیکی در حرکات جو استوار هستند (موهان و سدیکی، ۱۹۹۸؛ اشرفی و هشیاری‌پور، ۲۰۰۸).

در این تحقیق از هر دو حالت به منزله بیانگر وضعیت پایداری جو استفاده می‌شود و نتایج مدل‌ها با یکدیگر مقایسه خواهند شد. در حالت اول، سرعت باد در دو ارتفاع ۱۰ و ۲۴ متری به منظور لحاظ کردن اثر گرادیان باد و دمای سطح زمین و تفاوت دما در ارتفاع ۸ متری به منظور لحاظ کردن اثر گرادیان دما، داده‌های موجود که در ایستگاه‌ها اندازه‌گیری می‌شود، مورد استفاده قرار می‌گیرد. در مورد حالت دوم نیز، سرعت باد و تابش خورشیدی در حکم پارامترهای هواشناسی در ایستگاه‌ها مستقیماً اندازه‌گیری می‌شوند و داده‌های مربوط به آنها موجود است.

۲-۲ دستگاه استنتاج عصبی - فازی

یکی از روش‌هایی که اخیراً، در آلودگی هوا به آن توجه شده، مدل‌سازی بر مبنای قواعد فازی است. منطق فازی و نظریه مجموعه‌های فازی را به منظور توصیف تفکر و استدلال بشری در یک چارچوب ریاضی به کار می‌برند. مدل‌هایی که بر مبنای قواعد فازی هستند، نتایج را به‌طور

کیفی شرح می‌دهند.

به مدل‌سازی فازی، دستگاه استنتاج فازی (FIS, Fuzzy inference system) اطلاق می‌شود. ساختمان اولیه FIS شامل سه مولفه است: الف) پایگاه قانون که شامل مجموعه‌ای از قوانین فازی است، ب) پایگاه داده که تابع‌های عضویت (MFs, Membership functions) مورد استفاده در قوانین فازی را تعریف می‌کند و ج) سازوکار استدلال که بر اساس قوانین، الگوی ورودی را به خروجی مربوط، مرتبط می‌سازد (یانگ، ۱۹۹۳).


FIS با استفاده از تعدادی قوانین اگر-آن‌گاه فازی، یک رابطه جزء به جزء غیرخطی را از فضای ورودی به فضای خروجی شرح می‌دهد. ترکیبات متفاوت تابع‌های عضویت متغیرهای ورودی و خروجی قوانین را به وجود می‌آورند و این قوانین یک ناحیه فازی را از فضای ورودی تعریف می‌کنند و در نهایت رابطه خروجی، خروجی مدل را تعیین می‌کند. کارایی FIS بستگی به برآورد پارامترهای آن دارد که شامل پارامترهای تابع‌های عضویت و تابع خروجی هر قانون است (یانگ، ۱۹۹۳).

جدول ۱. مقایسه روش‌های متفاوت تحلیل پایداری جو.

روش تحلیل پایداری	پاسکویل-گیفورد	پاسکویل-ترنر	عدد ریچاردسون*	طول مومین-ابوخوف**
نحوه محاسبه	بر اساس تابش خورشیدی و سرعت باد	بر اساس شاخص تابش خالص و سرعت باد	$Ri = \frac{g(\Delta\theta/\Delta z)}{T(d\bar{u}/dz)^2}$	$L = \frac{u_*^2 T}{kg\theta_*}$
بسیار ناپایدار	A	۱	$Ri < -0.04$	$-100 < L \leq 0$
ناپایدار	B	۲	$-0.04 < Ri < 0$	$-100 \leq L \leq -100$
نسبتاً ناپایدار	C	۳		
خشتی	D	۴	$Ri = 0$	$100 < L $
نسبتاً پایدار	E	۵	$0 < Ri < 0.25$	$10 \leq L \leq 100$
پایدار	F	۶		
بسیار پایدار	G	۷	$Ri > 0.25$	$0 < L < 10$

* در این رابطه، θ دمای پتانسیل، \bar{u} سرعت باد، T دما و g شتاب جاذبه است.

** در این رابطه، u_* مقیاس سرعت اصطکاکی، g شتاب جاذبه، T دمای هوا، k ثابت ون-کارمن و θ_* مقیاس دمای پتانسیل مجازی است.



شکل ۱. دستگاه استنتاج فازی سوگنو (سوگنو و یاسوکاوا، ۱۹۹۳).

که خروجی آن یک رابطه خطی است و پارامترهای آن را می‌توان با ترکیب روش‌های حداقل مربعات خطا و انتشار خطا به عقب، براساس کاهش گرادیان برآورد کرد.

شکل ۱ نمونه‌ای از دستگاه استنتاج فازی سوگنو مرتبه اول که دارای دو ورودی x, y و خروجی z است را نشان می‌دهد. برای FIS نشان داده شده، یک نمونه پایگاه قانون فازی شامل ۲ قانون زیر قابل طرح است:

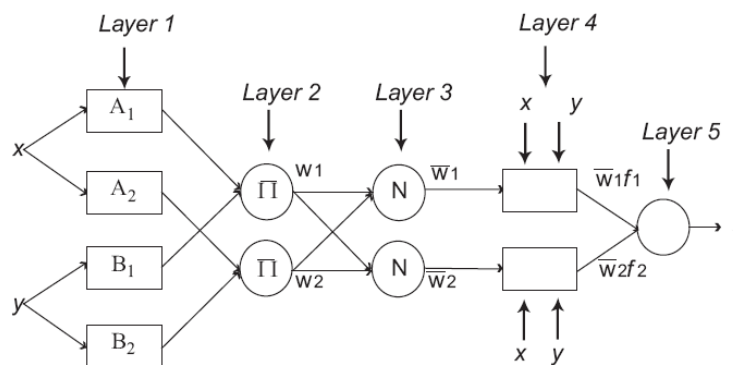
قانون اول: اگر x مساوی A_1 و y مساوی B_1 باشد، آن گاه p
 $f_1 = p_1 x + q_1 y + r_1$

قانون دوم: اگر x مساوی A_2 و y مساوی B_2 باشد، آن گاه
 $f_2 = p_2 x + q_2 y + r_2$

که در آن A_1, B_1, A_2, B_2 به ترتیب تابع‌های عضویت برای ورودی‌های x (هستند و $p_1, q_1, r_1, p_2, q_2, r_2$ نیز پارامترهای تابع‌های خروجی برای ۲ قانون تعریف شده است.

برای حل مشکل شناسایی پارامترها در یک FIS در مدل‌های عصبی-فازی از یک شبکه تطبیقی که حالت عمومی شبکه عصبی پیشرو چندلایه است، استفاده می‌شود. یک شبکه تطبیقی، یک ساختار پیشرو چندلایه است که رفتار کلی خروجی آن از مقدار یک مجموعه از پارامترهای قابل اصلاح تعیین می‌شود. با استفاده از این شبکه عصبی تطبیقی، مشکل اصلی استفاده از دستگاه استنتاج فازی (که همان به‌دست آوردن قواعد "اگر-آن‌گاه" فازی و بهینه‌سازی پارامترهای این مدل است) برطرف می‌شود (یانگ، ۱۹۹۳).

در این تحقیق از دستگاه استنتاج فازی-عصبی تطبیقی (ANFIS) که از جمله مدل‌های فازی-عصبی است، استفاده شده است. معمول‌ترین نوع دستگاه استنتاج فازی که قابلیت قرارگیری در یک شبکه تطبیقی را دارد، دستگاه فازی سوگنو (سوگنو و یاسوکاوا، ۱۹۹۳) است



شکل ۲. ساختار مدل ANFIS معادل دستگاه استنتاجی مورد بحث (یانگ، ۱۹۹۳).

که در آن، \bar{w} ، خروجی لایه ۳ و $\{p_i, q_i, r_i\}$ مجموعه پارامترهای تابع خطی خروجی نهمین قانون است. لایه ۵: تنها گره این لایه خروجی کلی ANFIS را به صورت زیر محاسبه می کند:

$$OP_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (7)$$

عملکرد اصلی دستگاه تطبیقی پیش گفته، بهینه سازی پارامترهای مدل است. یانگ و همکاران (۱۹۹۷) روش آموزش ترکیبی را برای مدل عصبی-فازی ابداع کردند که نسبت به روش معمول انتشار به عقب براساس کاهش گرادیان در محاسبه پارامترهای مدل، سریع تر و دقیق تر است. الگوریتم آموزش ترکیبی برای ANFIS از دو فاز متناوب زیر تشکیل شده است:

۱- کاهش گرادیان که که سیگنال های خطای ایجاد شده را از لایه خروجی به لایه ورودی برگشت می دهد. این فاز پارامترهای بخش مقدم مدل (تابع های عضویت) را تصحیح می کند.

۲- روش حداقل مربعات خطا^۸ که پارامترهای بخش تالی مدل (ضرایب رابطه خطی) را تصحیح می کند.

۳-۱ انتخاب پیشرو

یکی از مهم ترین مسئله ها در توسعه مدل های آماری مانند رگرسیون خطی، شبکه عصبی و ANFIS، پیش پردازش داده های ورودی به منظور انتخاب ورودی های مدل است. به عبارت دیگر از میان همه ورودی های محتمل به یک مدل، بخشی انتخاب می شود که بیشترین تاثیر را در نتایج داشته باشد زیرا بعضاً برخی از داده ها به دلیل وجود نوفه و یا سایر عوامل نه فقط اثر مستقیم چندانی بر خروجی مدل ندارند، بلکه باعث کاهش اثر سایر داده ها نیز خواهند شد؛ که این می تواند به یک مدل سازی نامناسب منجر شود. درعین حال بخشی از داده ها ممکن است با یکدیگر

معماری معمول ANFIS در شکل ۲ آورده شده است که در آن گره های هر لایه عملکرد ویژه ای دارند. کارکرد لایه های متفاوت ANFIS به شرح زیر است:

لایه ۱: هر گره در این لایه درجات عضویت از یک متغیر ورودی را تولید می کند. خروجی OP_i^1 با روابط زیر تعریف می شود:

$$OP_i^1 = \mu_{A_i}(x) \text{ for } i=1,2 \quad (1)$$

$$OP_i^1 = \mu_{B_i}(x) \text{ for } i=3,4 \quad (2)$$

که در آن، x (یا y) ورودی به گره مورد نظر، A_i (یا B_{i-2}) مجموعه فازی مرتبط با این گره است که از شکل تابع های عضویت این گره مشخص می شود و هر تابع مناسبی که پیوسته و به طور تکه ای مشتق پذیر باشد، مانند تابع های گاوسی، دوزنقه ای، مثلثی و مانند آن می تواند در حکم تابع عضویت مورد استفاده قرار گیرد. با فرض تابع عضویت گاوسی در حکم تابع عضویت، خروجی OP_i به صورت زیر قابل محاسبه است:

$$OP_i^1 = \mu_{A_i}(x) = \exp[-0.5\{(x-c_i)/\sigma_i\}^2] \quad (3)$$

که در آن، c_i و σ_i به ترتیب میانگین و انحراف معیار i امین تابع عضویت هستند.

لایه ۲: هر گره در این لایه در سیگنال ورودی ضرب و خروجی OP_i^2 که نشان دهنده قدرت تهییج یک قانون است، به صورت زیر محاسبه می شود:

$$OP_i^2 = w_i = \mu_{A_i}(x)\mu_{B_i}(y) \quad i=1,2 \quad (4)$$

لایه ۳: گره N ام این لایه که با N نام گذاری شده است، قدرت تهییج نرمال شده را محاسبه می کند:

$$OP_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i=1,2 \quad (5)$$

لایه ۴: گره i در این لایه مشارکت قانون N ام را به سمت خروجی مدل با استفاده از تابع گره زیر محاسبه می کند.

$$OP_i^4 = \bar{w}_i f_i = \bar{w}_i(p_i x + q_i y + r_i) \quad (6)$$

همکاران، ۲۰۰۶) و در اینجا به ذکر خلاصه‌ای از آن بسنده می‌شود. می‌توان ماتریس متغیرهای \mathbf{X} را به صورت $\mathbf{x} = \mathbf{vR}$ تجزیه کرد که در آن \mathbf{R} یک ماتریس $n \times n$ بالامثلی به صورت زیر است:

$$\mathbf{R} = \begin{bmatrix} 1 & r_{1,2} & \cdots & r_{1,n} \\ 0 & 1 & \ddots & \vdots \\ \vdots & \ddots & \ddots & r_{n-1,n} \\ 0 & \cdots & 0 & 1 \end{bmatrix} \quad (9)$$

و \mathbf{v} یک ماتریس $N \times n$ با ستون‌های متعامد \mathbf{v}_i و \mathbf{s} و $\mathbf{v}^T \mathbf{v} = \mathbf{s}$ به طوری است که $(\mathbf{v} = [\mathbf{v}_1 \dots \mathbf{v}_n])$ یک ورودی قطری به صورت $\mathbf{s}_i = \mathbf{v}_i^T \mathbf{v}_i$ است. چون فضای تحت پوشش \mathbf{s}_i و \mathbf{x}_i یکسان است پس می‌توان رابطه ۸ را به صورت زیر نوشت:

$$\mathbf{y} = \mathbf{vJ} + \mathbf{e} \quad (10)$$

که بردار \mathbf{J} با برآورده کردن رابطه مثلثی $\mathbf{r}\theta = \mathbf{J}$ جایگزین ماتریس پارامتر θ می‌شود. حل معادله ۱۰ از رابطه زیر به دست می‌آید:

$$\mathbf{J} = (\mathbf{v}^T \mathbf{v})^{-1} \mathbf{v}^T \mathbf{y} = \mathbf{s}^{-1} \mathbf{v}^T \mathbf{y} = \frac{\mathbf{v}_i^T \mathbf{y}}{\mathbf{v}_i^T \mathbf{v}_i} \quad (11)$$

with $i=1, \dots, n$

واریانس خروجی مدل از رابطه زیر محاسبه می‌شود:

$$\frac{1}{N} \mathbf{y}^T \mathbf{y} = \frac{1}{N} \sum_{i=1}^n \mathbf{J}_i^2 \mathbf{v}_i^T \mathbf{v}_i + \frac{1}{N} \mathbf{e}^T \mathbf{e} \quad (12)$$

ملاحظه می‌شود که عبارت $\frac{1}{N} \mathbf{J}_i^2 \mathbf{v}_i^T \mathbf{v}_i$ در معادله فوق به رگرسیون \mathbf{v}_i بستگی دارد. به عبارت دیگر متغیر \mathbf{v}_i وقتی در خروجی مدل اهمیت دارد که این عبارت مقدار بالایی داشته باشد. بنابراین، مقدار خطا \mathbf{e} با ورودی \mathbf{v}_i براساس نسبت کاهش خطای زیر کاهش می‌یابد:

$$err_i = \frac{\mathbf{J}_i^2 \mathbf{v}_i^T \mathbf{v}_i}{\mathbf{y}^T \mathbf{y}} \quad (13)$$

همبستگی نشان دهند و اعمال همه آنها به مدل صرفاً به افزایش ابعاد مدل و حجم محاسبات آن منجر شود. لذا بهتر است در برخورد با این گونه داده‌ها، موثرترین داده انتخاب شده و سایر داده‌های دارای همبستگی با آن از ورودی حذف شود تا علاوه بر بهینه‌سازی جواب‌های مدل، حجم محاسبات آن را کاهش دهد.

روش‌های متعددی به منظور پیش‌پردازش داده‌ها و یا انتخاب ورودی مدل پیشنهاد شده است که معروف‌ترین آنها عبارت‌اند از انتخاب پیشرو، حذف پسرو و آنالیز مولفه‌های اصلی. در این تحقیق از روش انتخاب پیشرو (FS, Forward selection) استفاده شده است. این روش بر مبنای رگرسیون خطی و حداقل مربعات متعامد استوار است که از رابطه ۸ پیروی می‌کند (چن و همکاران، ۱۹۸۹؛ وانگ و همکاران، ۲۰۰۶؛ خان و همکاران، ۲۰۰۷):

$$\begin{bmatrix} y(1) \\ y(2) \\ \vdots \\ y(N) \end{bmatrix} = \begin{bmatrix} x_1(1) & x_2(1) & \cdots & x_n(1) \\ x_1(2) & x_2(2) & \cdots & x_n(2) \\ \vdots & \vdots & \ddots & \vdots \\ x_1(N) & x_2(N) & \cdots & x_n(N) \end{bmatrix} \begin{bmatrix} \theta_1 \\ \theta_2 \\ \vdots \\ \theta_n \end{bmatrix} + \begin{bmatrix} e(1) \\ e(2) \\ \vdots \\ e(N) \end{bmatrix} \quad (8)$$

که در این رابطه، \mathbf{y} بردار پاسخ، \mathbf{X} ماتریس رگرسیون، θ ماتریس متغیرها و \mathbf{e} نشانگر خطا، n تعداد متغیرها و N تعداد مشاهدات است. روش حداقل مربعات متعامد (OLS) عبارت است از معامدسازی بردارهای مربوط به متغیرها به نحوی که با حذف همبستگی بین آنها بتوان اثر هر یک را به طور مجزا روی پاسخ مدل بررسی کرد. در این تحقیق از الگوریتم معامدسازی گرام-اشمیت استفاده شده است. جزئیات کاربرد این روش در انتخاب پیشرو در منابع علمی موجود است (چن و همکاران، ۲۰۰۴؛ وانگ و

منوکسید نسبت به بقیه آلاینده‌های هوا در شهر تهران اهمیت بیشتری دارد، به طوری که بیش از ۷۵ درصد وزن آلاینده‌های این شهر را در بر می‌گیرد (بیات، ۱۳۸۳). در شهر تهران هم اکنون ۱۱ ایستگاه سنجش آلودگی هوا وجود دارد که کار اندازه‌گیری غلظت آلاینده‌های شاخص هوا را عملی می‌سازند. در این تحقیق به منظور پیش‌بینی میانگین غلظت روزانه کربن منوکسید (CO) از داده‌های هواشناسی، شامل سرعت باد در ارتفاع‌های ۱۰ و ۲۴ متری (u10، u24)، تابش خورشیدی (rad)، دما (temp) و اختلاف دما در ارتفاع ۸ متری (dtemp) و داده‌های آلودگی شامل غلظت کربن منوکسید (CO) در ایستگاه مهرآباد واقع در غرب تهران (شکل ۳) در طول جغرافیایی ۵۱ درجه و ۱۹ دقیقه شرقی و عرض جغرافیایی ۳۵ درجه و ۴۱ دقیقه شمالی با ارتفاع ۱۱۹۰ متر از سطح دریا، ثبت شده در سال‌های ۱۳۸۴ و ۱۳۸۵ استفاده شده است. سری زمانی مربوط به میانگین غلظت روزانه این آلاینده در فصل‌های متفاوت در شکل ۴ آمده است. در این شکل می‌توان مشاهده کرد که در فصل‌های سرد که به دلیل کاهش تابش خورشیدی، جو اغلب در وضعیت پایدار به سر می‌برد، آلودگی نیز بیشتر است. تحلیل آماری متغیرهای مورد استفاده، در جدول ۲ آمده است. به علت خاموشی و مشکلات فنی دستگاه سنجش آلودگی هوا در برخی از روزهای سال، اطلاعات برخی از روزها در این سال‌ها در دسترس نبود و در مجموع بعد از مرتب کردن اطلاعات ثبت شده، از اطلاعات ۵۴۲ روز ثبت شده در این ایستگاه در طی این دو سال استفاده شده است.

۳-۳ معیارهای ارزیابی مدل‌ها

دو شاخص آماری متداول شامل ضریب همبستگی (R) و ریشه میانگین مربعات خطا ($RMSE$) برای ارزیابی عملکرد مدل‌ها به کار برده شد. این شاخص‌ها به صورت زیر محاسبه می‌شوند:

در عمل به منظور انتخاب یا حذف یک رگرسیون از ورودی‌های یک مدل، معیارهای متفاوتی را می‌توان به کار گرفت شود که متداولترین آنها عبارت‌اند از ضریب همبستگی (R) و ریشه میانگین مربعات خطا ($RMSE$)؛ اگر پس از وارد کردن یک متغیر به ورودی‌های مدل، بهبود معنی‌داری (مثلاً کاهش ۵٪ در $RMSE$ یا افزایش ۵٪ در R^2) در نتایج مدل‌سازی رخ دهد، آن متغیر در حکم ورودی جدید انتخاب و در غیر این صورت حذف می‌شود (چن و همکاران، ۱۹۸۹؛ خان و همکاران، ۲۰۰۷).

۳-۲ منطقه تحقیقاتی و داده‌های مسئله

کلان‌شهر تهران در حد فاصل طول جغرافیایی ۵۱ درجه و ۲ دقیقه شرقی و ۵۱ درجه و ۳۶ دقیقه شرقی به طول تقریبی ۵۰ کیلومتر و عرض جغرافیایی ۳۵ درجه و ۳۴ دقیقه شمالی تا ۳۵ درجه و ۵۰ دقیقه شمالی به عرض تقریبی ۳۰ کیلومتر واقع شده است. تهران از شمال به شمیران با ارتفاع ۱۷۰۰ متر از سطح دریا، از سمت جنوب به شهرری با ارتفاع ۱۰۶۰ متر از سطح دریا، از سمت شرق به دماوند با ارتفاع ۱۹۶۰ متر از سطح دریا و بالاخره از سمت غرب به کرج با ارتفاع ۱۳۲۰ متر از سطح دریا محدود شده است. در عین حال، این شهر دارای وسعت زیاد در حدود ۵۷۰ کیلومتر مربع است. این عوامل باعث بروز شرایط آب و هوایی متنوعی در آن شده است. شمال تهران به دلیل نزدیکی به رشته کوه‌های البرز دارای شرایط آب و هوایی سردتری نسبت به جنوب آن که در حاشیه کویر مرکزی قرار دارد است. جمعیت این شهر نیز مطابق با آخرین آمارگیری حدود ۸ میلیون نفر برآورد شده است (بختیاری، ۱۳۸۵؛ نوری و همکاران، ۱۳۸۷). نتایج به دست آمده از تحقیقی در مورد آلاینده‌های شهر تهران، بیانگر این واقعیت است که ۹۰ درصد از وزن کل آلاینده‌های هوای شهر تهران از خودروها منتشر می‌شود و ۱۰ درصد دیگر مربوط به منابع ثابت است (بیات، ۱۳۸۳). کربن

زیر خلاصه کرد:

- گام ۱- تعیین ضریب همبستگی متغیر پاسخ با تک‌تک متغیرهای ورودی
- گام ۲- انتخاب متغیر ورودی دارای بیشترین ضریب همبستگی در حکم اولین ورودی
- گام ۳- وارد کردن یک متغیر جدید به مدل و بررسی خطای مدل‌سازی (RMSE)
- گام ۴- اگر خطای مدل جدید نسبت به خطای مدل قبلی کاهش قابل توجه داشته باشد (مثلاً بیش از ۵٪) متغیر ورودی جدید انتخاب و در غیر این صورت حذف می‌شود.

- گام ۵- اگر متغیری باقی مانده است، بازگشت به گام ۳ و در غیر این صورت، پایان.
- شایان ذکر است همه ورودی‌ها برای اعمال انتخاب پیشرو بایستی استانداردسازی شوند، به نحوی که ابعاد همه متغیرها به بازه [۱-] منتقل شود. رابطه زیر برای استانداردسازی مورد استفاده قرار می‌گیرد (چن و همکاران، ۱۹۸۹):

$$x_s = \frac{2 \times (x - x_{\min})}{x_{\max} - x_{\min}} - 2 \quad (16)$$

از بین متغیرهای موجود، بیشترین همبستگی مربوط به CO(t-1) با R=0.69 است و این متغیر در حکم اولین ورودی انتخاب می‌شود. برای سایر متغیرها، با وارد کردن تک‌تک آنها به مدل و بررسی RMSE نتایج، نقطه کمینه آن در حکم تعداد ورودی بهینه انتخاب می‌شود. سپس متغیر بعدی به متغیرهای قبلی افزوده می‌شود و کار مانند عملیات قبلی ادامه می‌یابد. با اعمال روش پیش‌گفته روی ورودی‌های دو مدل ANFIS1 و ANFIS2 دو مدل ترکیبی جدید با نام‌های FS-ANFIS1 و FS-ANFIS2 ایجاد می‌شود. جدول‌های ۳ و ۴ نتایج عملیات انتخاب پیشرو صورت گرفته را به ترتیب برای مدل‌های FS-

$$R = \frac{\sum_{i=1}^n (C_i^o - \bar{C}^o)(C_i^e - \bar{C}^e)}{\left[\sqrt{\sum_{i=1}^n (C_i^o - \bar{C}^o)^2} \right] \left[\sqrt{\sum_{i=1}^n (C_i^e - \bar{C}^e)^2} \right]} \quad (14)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (C_i^o - C_i^e)^2} \quad (15)$$

که در این روابط C_i^o و C_i^e به ترتیب مقادیر مشاهداتی و خروجی غلظت آلاینده در لحظه، \bar{C}^o و \bar{C}^e به ترتیب میانگین مقادیر مشاهداتی و خروجی غلظت آلاینده و n تعداد داده‌های مورد استفاده است.

۴ نتایج و بحث

۴-۱ انتخاب ورودی‌های مدل

در اولین گام، به منظور تحلیل اثر انتخاب پیشرو در نتایج مدل‌سازی، دو مدل پایه با استفاده از کلیه ورودی‌های موجود توسعه داده می‌شود. ورودی‌های دو مدل پیش‌گفته به منظور پیش‌بینی CO در لحظه t به شرح زیر هستند:

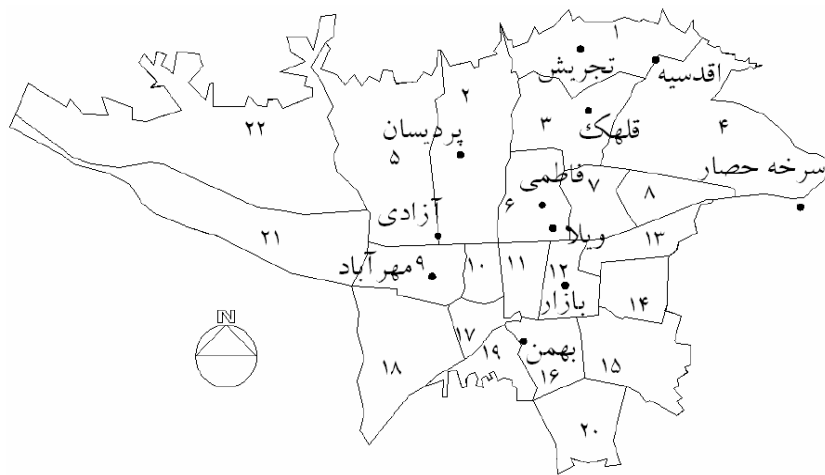
- ANFIS1: بر مبنای گرادیان باد و گرادیان دما دارای ۹ ورودی شامل: $CO(t-1)$, $u10(t)$, $u10(t-1)$, $u24(t)$, $u24(t-1)$, $temp(t)$, $temp(t-1)$, $dtemp(t)$, $dtemp(t-1)$
- ANFIS2: بر مبنای سرعت باد و تابش خورشیدی دارای ۵ ورودی شامل: $CO(t-1)$, $u10(t)$, $u10(t-1)$, $rad(t)$, $rad(t-1)$

در این تحقیق، در انتخاب ورودی‌های مدل، از روش انتخاب پیشرو استفاده شده است. همان‌گونه که ذکر شد، در این روش ابتدا متغیری که بیشترین ضریب همبستگی (R) را با خروجی موردنظر دارد، در حکم اولین ورودی در نظر گرفته می‌شود. سپس متغیرها یکی‌یکی وارد مدل می‌شوند و در صورتی که بتوانند نتایج مدل را بهبود بخشند و یا به عبارت دیگر RMSE را کاهش دهند، انتخاب و در غیر این صورت حذف می‌شوند (وانگ و همکاران، ۲۰۰۶؛ خان و همکاران، ۲۰۰۷). فرایند انتخاب پیشرو صورت گرفته در این تحقیق را می‌توان به صورت


• ANFIS1 و FS-ANFIS2 نشان می‌دهند. مشاهده می‌شود که به ازای افزودن متغیر جدید به ورودی، خطا (RMSE) کاهش می‌یابد تا جایی که تغییر در خطا ناچیز شود. بدین ترتیب ورودی‌های دو مدل پیش‌گفته به منظور پیش‌بینی CO در لحظه t به شرح زیر انتخاب می‌شوند:

• FS-ANFIS1 دارای ۵ ورودی شامل $CO(t-1)$, $u10(t)$, $u10(t-1)$, $u24(t)$, $temp(t)$, $dtemp(t-1)$, $dtemp(t)$

• FS-ANFIS2 دارای ۴ ورودی شامل $CO(t-1)$, $u10(t)$, $u10(t-1)$, $rad(t)$, نکته قابل توجه در اینجا حذف $u10$ از داده‌های ورودی مدل FS-ANFIS1 است. علت این مسئله آن است که در فرایند انتخاب پیشرو، از بین داده‌هایی که دارای همبستگی هستند معمولاً یکی از آنها حذف می‌شود و در اینجا همبستگی $u10$ با $u24$ باعث حذف $u10$ از داده‌های ورودی مدل ۱ شده است.



شکل ۳. ایستگاه‌های سنجش آلودگی هوای شهر تهران.



شکل ۴. سری زمانی مربوط به میانگین غلظت روزانه CO در فصل‌های متفاوت سال.

جدول ۲. تحلیل آماری متغیرهای مورد استفاده مربوط به سال‌های ۱۳۸۴ و ۱۳۸۵.

مشخصه	u10	u24	temp	dtemp	rad	CO کل	CO بهار	CO تابستان	CO پاییز	CO زمستان
واحد	m/s	m/s	°C	°C	kW/m ²	ppm	ppm	ppm	ppm	ppm
میانگین	۲/۶۹	۳/۸۵	۱۹/۳۶	۰/۰۲۳	۰/۲۳	۴/۳۹	۲/۹۷	۴/۴۱	۵/۹۹	۴/۰۹
بیشینه	۸/۱۶	۱۰/۰۵	۳۵/۷۹	۰/۷۶	۰/۳۷	۱۸/۴۰	۹/۹۵	۱۲/۳۲	۱۸/۴۰	۱۴/۳۸
کمینه	۰/۰۰	۱/۳۹	-۵/۰۰	-۰/۵۱	۰/۰۰۵	۰/۷۲	۰/۷۲	۰/۸۸	۱/۰۸	۰/۹۵
انحراف معیار	۱/۳۱	۱/۳۲	۹/۴۶	۰/۲۴	۰/۰۹	۲/۵۸	۱/۵۲	۲/۰۱	۳/۰۳	۲/۴۸

جدول ۳. نتایج عملیات انتخاب پیشرو برای مدل FS-ANFIS1.

مجموعه متغیرهای ورودی	RMSE
CO(t-1)	۰/۳۷۷۴
CO(t-1), u24(t)	۰/۳۷۲۳
CO(t-1), u24(t), temp(t)	۰/۳۶۴۵
CO(t-1), u24(t), temp(t), dtemp(t)	۰/۳۵۰۱
CO(t-1), u24(t), temp(t), dtemp(t), dtemp(t-1)	۰/۳۴۵۱*
CO(t-1), u24(t), temp(t), dtemp(t), dtemp(t-1), u24(t-1)	۰/۳۴۸۲
CO(t-1), u24(t), temp(t), dtemp(t), dtemp(t-1), u24(t-1), temp(t-1)	۰/۳۵۱۸
CO(t-1), u24(t), temp(t), dtemp(t), dtemp(t-1), u24(t-1), temp(t-1), u10(t)	۰/۳۵۸۰
CO(t-1), u24(t), temp(t), dtemp(t), dtemp(t-1), u24(t-1), temp(t-1), u10(t), u10(t-1)	۰/۳۵۷۶

* کمینه مقدار RMSE است که متغیرهای نظیر آن در حکم مجموعه ورودی بهینه مدل در نظر گرفته می‌شود.

جدول ۴. نتایج عملیات انتخاب پیشرو برای مدل FS-ANFIS2.

مجموعه متغیرهای ورودی	RMSE
CO(t-1)	۰/۳۷۷۴
CO(t-1), rad(t)	۰/۳۶۹۹
CO(t-1), rad(t), u10(t)	۰/۳۶۱۴
CO(t-1), rad(t), u10(t), u10(t-1)	۰/۳۵۴۲*
CO(t-1), rad(t), u10(t), u10(t-1), rad(t-1)	۰/۳۵۹۳

* کمینه مقدار RMSE است که متغیرهای نظیر آن در حکم مجموعه ورودی بهینه مدل در نظر گرفته می‌شوند.

۴-۲ تعیین ساختار مدل عصبی-فازی

در ANFIS در لایه اول، مقادیر هر متغیر ورودی باید به چند رده برای ساختن قوانین مربوط دسته‌بندی شود که قوانین فازی از ترکیب ۲ یا تعداد بیشتری تابع‌های عضویت در لایه دوم ساخته می‌شوند. برای رده‌بندی داده‌های ورودی و ساخت قوانین روش‌های متعددی پیشنهاد شده است که رایج‌ترین آنها عبارت‌اند از افراز شبکه‌ای (یانگ و سان، ۱۹۹۵) و خوشه‌بندی فازی کاهشی (چیو، ۱۹۹۴). زمانی که تعداد متغیرهای مورد استفاده کم است، افراز شبکه‌ای روش مناسبی برای رده‌بندی داده‌ها است ولی در این تحقیق به علت وجود تعداد زیاد متغیر ورودی و نیاز به وجود تعداد قابل توجهی تابع عضویت برای هر کدام نمی‌توان از این روش استفاده کرد. برای مثال اگر ۴ متغیر ورودی و برای هر متغیر ۴ تابع عضویت داشته باشیم تعداد قوانین برابر ۴^۴ خواهد بود که برآورد پارامترهای این مدل با توجه به تعداد داده‌های موجود و مشکلات محاسباتی میسر نیست. لذا در این تحقیق از روش خوشه‌بندی فازی کاهشی برای ساخت FIS استفاده شد. این روش بر مبنای اندازه‌گیری تراکم نقاط موجود در فضای متغیرهای مورد استفاده صورت می‌گیرد. به این منظور فضای متغیرهای موجود استانداردسازی می‌شود، به نحوی که ابعاد همه متغیرها به بازه [۱-۰] منتقل شود. در ابتدا هر یک از نقاط در حکم نقطه‌ای که پتانسیل مرکزیت یک خوشه را دارد در نظر گرفته می‌شود، سپس شاخص تراکم (D_i) نقاط موجود در اطراف نقطه x_i طبق رابطه زیر محاسبه می‌شود:

$$D_i = \sum_{j=1}^n \exp\left(-\frac{\|x_i - x_j\|^2}{(r_a/2)^2}\right) \quad (17)$$

که در آن، r_a یا شعاع خوشه، یک عدد مثبت ثابت در بازه [۱-۰] است که هرچه مقدار آن کمتر باشد، تعداد خوشه‌ها بیشتر می‌شود و برعکس. اگر یک نقطه دارای

تعداد زیادی نقاط همسایگی باشد، شاخص تراکم زیادی خواهد داشت. پس از محاسبه شاخص تراکم برای هر نقطه، نقطه‌ای که دارای بالاترین شاخص تراکم است در حکم مرکز اولین خوشه انتخاب می‌شود. برای تعیین خوشه‌های بعدی، اگر نقطه x_{C1} با شاخص تراکم D_{C1} در حکم مرکز خوشه انتخاب شده باشد، شاخص تراکم هر یک از نقاط باقی‌مانده برای انتخاب مرکز خوشه بعدی طبق رابطه زیر تصحیح می‌شود (یاگر و فیلف، ۱۹۹۴):

$$D_i^{new} = D_i - D_{C1} \exp\left(-\frac{\|x_i - x_{C1}\|^2}{(r_b/2)^2}\right) \quad (18)$$


که در آن، r_b یک عدد مثبت ثابت است که به طور معمول ۱/۵ برابر r_a در نظر گرفته می‌شود. برای چهار مدل موردنظر در این تحقیق، با استفاده از تابع‌های عضویت گاوسی، مقدار مناسب r_a به روش سعی و خطا تعیین شد. به این منظور، با توجه به تعداد زیاد ورودی و لزوم اجتناب از تعداد زیاد خوشه، عددهای ۰/۱ تا ۰/۹ با افزایش ۰/۰۵ مورد استفاده قرار گرفت و در پایان مقدار مناسب r_a برای هر مدل تعیین شد. مقدار مناسب r_a برای مدل ANFIS1 برابر ۰/۵۱ (۶ خوشه)، در مدل ANFIS2 برابر ۰/۴۷ (۵ خوشه)، در مدل FS-ANFIS1 برابر ۰/۳۹ (۵ خوشه) و در مدل FS-ANFIS2 برابر ۰/۴۳ (۴ خوشه) به دست آمد. همچنین مرکز خوشه‌های ساخته شده و شعاع اثر هر یک نیز مشخص شد. سپس با استفاده از آنها پارامترهای تابع‌های عضویت هر متغیر ورودی مشخص می‌شود و از ترکیب تابع‌های عضویت متناظر متغیرهای ورودی و ارتباط آنها با متغیر خروجی با یک رابطه خطی، قوانین تعریف می‌شوند. پس از آن پارامترهای مدل (ضرایب رابطه خطی خروجی هر قانون و پارامترهای تابع‌های عضویت) با قرار گرفتن دستگاه استنتاج در بطن یک شبکه تطبیقی بهینه می‌شوند. تعداد تکرار الگوریتم ترکیبی برای تصحیح پارامترهای مدل

برابر ۳۰ و خطای هدف برابر 10^{-4} قرار داده شد.

۳-۴ ارزیابی مدل‌های توسعه داده شده

بررسی نتایج توسعه مدل‌های ایجاد شده (جدول ۴ و ۵) نشان می‌دهد که به‌طور کلی اعمال انتخاب پیشرو نه فقط زمان محاسبات را کاهش می‌دهد بلکه دقت پیش‌بینی را نیز افزایش می‌دهد. جدول ۴ ارزیابی نتایج مراحل آموزش و آزمون مدل‌های ANFIS1 و FS-ANFIS1 را نشان می‌دهد. ملاحظه می‌شود مدل FS-ANFIS1 در مرحله آزمون خطای کمتری داشته و همبستگی نتایج پیش‌بینی آن با مقادیر مشاهده شده بیشتر است. نتایج مشابهی نیز برای مدل FS-ANFIS2 از جدول ۵ قابل استنباط است. می‌توان گفت انتخاب ورودی به روش انتخاب پیشرو خطای پیش‌بینی را به‌طور قابل‌توجهی کاهش می‌دهد. بنابراین، مدل‌های ترکیبی FS-ANFIS1 و FS-ANFIS2 در حکم مدل‌های مناسب‌تر انتخاب می‌شوند و مورد بررسی بیشتری قرار می‌گیرند. در شکل‌های ۶ و ۷، که در آنها به‌ترتیب سری زمانی مربوط به آلودگی مشاهده شده و پیش‌بینی شده و نیز مقایسه آلودگی مشاهده شده و پیش‌بینی شده با مدل FS-ANFIS1 نشان داده شده است، ملاحظه می‌شود که روند کلی آلودگی شامل نقاط بیشینه


و کمینه به‌طور قابل‌قبولی پیش‌بینی شده است. درعین حال شکل‌های ۸ و ۹ نیز نتایج آلودگی مشاهده شده و پیش‌بینی شده نسبتاً مشابهی را برای مدل FS-ANFIS2 نشان می‌دهند. بنابراین به‌طور کلی می‌توان گفت مدل‌های ترکیبی براساس گرادیان باد و گرادیان دما (FS-ANFIS1) و نیز براساس سرعت باد و تابش خورشیدی (FS-ANFIS2) به‌نحو مناسبی روند سری زمانی مربوط به میانگین غلظت روزانه کربن منوکسید را پیش‌بینی می‌کنند. با این تفاوت که ضریب همبستگی (R^2) نتایج مرحله آزمون برای مدل FS-ANFIS1 مناسب‌تر است. هرچند این موضوع با توجه به معیار ریشه میانگین مربعات خطا (RMSE) نیز قابل مشاهده است ولی تفاوت خطا چندان چشمگیر نیست. بنابراین، با توجه به ضریب همبستگی (R^2)، مدل برتر در این تحقیق، مدل FS-ANFIS1 براساس گرادیان باد و گرادیان دما است. این مدل را می‌تواند به خوبی در پیش‌بینی کوتاه‌مدت آلودگی هوا مورد استفاده قرار داد ولی در مورد پیش‌بینی‌های بلندمدت به بررسی‌های بیشتری نیاز است. چرا که به‌طور کلی مدل‌های آماری نسبت به افزایش مقیاس زمانی حساسیت بیشتری دارند. به‌عبارت‌دیگر، با افزایش مقیاس زمانی، دقت مدل کاهش می‌یابد.



شکل ۶. سری زمانی آلودگی مشاهده شده و پیش‌بینی شده با مدل FS-ANFIS1.

جدول ۴. نتایج مراحل آموزش و آزمون مدل‌های ANFIS1 و FS-ANFIS1.


مرحله آزمون	مرحله آموزش	معیار ارزیابی	مدل مورد بررسی
۰/۳۵	۰/۴۱	R^2	ANFIS1
۰/۴۶	۰/۳۹	RMSE	
۰/۵۲	۰/۵۸	R^2	FS-ANFIS1
۰/۲۷	۰/۲۴	RMSE	




شکل ۷. آلودگی مشاهده شده در برابر آلودگی پیش‌بینی شده با مدل FS-ANFIS1.

جدول ۵. نتایج مراحل آموزش و آزمون مدل‌های ANFIS2 و FS-ANFIS2.

مرحله آزمون	مرحله آموزش	معیار ارزیابی	مدل مورد بررسی
۰/۳۴	۰/۳۷	R^2	ANFIS2
۰/۴۹	۰/۴۳	RMSE	
۰/۴۱	۰/۴۷	R^2	FS-ANFIS2
۰/۲۸	۰/۲۷	RMSE	



شکل ۸. سری زمانی آلودگی مشاهده شده و پیش‌بینی شده با مدل FS-ANFIS2.



شکل ۹. آلودگی مشاهده شده در برابر آلودگی پیش‌بینی شده با مدل FS-ANFIS2.

۵ نتیجه‌گیری

این دو نگرش، دو مدل عصبی-فازی به‌منظور پیش‌بینی غلظت روزانه کربن منوکسید در جو تهران به‌ترتیب با ۹ ورودی و ۵ ورودی با نام‌های ANFIS1 و ANFIS2 توسعه داده شده است. در مرحله بعدی، انتخاب ورودی مدل‌ها با استفاده از روش انتخاب پیشرو صورت گرفت تا تعداد ورودی‌ها در حد امکان کاهش یابد. با استفاده از این روش، که بر مبنای رگرسیون خطی استوار است و از بین پارامترهای موجود، موثرترین آنها در مدل پیش‌بینی خطی را درحکم ورودی انتخاب می‌کند، برای مدل اول از میان ۹ ورودی، ۵ عدد (FS-ANFIS1) و برای مدل دوم از میان ۵ ورودی ۴ عدد (FS-ANFIS2) انتخاب شد. پس از توسعه مدل‌ها و مقایسه نتایج پیش‌بینی آنها، مشخص شد که به‌طور کلی اعمال انتخاب پیشرو نه تنها زمان محاسبات را کاهش می‌دهد بلکه دقت پیش‌بینی را نیز افزایش می‌دهد و بنابراین دو مدل ترکیبی با FS درحکم مدل‌های برتر معرفی شدند. درعین حال مشاهده شد که علی‌رغم اینکه هر دو مدل به نحو رضایت‌بخشی روند تغییرات غلظت روزانه کربن منوکسید را پیش‌بینی می‌کنند، مدل ترکیبی براساس گرادیان باد و گرادیان دما (FS-ANFIS1) درحکم مدل برتر شناخته می‌شود.

با توجه به اهمیت کربن منوکسید در جو شهر تهران، که بیش از ۷۵ درصد وزن آلاینده‌های هوای این شهر را شامل می‌شود، در این تحقیق، پیش‌بینی غلظت روزانه این آلاینده با استفاده از مدل ترکیبی انتخاب پیشرو با دستگاه استنتاج تطبیقی عصبی-فازی براساس تحلیل پایداری جو مورد بررسی قرار گرفت. با توجه به اینکه تحلیل پایداری جو، درحکم شاخص وضعیت تلاطمی آن، بیشترین اثر را در پراکنش آلاینده‌های هوا دارد می‌تواند در پیش‌بینی آلودگی هوا مورد توجه قرار گیرد. در تحقیقات قبلی نیز همبستگی آماری آلودگی هوای تهران با مشخصه‌های هواشناسی نظیر وارونگی دمایی و سرعت باد و نیز حرکات جوی در مقیاس همدیدی معنادار ارزیابی شده است (بیدختی و شرعی‌پور، ۱۳۸۸). به‌منظور تحلیل وضعیت پایداری جو دو نگرش مورد توجه قرار گرفت: در نگرش اول سرعت باد اصطکاک‌اکتی، درحکم شاخص تلاطم مکانیکی و گرادیان دما، درحکم شاخص تلاطم همرفتی منظور شده و در نگرش دوم، سرعت باد، به‌منزله شاخص تلاطم مکانیکی و تابش خورشیدی درحکم شاخص تلاطم همرفتی مورد توجه قرار گرفته‌اند. بر ساس

- Conference of Environmental Science and Engineering, Venice, Italy, 186-191.
- Boznar, M., Lesjak, M., and Mlakar, P., 1993, A neural network-based method for short-term predictions of ambient SO₂ concentrations in highly polluted industrial areas of complex terrain, *Atmospheric Environment*, **27B** (2), 221-230.
- Chen, S., Billings, S. A., and Luo, W., 2004, Orthogonal least squares methods and their application to nonlinear system identification, *International Journal of Control*, **50**, 1873-1896.
- Chiu, S. L., 1994, Fuzzy model identification based on cluster estimation, *Journal of Intelligent and Fuzzy Systems*, **2**(3), 267-278.
- Finzi, G., Volta, M., Nucifora, A., and Nunnari, G., 1998, Real-time ozone episode forecast: a comparison between neural network and grey-box models. In: *Proceedings of the International ICSC/ IFAC Symposium on Neural Computation—NC'98*, Vienna.
- Gardner, M. W., and Dorling, S. R., 1998, Artificial neural networks (the multilayer perceptron) a review of applications in the atmospheric sciences. *Atmospheric Environment*, **32** (14/15), 2627-2636.
- Gilbert, R. O., 1987, *Statistical methods for environmental pollution monitoring*, Van Nostrand Reinhold, New York.
- Glorennec, P. Y., 2002, Forecasting ozone peaks using self-organizing maps and fuzzy logic, *Proceeding of Conference on air pollution modelling and simulation No2*, Champs sur Marne, FRANCE, 544-550.
- Jang, J. S. R., 1993, ANFIS: adaptive-network-based fuzzy inference system, *IEEE Trans. Syst. Manag. Cyber*, **23**, 665-685.
- Jang, J. S. R., and Sun, C. T., 1995, Neuro-fuzzy modeling and control, *Proceedings of the IEEE*, **83**, 378-406.
- Jang, J. S. R., Sun, C. T., and Mizutani, E., 1997, *Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence*, New Jersey: Prentice-Hall.
- Khan, J. A., Aelst, S. V., and Zamar, R. H., 2007, Building a robust linear model with forward selection and stepwise procedures, *Computational Statistics and Data Analysis*, **52**, 239-248.
- Ljung, L., 1999, *System identification: theory for the user*, Prentice Hall; 2nd edition.
- Morabito, F. C., and Versaci, M., 2003, Fuzzy neural identification and forecasting
- منابع
- بختیاری، س.، ۱۳۸۵، اطلس کامل تهران، موسسه جغرافیایی و کارتوگرافی گیتاشناسی، تهران.
- بیات، ر.، ۱۳۸۳، سهم‌بندی منابع تولید آلودگی هوای شهر تهران، پایان‌نامه کارشناسی ارشد، مهندسی محیط زیست، دانشکده مهندسی عمران، دانشگاه صنعتی شریف.
- بیدختی، ع. ع.، و شرعی‌پور، ز.، ۱۳۸۸، شرایط هواشناختی جوّ بالا و وضعیت حاد آلودگی هوا (بررسی موردی: شهر تهران)، *محیط‌شناسی*، دوره ۳۵، شماره ۴، صفحه‌های ۱-۱۴.
- شرعی‌پور، ز.، و بیدختی، ع. ع.، ۱۳۸۴، شرایط بررسی آلودگی هوای تهران و ارتباط آن با مشخصه‌های هواشناسی، همایش آلودگی هوا و اثرات آن بر سلامت.
- علی‌جانی، ب.، و صفوی، ی.، ۱۳۸۵، بررسی عوامل جغرافیایی در آلودگی هوای تهران، پژوهش‌های جغرافیایی، دوره ۳۸، شماره ۶، صفحه‌های ۹۹-۱۲۲.
- نوری، ر.، اشرفی، خ.، و ازدرپور، ا.، ۱۳۸۷، مقایسه کاربرد روش‌های شبکه عصبی مصنوعی و رگرسیون خطی چندمتغیره براساس تحلیل مولفه‌های اصلی برای پیش‌بینی غلظت میانگین روزانه کربن مونوکسید: بررسی موردی شهر تهران، *مجله فیزیک زمین و فضا*، دوره ۳۴، شماره ۱، صفحه‌های ۱۵۲-۱۳۵.
- Aqil, M., Kita, I., Yano, A., and Nishiyama, S., 2007a, A comparative study of artificial neural networks and neuro-fuzzy in continuous modeling of the daily and hourly behaviour of runoff, *J. Hydro.*, **337**, 22-34.
- Aqil, M., Kita, I., Yano, A., and Nishiyama, S., 2007b, Analysis and prediction of flow from local source in a river basin using a neuro-fuzzy modeling tool, *J. Env. Manag.*, **85**, 215-223.
- Ashrafi, K., and Hoshyaripour, Gh., 2008, A model to determine atmospheric stability conditions and its correlation with CO concentration, *Proc. of International*

- Zannetti, P., 1990, Air pollution modelling, theories, Computational Methods and Available Software, Van Nostrand Reinhold, New York.
- techniques to process experimental urban air pollution data, *Neural Networks*, **16**, 493-506.
- Muhan, M., and Siddiqui, T. A., 1998, Analysis of various schemes for the estimation of atmospheric stability classification, *Atmospheric Environment*, **32**, 3775-3781.
- Nayak, P. C., Sudheer, K. P., Rangan, D. M., and Ramasastri, K. S., 2004, A neuro-fuzzy computing technique for modeling hydrological time series: *Journal of Hydrology*, **291**(1-2), 52-66.
- Noori, R., Hoshyaripour, G., Ashrafi, K., and Araabi, B. N., 2010, Uncertainty analysis of developed ANN and ANFIS models in prediction of carbon monoxide daily concentration, *Atmospheric Environment*, **44**(4), 476-482.
- Nunnari, G., Nucifora, A., and Randieri, C., 1998, The application of neural techniques to the modelling of time series of atmospheric pollution data, *Ecological Modelling* **111**, 187-205.
- Pokrovsky, O. M., Kwok, R., and Ng, C. N., 2002, Fuzzy logic approach for a description of meteorological impacts on urban air pollution species: A Hong Kong Case Study, *Computers and Geosciences*, **28**, 119-127.
- Seinfeld, J. H., and Pandis, S. N., 2006, *Atmospheric chemistry and physics: from air pollution to climate change*, Wiley-Interscience; 2nd edition.
- Schenelle, K. B., and Dey, P. R., 2000, *Atmospheric dispersion modeling compliance guide*, McGraw-Hill companies.
- Sugeno, M., and Yasukawa, T., 1993, A fuzzy-logic based approach to qualitative modeling, *IEEE Transactions on Fuzzy Systems*, **1**(1), 7-31.
- Wang, X. X., Chen, S., Lowe, D., and Harris, C. J., 2006, Sparse support vector regression based on orthogonal forward selection for the generalised kernel model. *Neurocomputing* **70**, 462-474.
- Yager, R., and Filev, D., 1994, Generation of fuzzy rules by mountain clustering, *Journal of Intelligent and Fuzzy Systems*, **2**(3), 209-219.
- Yildirim, Y., and Bayramoglu, M., 2006, Adaptive neuro-fuzzy based modelling for prediction of air pollution daily levels in city of Zonguldak, *Chemosphere*, **63**, 1575-1582.
- Zadeh, L. A., 1965, Fuzzy sets, *Information and Control* **8**, 338-353.