



مدل سازی تأثیرات جریان های ترافیکی بر آلودگی هوای شهر شیراز

رضیه قنبری فرد، سید علی اکبر صفوی* و پیمان ستوده

گروه مهندسی قدرت و کنترل، دانشکده مهندسی برق و کامپیوتر، دانشگاه شیراز، شیراز، ایران

تاریخ پذیرش: ۹۶/۲/۱۶

تاریخ دریافت: ۹۵/۶/۱۴

قنبری فرد، ر.، س.ع.ا. صفوی و پ. ستوده. ۱۳۹۶. مدل سازی تأثیرات جریان های ترافیکی بر آلودگی هوای شهر شیراز. علوم محیطی. ۱۵۷-۱۷۴:(۱)۱۵۷

سابقه و هدف: در کشور ایران حمل و نقل و جریان های ترافیکی بیشترین علت آلودگی هوا را تشکیل می دهند. بر همین اساس مسأله بررسی تأثیرات حمل و نقل و جریان های ترافیکی بر کیفیت هوا خصوصا در مناطق شهری و انجام پیش بینی ها و برنامه ریزی های لازم متناسب با آن، امری ضروری بحساب می آید. با این حال متأسفانه در این زمینه کارهای زیادی در ایران صورت نگرفته است. شناسایی منابع آلاینده از مهم ترین و زمان برترین مراحل مدل سازی آلودگی هواست. برای مدل سازی آلودگی هوای یک منطقه نمی توان تنها یک متغیر را در نظر گرفت؛ بلکه باید متغیرهای فراوانی را مورد مطالعه، بررسی و برنامه ریزی قرار داد. برخی اقدامات، تغییرات محسوسی در وضعیت آلودگی هوای کلان شهرها ایجاد می کند. بنابراین، انجام یکسری اقدامات می تواند کاهش آلودگی هوا را به دنبال داشته باشد که اتخاذ روش های نوین سنجش آلاینده های هوا یکی آنهاست. هدف اصلی این تحقیق ارائه مدلی هوش مند است که بتواند به کمک آن در شرایط خیابان های شهری غلظت آلاینده هایی از قبیل SO_2 ، NO_2 و CO را با دقت مناسبی تخمین زد و با بررسی علل و عوامل تولید این آلاینده ها و پیش بینی آلودگی هوا، اقدامات و برنامه ریزی های لازم در راستای مدیریت و کنترل آلودگی هوا را انجام داد.

مواد و روش ها: در این مقاله یک مدل شبکه عصبی و یک مدل غیر خطی مبتنی بر فضای حالت بر مبنای ترافیک شهر شیراز طراحی شده است. در این مدل سازی غلظت آلاینده های SO_2 ، NO_2 و CO مورد بررسی قرار گرفته و نهایتا با استفاده از فیلتر کالمن برای یک دوره ۲۴ ساعته پیش بینی شده است. این مدل سازی بر مبنای رابطه بین غلظت آلاینده ها و ترافیک و آلودگی اولیه و اطلاعات هواشناسی می باشد. الگوریتم فیلتر کالمن توسعه یافته با استفاده از داده های آلودگی و ترافیکی و همچنین داده های هواشناسی به منظور پیش بینی ۲۴ ساعته آلودگی نقاط مختلف شهر شیراز انجام گرفت. مشخصه کلیدی چنین سیستمی این است که رفتار آن با تغییرات آلودگی در کوتاه مدت منطبق می شود و نیاز به تنظیمات مکرر ندارد. روش شبکه عصبی و فیلتر کالمن به اطلاعات شهر شیراز اعمال شد.

نتایج و بحث: در این کار به بررسی داده های ترافیکی و داده های آلودگی ناشی از غلظت آلاینده ها پرداخته شده، سپس تلاش شده است که داده های آلودگی با نقاط معنی دار شهر شیراز تطبیق داده شود و بسیاری از داده های آلودگی و ترافیکی به دلیل عدم تطابق با یکدیگر از نظر مکانی حذف شدند. در نهایت مدل سازی بر اساس آن بهنگام شده و نتیجه این مطالعات با نتایج واقعی تطبیق داده شد. این ساختار مدل غیر خطی استفاده تکاملی و انعطاف پذیری را ارائه می دهد. به این معنا که ارزیابی کلی عملکرد مدل می تواند به راحتی با اضافه یا کم کردن متغیر جدید انجام گیرد. از طرفی در صورت در اختیار داشتن داده های متناظر با هر ایستگاه جدید دیگر می توان براحتی مطالعات را

* Corresponding Author. E-mail Address: Safavi@Shirazu.ac.ir

برای نقاط دیگر شهر شیراز بسط داد. به این ترتیب اگر ترافیک در بعضی نقاط شهر شیراز در دسترس باشد، می‌توان با بعضی مانورهای ترافیکی آلودگی را به سمت‌های دیگر بسط داده و در مناطق بحرانی کاهش داد.

نتیجه‌گیری: نتایج بصورت آزمایشی نشان می‌دهد که مدل‌ها و خصوصاً مدل فیلتر کالمن توسعه یافته غلظت آلاینده‌ها را بخوبی پیش‌بینی می‌کند.

واژه‌های کلیدی: مدل‌سازی، آلودگی هوا، ترافیک، شبکه عصبی، فیلتر کالمن.

مقدمه

مطالعه، بررسی و برنامه‌ریزی قرار داد. برخی اقدامات، تغییرات محسوس در وضعیت آلودگی هوای کلان‌شهر-ها ایجاد می‌کند. بنابراین انجام یکسری اقدامات می‌تواند کاهش آلودگی هوا را به دنبال داشته باشد که اتخاذ روش‌های نوین سنجش آلاینده‌های هوا یکی آنهاست. در ۲۰ سال گذشته تغییرات زیادی در حوزه مخابرات و الکترونیک اتفاق افتاده است که موجب تغییر در روند زندگی شده است که تجهیزات سنجش آلاینده‌های زیستی از جمله هوا هم از این قاعده مستثنی نیست. تغییرات عمده در سنجش آلاینده‌ها از سال ۲۰۰۵ تا ۲۰۰۶ میلادی اتفاق افتاده است و کاهش مصرف انرژی تا ۸۰ درصد، افزایش طول عمر قطعات ایستگاه‌ها تا ۱۰ برابر، قابل حمل و نقل شدن ایستگاه‌ها، پایش بدون محدودیت فضا، کاهش چشمگیر هزینه‌های بهره‌وری - تعمیر و نگهداری و پیروی از روش‌های استاندارد اندازه-گیری مورد تایید سازمان‌های معتبر جهانی برخی از این تغییرات است. بر فرض صحت داده‌ها، عدم تجمیع و مدل‌سازی آلاینده‌های هوا، حلقه گمشده حوزه مانیتورینگ و پایش آلاینده‌ها است.

هدف اصلی این تحقیق ارائه مدلی هوشمند است که بتوان به کمک آن در شرایط خیابان‌های شهری غلظت آلاینده‌هایی از قبیل SO_2 ، NO_2 و CO را با دقت مناسبی تخمین زد و با بررسی علل و عوامل تولید این آلاینده‌ها و پیش‌بینی آلودگی هوا، اقدامات و برنامه‌ریزی‌های لازم در راستای مدیریت و کنترل آلودگی هوا را انجام داد. برای

آلودگی هوا به معنی حضور یک ماده خارجی در هواست. به عبارت دیگر آلودگی هوا عبارت است از حضور آلاینده‌ها در هوا به مقدار و زمان ماند کافی که بر سلامت و استفاده درست و مطلوب از اموال، زندگی انسان، حیوانات و گیاهان اثر زیان‌بار دارد. تحلیل غلظت آلاینده- (ها) مونواکسیدکربن در مکان‌هایی که ترافیک اصلی‌ترین منبع آلودگی هوا شناخته شده است، به عنوان هدف اصلی انتخاب می‌شود. در کشور ایران حمل و نقل و جریان‌های ترافیکی بیشترین علت آلودگی هوا را تشکیل می‌دهند. بر همین اساس مسأله بررسی تأثیرات حمل و نقل و جریان‌های ترافیکی بر کیفیت هوا به‌ویژه در مناطق شهری و انجام پیش‌بینی‌ها و برنامه‌ریزی‌های لازم متناسب با آن ضروری بحساب می‌آید. با این حال متأسفانه در این زمینه کارهای زیادی در ایران صورت نگرفته است. بر همین اساس مسأله ارزیابی کیفیت هوا در طرح‌های شهری و برنامه ریزی حمل و نقل شهرها امری ضروری است. هرچند این ارزیابی محدود به پیش‌بینی غلظت آلاینده‌های ناشی از ترافیک در خیابان‌های شهری نمی‌شود، اما از آنجا که این مشکلات در خیابان‌های شهری حادث‌تر است، بررسی مسأله در این نواحی از اولویت خاصی برخوردار است.

شناسایی منابع آلاینده از مهم‌ترین و زمان‌برترین مراحل مدل‌سازی آلودگی هواست. برای مدل‌سازی آلودگی هوای یک منطقه نمی‌توان تنها یک متغیر را در نظر گرفت؛ بلکه باید متغیرهای فراوانی را مورد

در نظر گرفته شده است. اطلاعات ترافیکی مربوط به تردد خودروها در ساعات مختلف شبانه روز جمع‌آوری شده است. این اطلاعات به صورت تعداد خودروی عبوری از مقطع مورد مطالعه در طول یک‌ساعت می‌باشد و این موضوع برای تمام ساعات شبانه‌روز انجام گرفته است.

اطلاعات هواشناسی

غلظت آلاینده‌ها بوسیله‌ی شرایط هواشناسی چون سرعت باد و جهت باد و درجه حرارت تحت تاثیر قرار می‌گیرد. به عنوان مثال، بادهای آرام، به همراه سیستم‌های فشار بالا معمولاً شانس انباشته شدن آلاینده‌ها در لایه‌های مرزی هوا را افزایش می‌دهد. شهرستان شیراز با مختصات جغرافیایی ۵۲,۳۳ طول شرقی و ۲۹,۳۶ عرض شمالی در ارتفاع بیش از ۱۵۰۰ متر از سطح دریا قرار گرفته است. جهت غالب باد در شیراز با توجه به رشته کوه‌های زاگرس از جهت غرب به شمال غرب می‌باشد. شیراز را کوه‌های نسبتاً بلندی به شکل حصار در بر گرفته که از نظر جغرافیایی موقعیت مطلوبی است. شیراز در منطقه معتدل شمالی قرار گرفته است و آب و هوای آن بری است. اطلاعات هواشناسی استفاده شده در این تحقیق از سازمان هواشناسی شیراز بدست آمده است. دوره‌ی پوشش داده شده یک روز کامل و هر ۳ ساعت یک‌بار می‌باشد. از طرفی نویز ناشی از خطا در متغیرهای ورودی می‌تواند کیفیت تخمین نهایی را کاهش دهد. در تخمین بوسیله فیلتر کالمن این موضوع به عنوان منابع تولید نویز اضافه در دینامیک فضای حالت در نظر گرفته شده است. ماتریس کواریانس حالت و مشاهده نویز می‌تواند به عنوان پارامترهای طراحی سطح بالا در نظر گرفته شده و برای کنترل کردن انعطاف‌پذیری مدل فضای حالت پذیرفته شود.

اطلاعات آلودگی هوا

اطلاعات آلودگی هوای استفاده شده در این تحقیق

این کار می‌توانیم مدل‌های ریاضی و روش‌های آماری را بکار ببریم. بطور معمول مدل‌های ریاضی و روش‌های آماری همانند رگرسیون، شبکه‌های عصبی و مدل‌های احتمالاتی برای مدل‌سازی آلودگی هوا بکار برده می‌شوند (Hassan and Croether, 1998; Branis, 1998; Kim and Guldman, 2011; Gokhale, 2011; Keuken, 2012) و (Keuken, 2012). در این تحقیق جهت انجام مدل‌سازی از شبکه عصبی و فیلتر کالمن استفاده می‌شود. به دلیل رفتار غیرخطی آلاینده‌ها پیش‌بینی آنها مشکل است. فیلتر کالمن قبلاً توسط (Marsik et al. 2010) برای پیش‌بینی آلاینده‌ها در آلاسکا بکار برده شده است. هم‌چنین در تحقیقات (Zolghadri et al. 2006) یک مدل‌سازی مبتنی بر فضای حالت غیرخطی تطبیقی برای منطقه پایتخت بردآکس طراحی شده است. ما با اعمال این دو روش و هم‌چنین روش شبکه عصبی به بررسی و تحلیل نتایج می‌پردازیم.

فیلتر کالمن به عنوان یک تخمین درجه دوم خطی (LQE)^۱ شناخته می‌شود. این الگوریتم از یک سری مشاهدات اندازه‌گیری شده در زمان، شامل نویز و دیگر عدم دقت‌ها استفاده می‌کند و تخمینی از متغیرهای شناخته نشده که به سمت دقت بیشتر نسبت به داده‌های اندازه‌گیری تمایل دارند را تولید می‌کند. به طور رسمی‌تر فیلتر کالمن یک جریان از داده‌های ورودی شامل نویز برای تولید تخمین بهینه آماری از حالات سیستم را به ما می‌دهد.

مواد و روش‌ها

منبع اطلاعات

اطلاعات ترافیکی

از آنجا که انتشارات آگروز خودروها حاوی سه آلاینده مورد بحث در این مقاله می‌باشد؛ ترافیک یکی از منابع اصلی آلودگی شناخته می‌شود. در نتیجه در این مدل‌سازی ترافیک به عنوان یکی از ورودی‌های سیستم

مدل‌سازی غلظت آلاینده‌ها با استفاده از شبکه

عصبی RBF

سالیان اخیر در تجزیه و تحلیل اطلاعات برای مسائلی که راه حل مشخصی برای آنها موجود نیست و به راحتی حل شدنی نیستند، سیستم‌های دینامیکی هوشمند، که مبتنی بر داده‌های تجربی هستند، بطور فزاینده‌ای مورد توجه واقع شده است. شبکه‌های عصبی مصنوعی جزء این دسته از سیستم‌های دینامیکی می‌باشند که با پردازش داده‌های تجربی، قانون نهفته در ورای این اطلاعات را به ساختار شبکه منتقل می‌کنند. شبکه‌های عصبی در بعد آنالیز و توسعه ساختاری و همچنین در بعد پیاده‌سازی سخت افزاری، از نظر کمی و توانایی، در حال افزایش هستند. همچنین فعالیت علمی و کاربردی در مسائل فنی و مهندسی از قبیل سیستم‌های کنترلی، پردازش سیگنال‌ها و شناسایی الگو گسترش یافته است. شبکه‌های عصبی با داشتن ویژگی‌هایی از قبیل خودآموزی^۲ و قدرت تقریب هر تابع غیرخطی، به عنوان ابزاری بسیار قوی در زمینه سیستم‌های پیچیده مورد استفاده قرار می‌گیرد.

یک شبکه عصبی در واقع سیستمی متشکل از مؤلفه‌های تحلیلی متصل به یکدیگر می‌باشد که از ساختار شبکه مغز بشر الگوبرداری شده است. در این شبکه‌ها ارتباطات بین داده‌های ورودی و خروجی آموزش داده می‌شود (Safavi, 1996) (Haykin, 1999) (Ding et al., 1996). عامل مشترک بین تمام مدل‌های شبکه عصبی ارائه شده، بلوک‌های ساختاری یا نورون‌ها می‌باشند. ساختار این نورون از دو قسمت تابع شبکه^۳ و تابع فعال‌سازی^۴ تشکیل شده است. تابع شبکه چگونگی ترکیب ورودی‌های شبکه $\{y_j; 1 \leq j \leq N\}$ در داخل نورون را مشخص می‌کند:

$$u = \sum_{j=1}^N w_j y_j + \theta \quad (1)$$

که $\{w_j; 1 \leq j \leq N\}$ پارامترهای وزن هستند و θ

از سازمان ترافیک شهر شیراز جمع آوری شده است. داده‌ها شامل اندازه‌گیری غلظت آلاینده‌های SO_2 ، NO_2 و CO در ۲ ساعت از شبانه روز برای نقاط مختلف از شهر شیراز می‌باشد که از آنهاست برای بررسی کیفیت تخمین نهایی و همچنین به عنوان داده‌های خروجی شبکه‌ی عصبی استفاده شده است.

انتخاب متغیرهای ورودی

بدیهی است که پیش‌بینی‌های مختلف بین ماکزیمم و مینیمم دما ارتباط همبستگی بالا با غلظت آلاینده‌ها خواهد داشت. به دلیل ارتباط کم بین سری زمانی و تابش خورشید و رطوبت این متغیرها را در نظر نگرفته ایم. فشار هوا نیز به عنوان متغیر ورودی مدل ثبت شده است. ماکزیمم غلظت آلاینده‌ها در ساعات ۹-۱۱ صبح و ۶-۸ عصر که ساعات ازدحام مردم است مشاهده می‌شود. از آنجا که رفتارهای هواشناسی و ترافیکی در ساعات مختلف روز متفاوت می‌باشد، ساعات مختلف روز نیز به عنوان ورودی مدل ثبت شده است. داده‌های ورودی به اختصار در جدول ۱ آورده شده است.

جدول ۱- تعریف متغیرهای ورودی

Table 1. Definition of input variables

متغیر variable	واحد Unit	مخفف Acronym
داده‌ی ترافیک Traffic data	-	u_1
سرعت باد Wind speed	m/s	u_2
جهت باد Wind direction	-	u_3
فشار بخار Air pressure	hp	u_4
دما Temperature	°C	u_5
ساعت روز Daily hour	h	u_6

اگر چند نورون RBF به طور موازی از یک ورودی تغذیه شوند و سپس خروجی‌های آنها وارد یک نورون خروجی شود شبکه RBF حاصل می‌شود. می‌توان عملکرد شبکه RBF را در قالب فرمول زیر بیان کرد:

(۳)

$$\hat{y} = \sum_i^M \omega_i \Phi_i(\|\underline{u} - \underline{C}_i\| \sum_i) , \quad \Phi_i(\cdot) = 1$$

پارامترهای شبکه RBF شامل سه دسته می‌شوند، بردارهای C_i که مراکز نورون‌ها را مشخص می‌کنند، ماتریس‌های \sum_i که انحراف معیار هر نورون را مشخص می‌کنند و W_i که وزن‌های لایه خروجی هستند. مجموع تعداد پارامترهای لازم برای تشکیل یک شبکه RBF با P ورودی و یک خروجی که تعداد نورون‌های لایه مخفی آن M تا است بستگی به انتخاب نوع ماتریس \sum_i دارد. از آنجا که برتری اصلی شبکه‌های عصبی RBF بر شبکه‌های MLP سرعت آموزش بالای آنهاست، انتخاب ماتریس غیر-قطری با بالا بردن حجم محاسبات و در نتیجه افزایش زمان آموزش شبکه، به نوعی از بین بردن این برتری محسوب می‌شود. بنابراین معمولاً \sum_i قطری انتخاب می‌شود. حتی در بسیاری از موارد انتخاب ماتریس \sum_i به صورت قطری با درایه‌های یکسان نیز مطلوب است؛ زیرا با افزایش تعداد نورون‌ها می‌توان به دقت قابل قبول مسئله دست یافت و از آنجا که سرعت آموزش شبکه RBF ذاتاً بالاست، افزایش تعداد نورون‌ها تا حدی، موجب نگرانی در مورد بالا رفتن زمان آموزش نمی‌شود.

برای مدل‌سازی با استفاده از شبکه عصبی، سه شبکه MLP و RBF و WAVENET مورد بررسی قرار گرفت. از آنجا که نتایج مربوط به شبکه RBF قابل قبول‌تر و بهتر بود، تنها نتایج مدل‌سازی با استفاده از این شبکه آورده شده است. جهت انجام مدل‌سازی از نرم‌افزار MATLAB استفاده شد. داده‌های ترافیکی ۱۷ ایستگاه از شهر شیراز در طول ۲۴ ساعت در دسترس بود، اما داده‌های خروجی فقط در ساعات ۸ و ۱۱ صبح موجود بود. به دلیل کمبود داده‌های آلودگی نیاز به یک چینش خاص

بایاس یا حد آستانه نامیده می‌شود.

خروجی نورون که در شکل با a مشخص شده، بوسیله تبدیل خطی یا غیرخطی به نام تابع فعال‌سازی به u مرتبط می‌شود:

(۲)

$$a = f(u)$$

آنچه که در اینجا بیش از همه مورد توجه است، این است که شبکه‌های عصبی می‌توانند به عنوان یک ابزار علمی و عملی برای مسائلی که هنوز راه حل مناسبی برای آن‌ها پیدا نشده و یا با راه حل‌های موجود جواب مطلوبی ندارند، مورد توجه قرار بگیرد.

شبکه پایه شعاعی (RBF^۵)

شبکه‌های عصبی RBF شبکه‌های عصبی با یک لایه مخفی هستند که از توابع پایه شعاعی به عنوان تابع فعالیت خود استفاده می‌کنند. تک لایه بودن لایه مخفی موجب افزایش سرعت عملکرد و همچنین سرعت آموزش این شبکه‌ها نسبت به دیگر شبکه‌های عصبی همچون MLP^۶ شده است که امتیاز اصلی این نوع شبکه‌ها محسوب می‌شود و در مواردی که نیاز به آموزش برخط وجود دارد، حضور شبکه‌های RBF را اجتناب‌ناپذیر ساخته است. توابع پایه شعاعی اصالتاً به منظور درون‌یابی توابع غیرخطی در علم ریاضیات استفاده می‌شدند و هیچ‌گونه ارتباطی با شبکه‌های عصبی نداشته‌اند تا اینکه نظریه استفاده از آن در دهه ۸۰ میلادی مطرح شد. امروزه شبکه‌های عصبی RBF همانند شبکه‌های MLP فراگیر شده‌اند.

تابع فعال‌سازی در این شبکه‌ها معمولاً به گونه‌ای انتخاب می‌شود که ماکزیمی در $x = 0$ داشته باشد و در دو طرف نسبت به نقطه $x = 0$ متقارن باشد. توابع پایه شعاعی دارای چنین خواصی هستند که از آنها به عنوان تابع فعالیت در شبکه‌های عصبی RBF استفاده می‌شود. توابع گوسی و توابع مولتی کوادراتیک معکوس نمونه‌های مرسوم این توابع هستند.

شده که این داده‌ها در جدول ۲ نشان داده شده است. توجه شود که در مدل‌سازی هر ایستگاه در ساعات ۸ و ۱۱ دو ایستگاه مجزا در نظر گرفته شده‌اند. از مدرج-سازی برای بهتر نشان داده داده‌ها استفاده شده است. در این مطالعه آلودگی اولیه، با استفاده از مجموعه‌ی محدود از داده‌ها و با تحلیل داده‌های آلودگی ساعات موجود و نسبت بندی با ترافیک آن بازه زمانی بدست آمده است.

جهت انجام این مدل‌سازی می‌باشد. در این روش داده‌های ۱۳ ایستگاه به عنوان داده‌ی آموزش و داده‌ی ۴ ایستگاه به عنوان داده‌ی آزمایش در نظر گرفته شده است. ساختار شبکه عصبی RBF بکاربرده شده بصورت زیر می‌باشد: در این روش از یک شبکه با چهار ورودی و یک خروجی استفاده شد. با توجه به همبستگی بین داده‌های آلودگی در ساعات متوالی و پایداری آلودگی دینامیک داده‌ها نیز به عنوان ورودی به مدل داده

جدول ۲- ورودی و خروجی به شبکه عصبی RBF

Table 2. RBF Neural Network input and output

خروجی Output	ورودی شماره ۴ No. 4 Input	ورودی شماره ۳ No. 3 Input	ورودی شماره ۲ No. 2 Input	ورودی شماره ۱ No. 1 Input
آلودگی ایستگاه شماره n در لحظه t	ترافیک ایستگاه شماره n در لحظه t-2	ترافیک ایستگاه شماره n در لحظه t-1	ترافیک ایستگاه شماره n در لحظه t	آلودگی اولیه ایستگاه شماره n در لحظه t
Primary pollution of No. n station at t moment n = 1, ..., 26	Traffic of No. n station at t moment n = 1, ..., 26	Traffic of No. n station at t-1 moment n = 1, ..., 26	Traffic of No. n station at t moment n = 1, ..., 26	Primary pollution of No. n station at t moment n = 1, ..., 26

عدم دقت‌ها استفاده می‌کند و تخمینی از متغیرهای شناخته نشده که به سمت دقت بیشتر نسبت به داده‌های اندازه‌گیری تمایل دارند را تولید می‌کند. به طور رسمی تر فیلتر کالمن یک جریان از داده‌های ورودی شامل نویز برای تولید تخمین بهینه آماری از حالات سیستم را به ما می‌دهد. تئوری فیلتر مدرن با کار وینر در سال ۱۹۴۹ شروع شد (Winer, 1949). کار او بر مبنای مینیمم کردن خطای میانگین مربعات بود، بنابراین گاهی اوقات این شاخه از تئوری فیلتر به عنوان فیلتر حداقل مربعات بیان می‌شود. این بیان یک ساده‌سازی است اگرچه توصیف دقیق آن می‌تواند بصورت "فیلتر خطی در حوزه‌ی زمان بر مبنای کمینه کردن میانگین مربعات خطا" باشد. صرفه نظر از اینکه نام آن چه باشد، مشکل اصلی اهمیت جداسازی سیگنال از یک ترکیب سیگنال و نویز است. در حقیقت، راه حل وینر یکی از موضوعاتی بود که در کتاب-های درسی زیاد مورد بحث بود، اما در عمل چندان استفاده‌ای از آن نمی‌شد. شاید سهم اصلی وینر راهی بود

برای نوشتن برنامه‌ی شبکه عصبی RBF در نرم‌افزار MATLAB به ترتیب زیر عمل شده است. ابتدا برای آموزش شبکه داده‌های ورودی و خروجی ثبت شد و برای بهتر نشان دادن داده‌ها از مدرج‌سازی استفاده شد. تعداد نودها بصورت اتوماتیک برای جبران هدف خطا تنظیم می‌شوند. به عنوان مثال در مدل‌سازی غلظت آلاینده CO شبکه RBF با یک لایه‌ی مخفی شامل ۱۰ نود داریم. در ادامه شبیه‌سازی با آرگومان‌های ورودی و خروجی انجام شده است که خروجی در اینجا خروجی شبکه عصبی می‌باشد که باید با داده‌های هدف مقایسه شود. در مرحله‌ی بعد مقاردهی ابتدایی برای آزمایش شبکه، مدرج‌سازی داده‌ها انجام گرفته است.

مدل‌سازی با استفاده از فیلتر کالمن

فیلتر کالمن به عنوان یک تخمین درجه دوم خطی^۷ شناخته می‌شود. این الگوریتم از یک سری مشاهدات اندازه‌گیری شده در زمان، شامل نویز و دیگر

است:

$$z_k = H_k x_k + v_k \quad (5)$$

همچنین فرض می‌کنیم که ϕ_k و H_k و توصیف کوارینانس w_k و v_k شناخته شده هستند. در ادامه مفاهیم زیر تکرار خواهد شد:

$$x_k = \text{بردار حالت } (n \times 1) \text{ در زمان } t_k.$$

$\phi_k = \text{ماتریس } (n \times n)$ که x_k را به x_{k+1} در غیاب ورودی مربوط می‌کند. اگر x_k یک نمونه از پروسه پیوسته باشد، ϕ_k ماتریس انتقال حالت متداول $\phi(t_{k+1}, t_k)$ است. $w_k = \text{بردار } (n \times 1)$ — فرض کنید که یک دنباله سفید با ساختار کوارینانس مشخص باشد که سهم نویز سفید ورودی در بردار حالت برای فاصله زمان (t_{k+1}, t_k) می‌باشد.

$$z_k = \text{بردار اندازه گیری } (m \times 1) \text{ در زمان } t_k.$$

$H_k = \text{ماتریس } (m \times n)$ که ارتباط ایده‌آل (بدون نویز) بین مقادیر اندازه‌گیری و بردار حالت در زمان t_k می‌کند.

$v_k = \text{خطای اندازه گیری } (m \times 1)$ — فرض کنید که یک دنباله سفید با ساختار کوارینانس مشخص باشد و با دنباله w_k ارتباط متقابل صفر داشته باشد.

ماتریس کوارینانس برای بردارهای w_k و v_k بصورت

زیر داده شده است:

$$E[w_k w_i^T] = \begin{cases} Q_k, & i = k \\ 0, & i \neq k \end{cases} \quad (6)$$

$$E[v_k v_i^T] = \begin{cases} R_k, & i = k \\ 0, & i \neq k \end{cases} \quad (7)$$

$$E[w_k v_i^T] = 0, \quad \text{for all } k \text{ and } i \quad (8)$$

فرض می‌کنیم در این نقطه ما تخمین اولیه‌ای از پروسه را در بعضی از نقاط در زمان t_k داریم و این تخمین مبتنی بر دانسته‌های ما درباره‌ی فرآیند قبل از زمان t_k می‌باشد. این تخمین اولیه با \hat{x}_k^- نشان داده خواهد شد که " " مشخص کننده‌ی تخمین و منفی بالا به ما یادآوری

که مسئله‌ی مینیمم کردن خطای میانگین مربعات را به حوزه زمان منتقل کرد. این موضوع با روش‌های مجزای فرکانسی که در زمان استفاده می‌شوند مغایرت دارد. چند سال بعد (Kalman (1960) همان مسئله که وینر قبلاً کار کرده بود را در نظر گرفت، اما در مقاله‌ی او در سال ۱۹۶۰، کالمن اندازه‌گیری‌های نویزی با دامنه گسسته در زمان که با یک سیگنال پیوسته در زمان در مغایرت بود را در نظر گرفت. او همچنین مسئله را به یک محیط فضای حالت منتقل کرد که سناریوی چند ورودی/چند خروجی متغیر با زمان را اصلاح می‌کرد. مهندسان به سرعت تکنیک کالمن را به عنوان یک راه‌حل عملی برای بعضی از مسائل فیلترینگ کاربردی به خصوص در زمینه‌ی دریانوردی که متمرکزانه از روش‌های وینر استفاده می‌کردند، به کار بردند (Brown et al., 2007). همچنین پیشرفت‌های سریع که در سال ۱۹۶۰ در تکنولوژی رایانه اتفاق افتاد، قطعاً به مشهور شدن فیلتر کالمن به عنوان یک روش عملی جداسازی سیگنال از نویز کمک کرد. بعد از پنجاه سال، امروزه هنوز فیلتر کالمن مورد استفاده و صحیح است و کاربردهای جدید بطور منظم ظاهر می‌شود.

فیلتر کالمن گسسته

بر طبق معادلات بازگشتی فیلتر کالمن را بسط می‌دهیم. معیار بهینه سازی استفاده شده در اینجا مینیمم کردن خطای تخمین میانگین مربعات متغیر تصادفی x می‌باشد. این موضوع همان تخمین خطی متناظر با میانگین x تعیین شده روی همه‌ی دنباله‌های داده‌های اندازه‌گیری شده گذشته می‌باشد (Brown et al., 2007). فرض می‌کنیم که پروسه‌ی تصادفی برای تخمین زدن به صورت زیر مدل شود:

$$x_{k+1} = \phi_k x_k + w_k \quad (4)$$

فرض می‌کنیم که مشاهدات (اندازه‌گیری) در نقاط گسسته در زمان در تطابق با رابطه خطی زیر اتفاق افتاده

می‌کند که این تخمین بهترین تخمین پیشین از نظر شبیه بودن به اندازه‌گیری در زمان t_k می‌باشد. همچنین فرض می‌کنیم که ماتریس کواریانس خطای مربوط به \hat{x}_k^- را می‌دانیم. بنابراین خطای تخمین را به صورت زیر تعریف می‌کنیم:

می‌کند که این تخمین بهترین تخمین پیشین از نظر شبیه بودن به اندازه‌گیری در زمان t_k می‌باشد. همچنین فرض می‌کنیم که ماتریس کواریانس خطای مربوط به \hat{x}_k^- را می‌دانیم. بنابراین خطای تخمین را به صورت زیر تعریف می‌کنیم:

$$e_k^- = x_k - \hat{x}_k^- \quad (9)$$

و ماتریس کواریانس خطای مربوطه عبارت‌اند از:

$$P_k^- = E[e_k^- e_k^{-T}] = E[(x_k - \hat{x}_k^-)(x_k - \hat{x}_k^-)^T] \quad (10)$$

با فرض تخمین اولیه‌ی \hat{x}_k^- از اندازه‌گیری z_k برای

بهبود تخمین اولیه استفاده می‌کنیم:

$$\hat{x}_k = \hat{x}_k^- + K_k(z_k - H_k \hat{x}_k^-) \quad (11)$$

که \hat{x}_k تخمین بروزرسانی شده می‌باشد و ماتریس

کواریانس خطای مربوط به این تخمین (\hat{x}_k) بصورت زیر می‌باشد:

$$(12)$$

$$P_k^- = E[e_k e_k^T] = E[(x_k - \hat{x}_k)(x_k - \hat{x}_k)^T]$$

مقدار K_k که خطای تخمین میانگین مربعات را

حداقل می‌کند بهره‌کالمن^۸ نامیده می‌شود که به صورت زیر تعریف می‌شود:

$$K_k = P_k^- H^T (H_k P_k^- H_k^T + R_k)^{-1} \quad (13)$$

فرآیند اندازه‌گیری یک‌بار در زمان

در اینجا یک الگوریتم که حول کواریانس خطای معکوس قرار دارد و دارای یک بیان فیزیکی به عنوان ماتریس اطلاعات است را نشان می‌دهیم. در ادامه، نشان خواهیم داد که تحت یک شرح معین، اجزای بردار اندازه‌گیری می‌تواند یکبار در یک زمان اجرا شود. ابتدا با فرمول بروزرسانی ماتریس اطلاعات شروع می‌کنیم:

$$P^{-1} = (P^-)^{-1} + H^T R^{-1} H \quad (14)$$

توجه کنید که این معادله بروزرسانی با فرض بهره

$$(15)$$

p^{-1}

$$= \frac{(P_k^-)^{-1} + H_k^{aT} (R_k^a)^{-1} H_k^a + H_k^{bT} (R_k^b)^{-1} H_k^b + \dots}{\underbrace{(P_k^-)^{-1} \text{ after assimilating block a measurements}}_{(P_k^-)^{-1} \text{ after assimilating block b measurements}}}$$

دقت کنید که جمع دو جمله اول در معادله $(P_k^-)^{-1}$

است که بعد از یکسان‌سازی اندازه‌گیری "بلوک a"، اگر اندازه‌گیری دیگری در دسترس نباشد، بدست می‌آید. بهره‌کالمن وابسته به این بلاک ممکن است برای بروزرسانی متقابل تخمین حالت استفاده شود. هدف ما ایجاد یک تصویر بدیهی از طریق زمان صفر، و سپس شروع از طریق بروزرسانی بهره حلقه با استفاده از اندازه‌گیری‌های "بلوک b" می‌باشد. در حقیقت، ما می‌توانیم مکرراً از حلقه بروزرسانی کواریانس خطای معمولی تا زمانی که همه‌ی بلوک‌های اندازه‌گیری در زمان t_k یکسان شوند، استفاده کنیم. نتیجه نهایی زمانی است که ما پروسه را یکبار برای همه اندازه‌گیری‌ها به عنوان یک کمیت برداری انجام دهیم. بار دیگر با تصویر نه چندان کم در t_{k+1} یک مرحله به جلو می‌رویم و برای اندازه‌گیری‌های دیگر تمام مراحل را مشابه اندازه‌گیری یکبار در یک زمان شروع می‌کنیم.

برای مدل‌سازی با استفاده از فیلتر کالمن، از دو

روش خطی و غیرخطی استفاده شده است و با پیاده‌سازی

مدل‌های تایید شده خطی و غیرخطی نتیجه مورد بحث

و می‌تواند یک روند خاص داشته باشد. ، مشخصات متوسط ارتفاع و نرخ حمل و نقل همان روند داده شده بوسیله‌ی تابش خورشید را دنبال می‌کنند؛ که بر باد و ارتفاع مختلط و در نتیجه نرخ حمل و نقل اثر می‌گذارد. اگر تابش خورشید را کم در نظر بگیریم، بنابراین متوسط مشخصات روزانه برای ارتفاع و نرخ حمل و نقل می‌تواند با مشخصات ثابت تقریب زده شود. با فرض ثابت بودن k, k_d, k_t و K معادله را می‌توان با استفاده از یک مدل فضای حالت تک ورودی-تک خروجی (SISO^۹) با تنها یک متغیر حالت بصورت زیر

بیان کرد:

$$\frac{dx}{dt} = Ax + Bu \quad (۱۷)$$

$$y = Cx + Du \quad (۱۸)$$

که $A = -(k + k_d + k_t)$ ، $B = \frac{K}{H}$ ، $C = 1$ و $D = 0$ پارامترهای مدل هستند.

این مدل به راحتی در MATLAB با استفاده از دستور $ss(A,B,C,D)$ ساخته می‌شود. در اینجا نیز از مدرج‌سازی برای بهتر نشان داده داده‌ها استفاده شده است. در ادامه به معرفی فاکتورها و مقادیر اولیه لازم برای تخمین فیلتر کالمن پرداخته می‌شود. فاصله بین ایستگاه‌ها از یکدیگر بر حسب متر به مدل اضافه شد که بهبود نتیجه به خوبی قابل مشاهده بود. از آنجا که داده‌های خروجی برای هر آلاینده در ساعات ۸ و ۱۱ در دسترس بود، با استفاده از مدل معرفی شده مقادیر آلاینده‌ها را برای ساعات دیگر تخمین زده شد.

مدل‌سازی و تخمین بر اساس فیلتر کالمن توسعه یافته

همانطور که می‌دانید مدل‌های پارامتر متغیر با زمان می‌تواند بوسیله پارامترهای متغیر که یک ترکیب

و بررسی قرار گرفته است. جهت انجام مدل‌سازی از نرم-افزار MATLAB استفاده شد. داده‌های ترافیکی ۱۷ ایستگاه از شهر شیراز در طول ۲۴ ساعت در دسترس بود اما داده‌های خروجی فقط در ساعات ۸ و ۱۱ صبح موجود بود که در این روش با ارائه مدل پس از تایید صحت عملکرد مدل بر شهر شیراز، سعی بر تخمین و پیش بینی آلودگی در ساعات مختلف را داشته‌ایم.

مدل‌سازی و تخمین بر اساس فیلتر کالمن خطی

استفاده از مدل برای تخمین سهم ترافیک در سطوح آلودگی هوا از داده‌های ترافیک شناخته شده، عموماً به شناخت از پارامترهای مدل همچون عوامل انتشار و شرایط هواشناسی نیاز دارد. در اینجا به بررسی و پیاده‌سازی پارامترهای مدل فضای حالت که به اطلاعاتی از پارامترهای مدل نیاز ندارد، پرداخته شده است. (2010) Marsik et al. این مدل را در تجزیه و تحلیل مونواکسیدکربن در مرکز شهر فیرینکس بکار گرفته و صحت عملکرد آن را تایید کرده است.

رابطه‌ی موازنه‌ی جرم بین غلظت آلاینده‌های مربوط به ترافیک بصورت زیر توصیف می‌شود:

$$\frac{dC_{traffic}}{dt} = -(k + k_d + k_t)C_{traffic} + \frac{K}{H}N_{traffic} \quad (۱۶)$$

که $C_{traffic}$ غلظت آلودگی ناشی از ترافیک، $N_{traffic}$ شدت ترافیک (در اینجا وسیله نقلیه بر ساعت (Vph))، k نرخ فروپاشی $(\frac{1}{hr})$ ، k_d نرخ رسوب، k_t نرخ حمل و نقل شبکه، K یک ثابت مربوط به تعداد ترافیک به انتشار آلاینده در واحد سطح است و H ارتفاع (متر) است. مشخصات روزانه‌ی ارتفاع مختلط و نرخ انتقال به دلیل متوسط‌گیری خطی هستند. با این حال یک مشخصه‌ی خطی به معنی یک مشخصه ثابت نیست

$$\begin{aligned} \hat{y}(k+1) = & \theta_1(k)y(k) + \theta_2(k)u_1(k) \quad (20) \\ & + [\theta_3(k)y(k) \\ & + \theta_4(k)] \\ & * \tanh(\theta_5(k)/u_2(k+1)) \\ & + \theta_6(k)y(k)u_3(k) \\ & + 1) \\ & + \theta_7(k)u_3(k+1) \\ & + \theta_8(k)u_4(k+1) \\ & + \theta_9(k)u_5(k+1) \\ & + \theta_{10}(k)u_6(k+1) \\ & + \theta_{11}(k) + v_{12}(k) \end{aligned}$$

ساختار مدل بالا از طریق رگرسیون برداری چندجمله‌ای و غیرخطی آلاینده‌ها با متغیرهای ورودی مختلف بدست آمده است. این مدل در تجزیه و تحلیل PM₁₀ در مرکز شهر برداکس بکار گرفته شده است و صحت عملکرد آن تایید شده است. مدل شامل ۱۱ پارامتر متغیر با زمان است که به صورت اتوماتیک بر روزرسانی می‌شوند. هر پارامتر، $i=1, \dots, 11$ بوسیله یک معادله حالت دینامیک به فرم زیر مدل می‌شود:

$$\theta_i(k+1) = \theta_i(k) + v_i(k) \quad (21)$$

توجه شود که بیان صریح "راه‌حل کلی" برای انتخاب ساختار، از آنجا که هر منطقه شهری باید با مراجعه به منابع هواشناسی، محیطی و محلی آن بررسی شود، احتمالاً پیدا نخواهد شد. ساختار مدل بکارگرفته شده استفاده تکاملی و انعطاف پذیر را ارائه می‌دهد، به این معنا که ارزیابی کلی عملکرد مدل می‌تواند به راحتی با اضافه و یا کم کردن متغیر جدید انجام شود. یک بردار حالت توسعه یافته به صورت زیر بیان می‌شود (Zolghadri et al., 2006):

$$x_k = \begin{pmatrix} \theta_k \\ y_k \end{pmatrix} \quad (22)$$

که $\theta \in R^{11}$ و $\theta \in R^{14}$ می‌باشد. برای بدست آوردن مقادیر اولیه پارامترها، با توجه به داده‌ها و مثال‌های نقطه‌ای، پارامترها را به روش سعی و خطا

خطی، تغییرات تدریجی و یا توابع با شیب بیشتر هستند، توصیف شوند (Young, 1992). بنابراین این روش مدل‌سازی می‌تواند برای بعضی از سیستم‌های با دینامیک متغیر و رفتار غیرخطی ملایم بکار برده شود. این موضوع مشخص است که اگر، سری‌های زمانی مشخصه بسیار نامنظم و بی‌قاعده داشته باشند، فیلتر کالمن خطی ممکن است تفاوت اندکی با مدل‌های متداول داشته باشد (مقادیر پیش‌بینی شده برای آینده \sim مقادیر اندازه‌گیری شده حال). در اینجا به ارزیابی مدلی می‌پردازیم که مبتنی بر روابط تجربی بین آلاینده‌های اندازه‌گیری شده و متغیرهای هواشناسی می‌باشد. سیستم مدل‌سازی مبتنی بر یک تطبیق غیرخطی فیلتر مبتنی بر فضای حالت می‌باشد. معادلات فیلترینگ با استفاده از فیلتر کالمن توسعه یافته (EKF) حل می‌شوند. ویژگی چنین سیستمی این است که پارامترهای مدل با استفاده از مکانیزم تطبیق هر ساعت روزرسانی می‌شوند و مدل نیاز به تنظیمات مکرر ندارد. غلظت آلاینده‌های مورد بررسی در این تحقیق بوسیله شرایط هواشناسی چون سرعت باد، جهت باد، درجه حرارت و ... تحت تأثیر قرار می‌گیرد. ساختار مدل فیلتر کالمن توسعه یافته به صورت زیر می‌باشد:

خروجی مدل را بصورت زیر داریم (Zolghadri et al., 2006):

$$\hat{y}_{k+1} = \Phi(\hat{y}_k, y_k, u_k, \hat{u}_{k+1}, \hat{\theta}_k) \quad (19)$$

که Φ تابع خطی یا غیرخطی، u نشان دهنده متغیرهای ورودی، k توصیف کننده زمان (ساعت جاری) و θ بردار پارامترهای آزاد و $\hat{\theta}$ تخمین θ ناشی از برخی روندهای بهینه‌سازی می‌باشد. برای انتخاب ساختار مدل از یک روش تجربی استفاده شده است. مدل بکار گرفته شده بصورت زیر می‌باشد:

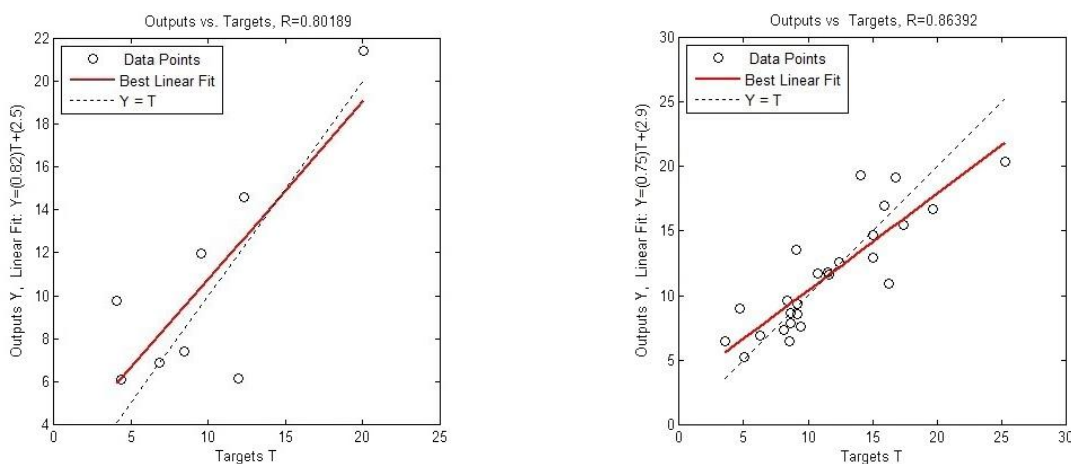
است. ضریب همبستگی بین مقادیر هدف و خروجی (R) در حالت ایده آل برابر یک است که در اینجا برای داده‌ی آموزش $R=0/۸۶۳۹۲$ و برای داده‌ی آزمایش $R=0/۸۰۱۸۹$ می‌باشد. در روش شبکه عصبی به دلیل در اختیار نبودن داده‌های آلودگی فقط امکان مدل‌سازی در ساعات ۸ و ۱۱ فراهم بود به همین دلیل از کالمن برای تخمین ساعات دیگر استفاده می‌کنیم.

در جدول ۳ خطای حداقل مربعات روش فیلتر کالمن و فیلتر کالمن توسعه یافته برای سه متغیر CO و NO_2 و SO_2 مربوط به خیابان‌های شهر شیراز بطور خلاصه آورده شده است. همانطور که مشاهده می‌شود روش فیلتر کالمن توسعه یافته بهبود قابل توجهی نسبت به روش فیلتر کالمن دارد.

تغییر داده تا جایی که مشخص شود با کدام پارامترها بهترین تخمین صورت می‌گیرد. پارامترها در مدل انعطاف‌پذیری کمی دارند و تغییرات قابل توجهی در طول روزرسانی ندارند.

نتایج و بحث

نتایج مربوط به یادگیری و آزمایش شبکه عصبی برای آلاینده CO به عنوان نمونه آورده شده است. در این نمودارها محور افقی نشان دهنده مقدار هدف و محور عمودی نشان دهنده مقادیر خروجی است. نمودار آموزش و آزمایش شبکه‌ی عصبی را در شکل ۱ مشاهده می‌کنید. برای داشتن رفتار خوب باید خط درخور^{۱۱} بر خط $Y = T$ منطبق شود و نقاط داده بر روی آنها سوار شود. در اینجا به دلیل کم بودن داده‌ها این تطبیق به خوبی انجام نشده



شکل ۱- نمودار آموزش (سمت راست) و آزمایش (سمت چپ) برای آلاینده CO
 Fig. 1 - Train diagram (right hand side) and test diagram (left hand side) for CO pollution

جدول ۳- خطای حداقل مربعات برای دو روش فیلتر کالمن و فیلتر کالمن توسعه یافته مربوط به شهر شیراز

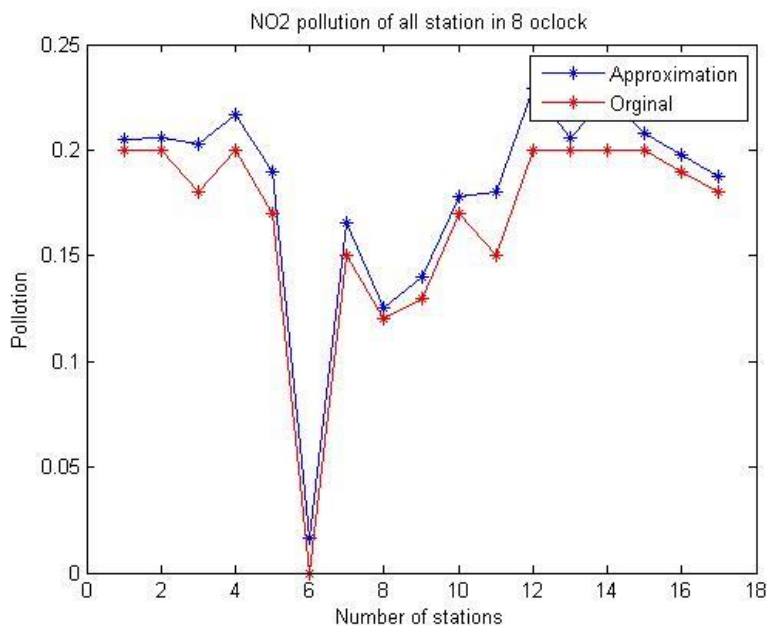
Table 3- Minimum quadratic error for both Kalman filter and extended Kalman filter for Shiraz city

همه CO ایستگاه‌ها در ساعت ۸ صبح CO of all station at 8 am	همه NO_2 ایستگاه‌ها در ساعت ۸ صبح NO_2 of all stations at 8 am	همه SO_2 ایستگاه‌ها در ساعت ۸ صبح SO_2 of all stations at am	همه ایستگاه‌ها در ساعت ۱۱ صبح CO of all stations at 11 am	همه ایستگاه‌ها- ها در ساعت ۱۱ صبح NO_2 of all stations at 11 am	همه ایستگاه‌ها در ساعت ۱۱ صبح SO_2 of all stations at 11 am	خطا Error
0.0011	0.0865	0.0514	8.6687×10^{-4}	0.0261	0.0383	KF
2.0459×10^{-5}	3.6681×10^{-8}	5.9982×10^{-11}	3.125×10^{-7}	2.5138×10^{-8}	2.7846×10^{-11}	EKF

در نمودار شکل ۲ داده‌های واقعی و تخمین آلاینده NO_2 در ساعت ۸ صبح برای ۱۷ ایستگاه آورده شده است. مشاهده می‌شود که برای این ساعت‌ها مقادیر تخمین زده شده بر مقادیر واقعی منطبق نمی‌شود، اما رفتار این آلاینده را با مقدار ناچیزی خطا دنبال می‌کند. این مشکل در SO_2 با کیفیت کمتری دنبال می‌شود. این مشکل در فیلتر کالمن توسعه یافته برطرف شده و تخمین آلودگی با کیفیت و دقت انجام شده است.

در مدل فیلتر کالمن توسعه یافته به ازای هر کدام از ۵۶۱ پارامتر مورد نیاز برای مدل‌سازی یک معادله بکاربرده شده است.

برای مشخص شدن بهتر این نتیجه به عنوان مثال نمودار آلاینده NO_2 (شکل ۲) برای ساعت ۸ صبح آورده شده است. ماتریس کواریانس R و Q برای ماتریس-های توصیف کواریانس W و V بصورت ماتریس قطری می‌باشد که درایه‌های روی قطر آن به روش سعی و خطا بدست آمده است. در روش خطی به دلیل دقت پایین مدل با زیاد کردن ضرائب ماتریس Q دقت مدل را پایین آورده و بالعکس با کمتر کردن ضرائب ماتریس R دقت داده‌های ورودی را زیاد فرض می‌کنیم. تعداد ستون‌های ماتریس‌های توصیف کواریانس برابر است با تعداد ورودی که در اینجا ایستگاه‌ها می‌باشند و ستون‌ها برابر ۲۴ (یک شبانه روز) در نظر گرفته شده است.



شکل ۲- نمودار داده‌های واقعی و تخمین آلاینده NO_2 در ساعت ۸ صبح (فیلتر کالمن خطی)
Fig. 2 - NO_2 graph of Real and estimated data pollutants at 8 am (linear Kalman filter)


شد. مقدار آلودگی تخمین زده شده برای CO بیشتر از دو آلاینده‌ی دیگر است که این موضوع با داده‌های واقعی جمع‌آوری شده هم‌خوانی دارد.

در ادامه نمودار آلاینده‌ها به تفکیک برای ساعت ۸ و ۱۱ صبح مورد بررسی قرار گرفته که به عنوان نمونه نمودار CO در ساعت ۸ صبح آورده شده است. هم‌چنین مقادیر تخمین CO برای یک ایستگاه دلخواه آورده شده

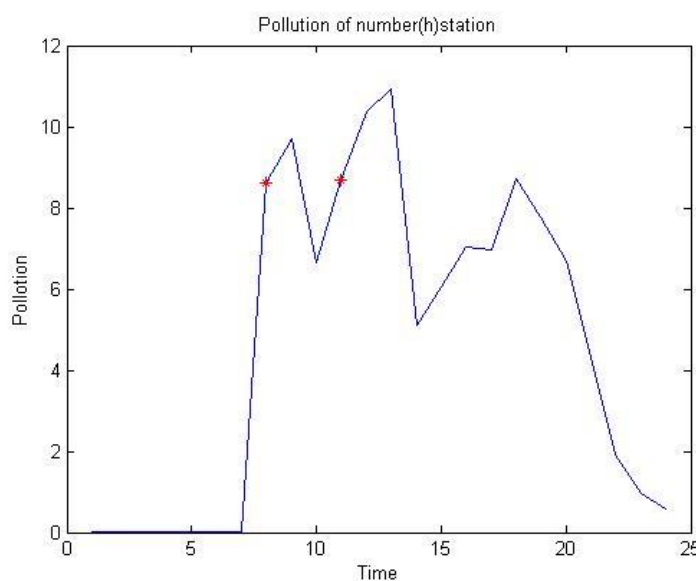
از آنجا که داده‌های خروجی برای آلاینده در ساعات ۸ و ۱۱ در دسترس بود، ابتدا به بررسی صحت کارکرد مدل در این ساعات پرداخته شده و سپس با استفاده از مدل معرفی شده مقادیر آلاینده‌ها برای ساعات دیگر تخمین زده شده است. مدل در ساعت ۸ صبح در تمام ایستگاه‌ها به خوبی توانسته مقادیر آلاینده‌ها را تخمین می‌زند. همین نتیجه برای ساعت ۱۱ نیز مشاهده

ساعت برای ایستگاه شماره ۱۱ آورده شده است که مدل رفتار آلاینده CO را به خوبی دنبال کرده است. در ساعات ابتدایی به دلیل حجم ترافیک بسیار کم آلودگی بسیار ناچیز خواهد بود. افزایش آلودگی در ساعات اوج ترافیک با افزایش آلاینده‌ها همراه بوده است.

است که در ادامه به بررسی نتایج آن پرداخته می‌شود. در شکل ۳ نمودار داده‌های واقعی و تخمین آلاینده CO در ساعت ۸ صبح برای ۱۷ ایستگاه آورده شده است. مشاهده می‌شود که برای این ساعت‌ها مدل به خوبی رفتار این آلاینده را دنبال می‌کند. در شکل ۴ نمودار داده‌های واقعی و تخمین آلاینده CO در ۲۴



شکل ۳- نمودار داده‌های واقعی و تخمین آلاینده CO در ساعت ۸ صبح
 Fig. 3 - Diagram of real and estimated data of CO pollution at 8 am



شکل ۴- نمودار داده‌های واقعی و تخمین آلاینده CO در ۲۴ ساعت در ایستگاه شماره ۱۱ (h=11) (نادر- اولین تقاطع بعد از چهارراه پانزده خرداد)

Fig. 4 - Diagram of real and estimated CO pollutant at station number 11 over 24 hours

نتیجه‌گیری

مدل می‌تواند به راحتی با اضافه یا کم کردن متغیر جدید انجام گیرد. از طرفی در صورت در اختیار داشتن داده‌های متناظر با هر ایستگاه جدید دیگر می‌توان بر راحتی مطالعات را برای نقاط دیگر شهر شیراز بسط داد. به این ترتیب اگر ترافیک در بعضی نقاط شهر شیراز در دسترس باشد، می‌توان با بعضی مانورهای ترافیکی آلودگی را به سمت‌های دیگر بسط داده و در مناطق بحرانی کاهش داد.

تشکر و قدردانی

از معاونت محترم حمل و نقل و ترافیک شهرداری شیراز به خاطر تامین داده‌های مرتبط با ترافیک شهر شیراز و از سازمان هواشناسی شهر شیراز به خاطر در اختیار قرار دادن داده‌های هواشناسی شهر شیراز کمال تشکر و قدردانی را داریم.

پی‌نوشت

- ¹ Linear Quadratic Estimation
- ² Self-Learning
- ³ Net Function
- ⁴ Activation Function
- ⁵ Radial Bases Function
- ⁷ Multi-Layer Perceptron
- ⁸ Linear Quadratic Estimation
- ⁹ Kalman Gain
- ¹⁰ Single Input Single Output
- ¹¹ Extended Kalman Filter
- ¹² Best Linear Fit

برای داشتن مدلی مناسب که بتواند به خوبی سهم ترافیک را در آلودگی هوا با توجه به داده‌های ترافیکی تخمین بزند، عموماً به شناخت از پارامترهای مدل - همچون عوامل انتشار و شرایط هواشناسی نیازمندیم. در عین حال داشتن چنین مدلی می‌تواند به مدیریت بهتر ترافیک و آلودگی هوا منجر شود. در این مقاله به مدل - سازی آلودگی هوای شهر شیراز به کمک داده‌های ترافیکی و هواشناسی در یک روز مشخص از پاییز پرداخته شده است. مدل‌سازی به دو روش شبکه‌ی عصبی و فیلتر کالمن انجام شده است. در روش فیلتر کالمن مدل‌سازی با دو روش خطی و غیرخطی انجام گرفته است که مدل - سازی غیرخطی تخمین‌های واقعی‌تر و قابل قبول‌تری دارد. در این کار به بررسی داده‌های ترافیکی و داده‌های آلودگی ناشی از غلظت آلاینده‌ها پرداخته شده، سپس تلاش شده است که داده‌های آلودگی با نقاط معنی‌دار شهر شیراز تطبیق داده شود و بسیاری از داده‌های آلودگی و ترافیکی به دلیل عدم تطابق با یکدیگر از نظر مکانی حذف شدند. در نهایت مدل‌سازی بر اساس آن به‌نگام شده و نتیجه این مطالعات با نتایج واقعی تطبیق داده شد. این ساختار مدل غیرخطی استفاده تکاملی و انعطاف - پذیری را ارائه می‌دهد. به این معنا که ارزیابی کلی عملکرد

منابع

Hassan, A.A. and Crowther, J.M., 1998. Modelling of fluid flow and pollutant dispersion in a street canyon. *Environmental Monitoring and Assessment Journal*. 52:281-297.

Branis, M., 2009. Air quality of Prague traffic as a main pollution source. *Environmental monitoring and assessment Journal*. 156.1-4:377-390.

Kim, Y, and Guldman, J.M., 2011. Impact of traffic flows and wind directions on air pollution concentrations in Seoul, Korea. *Atmospheric*

Environment Journal. 45.16:2803-2810.

Gokhale, S., 2011. Traffic flow pattern and meteorology at two distinct urban junctions with impacts on air quality. *Atmospheric Environment Journal*. 45.10:1830-1840.

Keuken, M.P., 2012. Elemental carbon as an indicator for evaluating the impact of traffic measures on air quality and health. *Atmospheric Environment Journal*. 61:1-8.

Marsik T. and Johnson, R., 2010. Model for Estimation of Traffic Pollutant Levels in Northern Communities. *Journal of the Air & Waste Management Association*. 60 (11):1335-1340.

Zolghadri, A. and Cazaurang, F., 2006. Adaptive nonlinear state-space modelling for the prediction of daily mean PM10 concentrations. *Environmental Modelling & Software Journal*. 21, (6):885-894.

Safavi, A.A, 1996. Wavelet-based neural network and multiresolution analysis with applications to process systems engineering. Ph.D.: Dept. of Chemical Eng., the University of Sydney, Australia.

Haykin, S., 1999. *Neural networks-a comprehensive foundation*. 2nd Ed, Prentic-Hall.

Ding, X., Canu S. and Denceux, T., 1996. Neural network model for forecasting. *Neural networks and their applications*, In J. G. Taylor, Ed., John Wiley and Sons. pp 153-167.

Winer, N, 1949. *Extrapolation, Introduction, and Smoothing of Stationary Time Series*. New York. Wiley.

Kalman, R.E.A., 1960. New Approach to Linear Filtering and Prediction Problems. *Trans. ASME-J. Basic Eng.*, 35-45.

Brown, R.G., 2007. Hwang P. Y. C. *Introduction to Random signals and applied Kalman Filtering*. Wiley, 4th Ed.

Young, P.C. and Ng C.N., 1992. Lane K, Parker D. Recursive forecasting, smoothing and seasonal adjustment of non-stationary environmental data. *Journal of Forecasting*. 10: 57-89.





Environmental Sciences Vol.15 / No.1 / Spring 2017

157-174

Effect of traffic flow modelling on air pollution in Shiraz city

Razieh Ghanbari Fard, Ali Akbar Safavi* and Peyman Setoodeh

Department of Power and Control Engineering, School of Electrical and Computer Engineering, Shiraz University, Shiraz

Received: September 4, 2016

Accepted: May 6, 2017

Ghanbari Fard, R., Safavi A.A. and Setoodeh, P. 2017. Effect of traffic flow modelling on air pollution in Shiraz city. *Environmental Sciences*. 15(1):157-174.

Introduction: Transportation and traffic flows are the main factors of air pollution in Iran. Therefore it is essential to investigate their effects on the air quality of urban areas to forecast more accurately and manage better traffic and pollution. Unfortunately, not much research has been conducted on this issue in Iran. Identification of pollutant sources is the most important and time-consuming stage of air pollution modelling. We cannot consider only one variable for air pollution modelling in a single region. Hence, different variables should be taken into account, studied and planned. Some measures make significant changes in the air pollution of a metropolis. Hence, undertaking a series of measures can reduce the air pollution, and adopting new methods to evaluate the air pollution is one of these measures. The main goal of this research is to offer a smart model by which concentration of pollutants such as CO can be estimated with the appropriate accuracy and, by examining the causes of these pollutants and predicting the air pollution, the necessary actions to manage and control the air pollution can be planned (Hassan and Croether, 1998).

Materials and methods: In this paper, a neural network model and a nonlinear state space model were designed based on urban traffic in Shiraz. In these models the concentrations of CO, NO₂ and SO₂ pollutants were analyzed and also estimated using a Kalman Filter for a 24 hour cycle. The models are based on the correlation between the volume of pollution, traffic, initial pollution and meteorological information. The extended Kalman Filter algorithm was used to analyse and predict the air pollution in Shiraz over a 24 hour period. A key factor of the proposed system is its adaptation with the short time pollution changes (Safavi, 2008; Brown *et al.*, 2007).

Result and discussion: In this research, traffic and pollution data caused by pollutant concentrations has been studied, then an attempt was made to match these air pollution data with significant parts in Shiraz city and many traffic and pollution data were excluded due to a mismatch in terms of location. Finally, modelling was updated based on this data and the result was adapted to real data. This nonlinear model structure offers the

* Corresponding Author. *E-mail Address:* Safavi@Shirazu.ac.ir

advantage of being evolutionary and sufficiently flexible, in the sense that the overall evaluation of the model performance can easily be undertaken by excluding or adding input variables. On the other hand, if the corresponding data of each new station is available, the study can be extended to other parts of Shiraz city. So, if traffic data is available in some parts of the city, the pollution can be extended to some other parts and be reduced in critical areas using certain traffic strategies.

Conclusion: The neural network method and the Kalman Filter were tested on Shiraz pollution data which revealed that the models, specially the Kalman Filter, work reasonably well.

Keywords: Modelling, Air pollution, Traffic, Neural Network, Kalman Filter.

