


بسم الله الرحمن الرحيم



دانشگاه حکیم سبزواری

دانشکده جغرافیا و علوم محیطی

پایان نامه جهت دریافت درجه کارشناسی ارشد رشته مهندسی منابع طبیعی - گرایش محیط‌زیست

پیش‌بینی زمانی کیفیت هوا با استفاده از شاخص‌های پایداری و

ناپایداری جو و شبکه عصبی مصنوعی، مطالعه موردی: تهران

استاد راهنما:

دکتر مجتبی هادوی فر

دکتر مظاهر معین‌الدینی

استاد مشاور:

دکتر محمود امین طوسی

پژوهشگر:

راضیه فرهادی

شهریور 1395



فرم ارزشیابی و صورتجلسه دفاع از پایان نامه کارشناسی ارشد\*

جلسه دفاع از پایان نامه آقای/ خانم راضیه فرهادی دانشجوی رشته منابع طبیعی گرایش محیطزیست به شماره دانشجویی 9323202036 با عنوان پیش‌بینی زمانی کیفیت هوا با استفاده از شاخص‌های پایداری و ناپایداری جو و شبکه عصبی مصنوعی، مطالعه موردی: تهران در مورخه ..... در دانشکده جغرافیا تشکیل و توسط هیات داوران مورد ارزشیابی قرار گرفت و نمره ..... برابر درجه ..... برای آن تعیین گردید. به این ترتیب از این تاریخ خانم راضیه فرهادی به‌عنوان کارشناس ارشد در رشته مذکور شناخته می‌شود.

Table with 4 columns: موارد ارزشیابی, موارد, حداکثر نمره, نمره کسب شده. Rows include: 1- کیفیت نگارش, 2- کیفیت علمی, 3- کیفیت ارایه در جلسه دفاع, 4- ارزشیابی گزارشات, 5- خروجی پایان نامه.

درجه معادل کسب شده: (از 19 تا 20 عالی) □ از 18 تا 18/99 بسیار خوب □ از 16 تا 17/99 خوب □ از 14 تا 15/99 قابل قبول □ کمتر از 14 غیر قابل قبول □

مشخصات هیات داوران

Table with 6 columns: ردیف, نام و نام خانوادگی, سمت, مرتبه علمی, محل کار, امضاء. Rows list 4 members: دکتر مجتبی هادوی فر, دکتر مظاهر معین‌الدینی, دکتر محمود امین طوسی, دکتر قاسم ذوالفقاری, دکتر هادی سلطانی فرد.

امضاء  
رئیس دانشکده

امضاء  
مدیر گروه

\* این فرم الزاما باید به صورت تایپ شده تهیه، ارسال و در پایان نامه درج شود



## سوگندنامه دانش آموختگان دانشگاه حکیم سبزواری

به نام خداوند جان و خرد

کزین برتر اندیشه بر نگذرد

اینک که به خواست آفریدگار پاک، کوشش خویش و بهره گیری از دانش استادان و سرمایه های مادی و معنوی این مرز و بوم، توشه ای از دانش و خرد گردآورده ام، در پیشگاه خداوند بزرگ سوگند یاد می کنم که در به کارگیری دانش خویش، همواره بر راه راست و درست گام بردارم. خداوند بزرگ، شما شاهدان، دانشجویان و دیگر حاضران را به عنوان داورانی امین گواه می گیرم که از همه دانش و توان خود برای گسترش مرزهای دانش بهره گیرم و از هیچ کوششی برای تبدیل جهان به جایی بهتر برای زیستن، دریغ نورزم. پیمان می بندم که همواره کرامت انسانی را در نظر داشته باشم و ممنوعان خود را در هر زمان و مکان تا سر حد امکان یاری دهم. سوگند می خورم که در به کارگیری دانش خویش به کاری که با راه و رسم انسانی، آیین پرهیزگاری، شرافت و اصول اخلاقی برخاسته از ادیان بزرگ الهی، به ویژه دین مبین اسلام، مابینت دارد دست نیازم. همچنین در سایه اصول جهان شمول انسانی و اسلامی، پیمان می بندم از هیچ کوششی برای آبادانی و سرافرازی میهن و هم میهنانم فروگذاری نکنم و خداوند بزرگ را به یاری طلبم تا همواره در پیشگاه او و در برابر وجدان بیدار خویش و ملت سرافراز، بر این پیمان تا ابد استوار بمانم.

نام و نام خانوادگی و امضای دانشجو

راضیه فرهادی

## تاییدیه ی صحت و اصالت نتایج

بسمه تعالی

اینجانب راضیه فرهادی به شماره دانشجویی **9323202036** رشته مهندسی منابع طبیعی\_محیط زیست مقطع تحصیلی کارشناسی ارشد تأیید می نمایم که کلیه نتایج این پایان نامه حاصل کار اینجانب و بدون هرگونه دخل و تصرف و موارد نسخه برداری شده از آثار دیگران را با ذکر کامل مشخصات منبع ذکر کرده ام در صورت اثبات خلاف مندرجات فوق به تشخیص دانشگاه مطابق با ضوابط و مقررات حاکم (قانون حمایت از حقوق مولفان و مصنفان ، قانون ترجمه و تکثیر کتب و نشریات و آثار صوتی ضوابط و مقررات آموزشی پژوهشی و انضباطی ...) با اینجانب رفتار خواهد شد. و حق هرگونه اعتراض در خصوص احقاق حقوق مکتسب و تشخیص و تعیین تخلف و مجازات را از خویش سلب می نمایم. در ضمن مسئولیت هرگونه پاسخگویی به اشخاص اعم از حقیقی و حقوقی و مراجع ذی صلاح (اعم از اداری و قضایی ) به عهده اینجانب خواهد بود و دانشگاه هیچ گونه مسئولیتی در این خصوص نخواهد داشت.

نام و نام خانوادگی

راضیه فرهادی

تاریخ و امضاء:

سپاس مخصوص خداوند مهربان که به انسان توانایی و دانایی بخشید تا به بندگانش شفقت ورزد، مهربانی کند و در حل مشکلاتشان یاری شان نماید. از راحت خویش بگذرد و آسایش هم نوعان را مقدم دارد، با او معامله کند و در این خلوص انباز نگیرد و خوش باشد که پروردگار سمیع و بصیر است سپاس ایزد منان که به من این فرصت را داد تا به این مرحله از علم رسیده و از هیچ محبتی دریغ نکرد و در تمام مراحل زندگی مرا قوت قلب بود.

به پاس تعبیر عظیم و انسانی شان از کلمه ایثار و از خودگذشتگان

به پاس عاطفه سرشار و گرمای امیدبخش وجودشان که در این سردترین روزگاران بهترین پشتیبان است

به پاس قلب های بزرگشان که فریاد رس است و سرگردانی و ترس در پناهشان به شجاعت می گراید

و به پاس محبت های بی دریغشان که هرگز فروکش نمی کند

این مجموعه را به مادر و برادر عزیزم تقدیم می کنم

با تقدیر و درود فراوان خدمت استادان بسیار عزیز، دلسوز و فداکارم که پیوسته جرعه نوش جام تعلیم و تربیت، فضیلت و انسانیت آنها بوده ام و همواره چراغ وجودشان روشنگر راه من در سختی ها و مشکلات بوده است.

از استادان گرامی جناب آقای دکتر مجتبی هادوی فر و جناب آقای دکتر مظاهر معین الدینی بسیار سپاسگزارم چرا که بدون راهنماییهای ایشان تامین این پایان نامه بسیار مشکل می نمود.

از استاد عالی قدرم جناب آقای دکتر محمود امین طوسی که با سعه صدر زحمت مشاوره این پایان نامه را پذیرفتند و در طول نگارش این مجموعه همواره از نظرات کارشناسانه شان، بهره جستیم، قدردانی و تشکر می نمایم.

و همچنین از آقای صبر نهایت سپاس و تشکر را دارم که در تکمیل داده ها به من کمک فراوانی نمودند.

## فهرست مطالب

چکیده: 1

فصل اول: مقدمه ..... 2

1-1 بیان مسئله، اهمیت و ضرورت تحقیق ..... 2

2-1 اهداف پژوهش ..... 7

3-1 سوالات پژوهش ..... 7

4-1 فرضیه ..... 7

فصل دوم: مبانی نظری ..... 8

1-2 مقدمه ..... 8

2-2 آلودگی هوا ..... 8

3-2 آلاینده های شاخص ..... 8

1-3-2 مونوکسیدکربن ..... 9

2-3-2 ذرات معلق ..... 9

4-2 روش پیش بینی آلاینده

ها ..... 9

1-4-2 روش های پیش بینی غیر رگرسیونی ..... 10

1-1-4-2 روش میانگین ساده ..... 10

2-1-4-2 روش میانگین متحرک ..... 10

3-1-4-2 روش میانگین متحرک با روند خطی ..... 10

4-1-4-2 روش رهیافت تعدیل نمایی یگانه ..... 10

2-4-2 روش های پیش بینی رگرسیونی ..... 10

1-2-4-2 آریمما ..... 10

2-2-4-2 رگرسیون خطی چندگانه ..... 11

3-2-4-2 شبکه عصبی مصنوعی ..... 11

1-3-2-4-2 تعریف شبکه ..... 11

**Error! Bookmark not defined.** ..... 2-3-2-4-2 شبکه عصبی زیستی

3-3-2-4-2 تعریف شبکه عصبی مصنوعی ..... 11

- 13.....انواع شبکه عصبی مصنوعی 4-3-2-4-2
- Error! Bookmark not defined.**..... ساختار شبکه عصبی مصنوعی 5-3-2-4-2
- 14.....مزایای شبکه عصبی 6-3-2-4-2
- 14.....معایب شبکه عصبی 7-3-2-4-2
- 15.....کاربرد شبکه های عصبی مصنوعی 8-3-2-4-2
- 15.....کاربرد شبکه های عصبی مصنوعی در علوم زیست محیطی 9-3-2-4-2
- 5-2 پیشینه
- 15.....تحقیق
- 19.....فصل سوم : مواد و روش ها
- 19.....1-3 منطقه مورد مطالعه
- 21.....2-3 روش انجام تحقیق
- 21.....1-2-3 نقاط نمونه گیری
- 21.....1-1-2-3 ایستگاههای هواشناسی
- 21.....2-1-2-3 ایستگاههای سنجش کیفیت هوا
- 22.....3-3 تبدیل مقدار داده ها به میانگین روزانه
- 22.....4-3 شاخص های پایداری و ناپایداری
- 22.....5-3 شاخص کیفیت هوا
- 6-3 تجزیه و تحلیل
- 25.....آمار
- 7-3 آنالیز
- 25.....حساسیت
- 25.....8-3 مدلسازی
- 26.....1-8-3 شبکه عصبی مصنوعی
- 26.....1-1-8-3 ورودی های شبکه
- 26.....2-1-8-3 استاندارد کردن داده ها
- 26.....3-1-8-3 دسته بندی داده ها
- 27.....4-1-8-3 توابع متحرک

- 3-8-1-4-1 تابع انتقال سیگموئید.....27
- 3-8-1-5 معماری و الگوریتم آموزش شبکه .....27
- 3-8-1-6 ارزیابی مدل .....30
- فصل چهارم : تجزیه و تحلیل داده‌ها و نتایج.....32
- 1-4 جمع‌آوری داده‌ها و مدلسازی .....32
- 2-4 نتایج حاصل از آنالیز حساسیت.....32
- 3-4 شبیه سازی غلظت PM10 و CO و AQI بر اساس همه پارامترهای هواشناسی و شاخص های پایداری و ناپایداری با استفاده از مدل شبکه عصبی .....33
- 1-3-4 نتایج حاصل از شبیه سازی غلظت CO با استفاده از مدل شبکه عصبی مصنوعی .....33
- 1-1-3-4 نتایج حاصل از شبیه سازی غلظت CO با پارامترهای هواشناسی و شاخص های پایداری و ناپایداری .....33
- 4-1-3-2 نتایج حاصل از شبیه سازی غلظت CO با پارامترهای هواشناسی و شاخص های پایداری و ناپایداری برای فصول گرم.....36
- 4-1-3-3 نتایج حاصل از شبیه سازی غلظت CO با پارامترهای هواشناسی و شاخص های پایداری و ناپایداری برای فصول سرد.....37
- 2-3-4 نتایج حاصل از شبیه سازی غلظت PM10 با استفاده از مدل شبکه عصبی مصنوعی .....40
- 1-2-3-4 نتایج حاصل از شبیه سازی غلظت PM10 با پارامترهای هواشناسی و شاخص های پایداری و ناپایداری .....40
- 2-2-3-4 نتایج حاصل از شبیه سازی غلظت PM10 با پارامترهای هواشناسی و شاخص های پایداری و ناپایداری برای فصول گرم .....42
- 3-2-3-4 نتایج حاصل از شبیه سازی غلظت PM10 با پارامترهای هواشناسی و شاخص های پایداری و ناپایداری برای فصول سرد.....44
- 3-3-4 نتایج حاصل از شبیه سازی AQI با استفاده از مدل شبکه عصبی مصنوعی .....46
- 1-3-3-4 نتایج حاصل از شبیه سازی AQI با پارامترهای هواشناسی و شاخصهای پایداری و ناپایداری .....46
- 2-3-3-4 نتایج حاصل از شبیه سازی AQI با پارامترهای هواشناسی و شاخصهای پایداری و ناپایداری برای فصول گرم ..47
- 3-3-3-4 نتایج حاصل از شبیه سازی AQI با پارامترهای هواشناسی و شاخصهای پایداری و ناپایداری برای فصول سرد ..50
- 4-4 شبیه سازی غلظت PM10 و CO و AQI بر اساس فقط پارامترهای هواشناسی با استفاده از مدل شبکه عصبی .....51
- 1-4-4 نتایج حاصل از شبیه سازی غلظت CO با استفاده از مدل شبکه عصبی مصنوعی .....51
- 1-1-4-4 نتایج حاصل از شبیه سازی غلظت CO با پارامترهای هواشناسی برای کل سال .....51
- 2-1-4-4 نتایج حاصل از شبیه سازی غلظت CO با پارامترهای هواشناسی برای فصول گرم .....54
- 3-1-4-4 نتایج حاصل از شبیه سازی غلظت CO با پارامترهای هواشناسی برای فصول سرد .....55



- 58..... 2-4-4 نتایج حاصل از شبیه سازی غلظت PM<sub>10</sub> با استفاده از مدل شبکه عصبی مصنوعی
- 58..... 1-2-4-4 نتایج حاصل از شبیه سازی غلظت PM<sub>10</sub> با فقط پارامترهای هواشناسی برای کل سال
- 59..... 2-2-4-4 نتایج حاصل از شبیه سازی غلظت PM<sub>10</sub> با فقط پارامترهای هواشناسی برای فصول گرم
- 62..... 3-2-4-4 نتایج حاصل از شبیه سازی غلظت PM<sub>10</sub> با فقط پارامترهای هواشناسی برای فصول سرد
- 63..... 3-4-4 نتایج حاصل از شبیه سازی AQI با استفاده از مدل شبکه عصبی مصنوعی
- 63..... 1-3-4-4 نتایج حاصل از شبیه سازی AQI با فقط پارامترهای هواشناسی برای کل سال
- 66..... 2-3-4-4 نتایج حاصل از شبیه سازی AQI با فقط پارامترهای هواشناسی برای فصول گرم
- 67..... 3-3-4-4 نتایج حاصل از شبیه سازی AQI با فقط پارامترهای هواشناسی برای فصول سرد
- 70..... 5-4 بررسی غلظت CO و PM<sub>10</sub> و AQI در روزهای هفته و پایان هفته
- 70..... 1-5-4 بررسی غلظت CO در روزهای هفته و پایان هفته
- 71..... 2-5-4 بررسی غلظت PM<sub>10</sub> در روزهای هفته و پایان هفته
- 71..... 3-5-4 AQI در روزهای هفته و پایان هفته

بررسی

- 72..... 6-4 : بحث
- 74..... 7-4 : محدودیت های پژوهش
- 7..... منابع
- 5
- 81..... پیوست الف

### فهرست جداول

- جدول 1-1: منابع آلاینده های اولیه..... 3
- جدول 3-1: ایستگاههای هواشناسی مورد مطالعه در شهر تهران.....  
21...
- جدول 3-2: ایستگاههای سنجش کیفیت هوای مورد مطالعه در شهر تهران ..... 22
- جدول 3-3: طبقات غلظت آلاینده ها جهت محاسبات شاخص کیفیت هوا ..... 23
- جدول 3-4: نقاط شکست آلاینده‌گی در محاسبه شاخص کیفیت  
هوا..... 23
- جدول 4-1: میزان همبستگی  $CO$ ,  $PM_{10}$ ,  $AQI$  با پارامترهای هواشناسی و شاخص های پایداری و ناپایداری ..... 33

### فهرست نمودارها

- نمودار 2-1: یک تقسیم بندی از معماری شبکه عصبی مصنوعی ..... 13
- نمودار 3-4: نمودار جریانی روش تحقیق ..... 31

### فهرست روابط

- رابطه 1-1: فرمول شاخص انرژی پتانسل فرارفتی ..... 5
- رابطه 1-2: فرمول شاخص شوالتر ..... 6

- رابطه 1-3: فرمول شاخص K..... 6
- رابطه 1-4: فرمول شاخص هوای  
مخرب..... 6
- رابطه 1-5: فرمول شاخص TT..... 7
- رابطه 1-2: فرمول رگرسیون خطی  
چندگانه..... 11
- رابطه 3-1: فرمول محاسبه شاخص کیفیت هوا ..... 22
- رابطه 3-2: فرمول نرمال سازی داده ها ..... 26
- رابطه 3-3: فرمول تابع انتقال سیگموئید..... 27
- رابطه 3-4: فرمول ورودی شبکه عصبی ..... 28
- رابطه 3-5: فرمول شبکه عصبی ..... 28
- رابطه 3-6: معادله لونبرگ مارکوات ..... 28
- رابطه 3-7: فرمول RMSE
- ..... 30
- رابطه 3-8: فرمول ضریب  
همبستگی..... 30

### فهرست اشکال

- شکل 2-1: ساختار شبکه عصبی زیستی و شبکه عصبی مصنوعی ..... 12
- شکل 2-2: ساختار شبکه عصبی مصنوعی ..... 14
- شکل 3-1: ایستگاه تحت نظارت شرکت کنترل کیفیت هوای تهران ..... 20
- شکل 3-2: پراکندگی ایستگاههای پایش کیفیت هوا و هواشناسی سینوپتیکی و کليماتولوژی شهر تهران ..... 20
- شکل 3-3: فرایند پیش بینی شبکه عصبی مصنوعی ..... 29
- شکل 3-4: شمایی از شبکه عصبی مصنوعی مورد استفاده در این تحقیق ..... 29
- شکل 4-1: شبیه سازی غلظت CO برای سه روز بعد با پارامترهای هواشناسی و شاخص های پایداری و ناپایداری ..... 35
- شکل 4-2: شبیه سازی غلظت CO برای سه روز بعد با پارامترهای هواشناسی و شاخص های پایداری و ناپایداری برای فصول  
گرم ..... 36

|  |    |
|--|----|
| شکل 4-3: شبیه سازی غلظت CO برای سه روز بعد با پارامترهای هواشناسی و شاخص های پایداری و ناپایداری برای فصول سرد.....                | 39 |
| شکل 4-4: شبیه سازی غلظت PM <sub>10</sub> برای سه روز بعد با پارامترهای هواشناسی و شاخص های پایداری و ناپایداری .....               | 41 |
| شکل 4-5: شبیه سازی غلظت PM <sub>10</sub> برای سه روز بعد با پارامترهای هواشناسی و شاخص های پایداری و ناپایداری برای فصول گرم.....  | 42 |
| شکل 4-6: شبیه سازی غلظت PM <sub>10</sub> برای سه روز بعد با پارامترهای هواشناسی و شاخص های پایداری و ناپایداری برای فصول سرد ..... | 45 |
| شکل 4-7: شبیه سازی AQI برای سه روز بعد با پارامترهای هواشناسی و شاخص های پایداری و ناپایداری .....                                 | 46 |
| شکل 4-8: شبیه سازی AQI برای سه روز بعد با پارامترهای هواشناسی و شاخص های پایداری و ناپایداری برای فصول گرم .....                   | 49 |
| شکل 4-9: شبیه سازی AQI برای سه روز بعد با پارامترهای هواشناسی و شاخص های پایداری و ناپایداری برای فصول سرد .....                   | 50 |
| شکل 4-10: شبیه سازی غلظت CO برای سه روز بعد با پارامترهای هواشناسی .....   | 53 |
| شکل 4-11: شبیه سازی غلظت CO برای سه روز بعد با پارامترهای هواشناسی برای فصول گرم .....   | 54 |
| شکل 4-12: شبیه سازی غلظت CO برای سه روز بعد با پارامترهای هواشناسی برای فصول سرد .....   | 57 |
| شکل 4-13: شبیه سازی غلظت PM <sub>10</sub> برای سه روز بعد با پارامترهای هواشناسی .....   | 58 |
| شکل 4-14: شبیه سازی غلظت PM <sub>10</sub> برای سه روز بعد با پارامترهای هواشناسی برای فصول گرم .....                               | 61 |
| شکل 4-15: شبیه سازی غلظت PM <sub>10</sub> برای سه روز بعد با پارامترهای هواشناسی برای فصول سرد.....                                | 62 |
| شکل 4-16: شبیه سازی AQI برای سه روز بعد با پارامترهای هواشناسی .....   | 65 |
| شکل 4-17: شبیه سازی AQI برای سه روز بعد با پارامترهای هواشناسی برای فصول گرم.....  | 66 |
| شکل 4-18: شبیه سازی AQI برای سه روز بعد با پارامترهای هواشناسی برای فصول سرد .....   | 69 |
| شکل 4-19: غلظت CO در روزهای هفته و پایان هفته .....  | 70 |
| شکل 4-20: غلظت PM <sub>10</sub> در روزهای هفته و پایان هفته .....  | 71 |
| شکل 4-21: AQI در روزهای هفته و پایان هفته .....  | 72 |
| شکل الف- 1: یک نمونه روش بدست آوردن شاخص های پایداری و ناپایداری با داده های رادیو سوند .....                                      | 81 |
| شکل الف- 2: درصد تاثیر پارامترهای اقلیمی و شاخص های ناپایداری روی CO .....   | 81 |
| شکل الف- 3: درصد تاثیر پارامترهای اقلیمی و شاخص های ناپایداری روی PM <sub>10</sub> .....   | 82 |
| شکل الف- 4: درصد تاثیر پارامترهای اقلیمی و شاخص های ناپایداری روی AQI .....  | 82 |
| شکل الف- 5: تغییرات غلظت CO در سال های 2012 و 2013.....  | 83 |
| شکل الف- 6: تغییرات غلظت PM <sub>10</sub> در سال های 2012 و 2013 .....   | 83 |
| شکل الف- 7: تغییرات AQI در سال های 2012 و 2013 .....   | 84 |
| شکل الف- 8: تغییرات LCL در سال های 2012 و 2013.....  | 84 |

|    |  |
|----|--|
| 85 | شکل الف- 9: تغییرات S در سال های 2012 و 2013           |
| 85 | شکل الف- 10: تغییرات TT در سال های 2012 و 2013         |
| 86 | شکل الف- 11: تغییرات رطوبت نسبی در سال های 2012 و 2013 |
| 86 | شکل الف- 12: تغییرات جهت باد در سال های 2012 و 2013    |



## فرم چکیده پایان‌نامه‌ی دوره‌ی تحصیلات تکمیلی

### مدیریت تحصیلات تکمیلی

|   |                                   |                        |
|---|-----------------------------------|------------------------|
| نام خانوادگی دانشجو: فرهادی   | نام: راضیه                        | ش دانشجویی: 9323202036 |
| استاد راهنما: دکتر مجتبی هادوی‌فر   | استاد مشاور: دکتر محمود امین طوسی |                        |
| دانشکده: جغرافیا و علوم محیطی   | رشته: مهندسی منابع طبیعی          | گرایش: محیط‌زیست       |
| مقطع: کارشناسی ارشد   | تاریخ دفاع: 1395/6/17             | تعداد صفحات: .....     |
| عنوان پایان‌نامه: پیش‌بینی زمانی کیفیت هوا با استفاده از شاخص‌های پایداری و ناپایداری جو و شبکه عصبی مصنوعی، مطالعه موردی: تهران  |                                   |                        |
| کلیدواژه‌ها: پیش‌بینی کیفیت هوا، شاخص‌های پایداری و ناپایداری، شبکه عصبی مصنوعی   |                                   |                        |
| <b>چکیده:</b>   |                                   |                        |
| <p>پیشرفت تکنولوژی، افزایش روزافزون جمعیت و توسعه‌ی کلان‌شهرها، موجب آلودگی هوا شده و ایران و جهان را به چالش کشیده است که در تلاش برای پیدا کردن راه‌حلی مناسب برای آن می‌باشند. یکی از بهترین راه‌حل‌ها برای کاهش اثرات منفی آلاینده‌ها تعیین غلظت آلاینده‌ها و روش‌های پیش‌بینی کیفیت هوا با شبکه عصبی مصنوعی است. یکی از عوامل تأثیرگذار بر آلودگی هوا، پارامترهای هواشناسی است. در مطالعات گذشته از پارامترهای هواشناسی به‌طور گسترده‌ای در تخمین یا پیش‌بینی غلظت آلاینده‌ها به‌عنوان ورودی شبکه عصبی استفاده شده است ولی از داده‌های نیم‌رخ عمودی جو در تخمین میزان کیفیت هوا یا غلظت آلاینده‌های هوا استفاده نشده است. در مطالعه حاضر علاوه بر در نظر گرفتن پارامترهای معمول از داده‌های پایداری و ناپایداری استفاده شده است. هدف اصلی از انجام این پژوهش پیش‌بینی زمانی کیفیت هوا با شاخص‌های پایداری و ناپایداری با شبکه عصبی است. شبکه عصبی مصنوعی MLP با دو لایه پنهان و خروجی، با 10 نورون در لایه پنهان با تابع انتقال سیگموئید و الگوریتم لونیبرگ مارکوات (LMA) استفاده شد و برای ارزیابی عملکرد مدل از RMSE و R استفاده شد. برای ورودی شبکه یک‌بار از پارامترهای هواشناسی (TE, WS, WD) و غلظت آلاینده‌ها (AQI و PM<sub>10</sub>, CO) و یک‌بار هم از شاخص‌های ناپایداری (LCL, S و TT) و پارامترهای هواشناسی و غلظت آلاینده‌ها برای پیش‌بینی سه روز بعد برای فصول گرم و فصول سرد و کل سال استفاده شد. نتایج نشان داد که پیش‌بینی فردای آلاینده PM<sub>10</sub> برای فصول گرم، هم با پارامترهای هواشناسی (R=0/55, RMSE=22/24) و هم با پارامترهای شاخص ناپایداری و پارامترهای هواشناسی (R=0/80, RMSE=26/17) نسبت به CO بر حسب مقادیر پارامترهای هواشناسی (R=0/69, RMSE=0/66) و شاخص‌های ناپایداری و پارامترهای هواشناسی (R=0/64, RMSE=0/69) بهتر بود. همچنین این مطالعه نشان داد که نتایج PM<sub>10</sub> نسبت به مقادیر حاصله برای AQI برای پارامترهای هواشناسی (R=0/51, RMSE=21/45) و شاخص‌های ناپایداری و پارامترهای هواشناسی (R=0/48, RMSE=22/01) بهتر بود. در کل میزان PM<sub>10</sub> بهتر از AQI و CO پیش‌بینی شد و AQI فقط با پارامترهای هواشناسی بهتر از شاخص‌های ناپایداری پیش‌بینی شد و شبکه عصبی مصنوعی نتوانست AQI را نسبت به PM<sub>10</sub> به خوبی شبیه‌سازی کند که این شاید به دلیل عدم انتخاب درست پارامترها بوده باشد.</p> |                                   |                        |

## فصل اول: مقدمه

### 1-1 بیان مسئله، اهمیت و ضرورت تحقیق

از بین مهم‌ترین نیازهای انسان، هوا حیاتی‌ترین نیاز شناخته شده است که اگر اختلالی در آن ایجاد شود ادامه زندگی را غیرممکن خواهد کرد (Beamish, & Wine, 2011). هوای پاک به طور معمولی از 79 درصد نیتروژن، 20 درصد اکسیژن، و یک درصد ترکیب دی‌اکسید کربن، بخار آب، و مقدار کم‌تر از چندین گاز دیگر تشکیل شده است (Enger et al., 2014). اما فعالیت‌های انسان باعث آلوده شدن هوا می‌گردد. انجمن مشترک مهندسين آلودگی هوا و کنترل آن، این تعریف را برای آلودگی هوا بیان کرده است: "آلودگی هوا یعنی وجود ماده‌ی آلوده‌کننده‌ای مانند گردوغبار، گازها، دود، بخارات در هوای آزاد با کمیت و ویژگی‌هایی که برای انسان، گیاه یا زندگی حیوانات خطرناک باشد، یا به طور غیرقابل قبولی مخل استفاده‌ی راحت از زندگی و اموال شود" (واثقی، 1387). تاریخچه آلودگی هوا به قرون وسطی حتی سال‌های قبل برمی‌گردد، بنابراین بحث در مورد آلودگی هوا و وضع قوانین درباره‌ی آن پدیده جدیدی نیست. چندین نوع آلودگی هوا وجود دارد که آثار گوناگونی بر جای می‌گذارند مه دود، باران اسیدی، پدیده اثر گلخانه‌ای و ایجاد حفره در لایه ازون هرکدام عوارض خطرناکی را برای سلامت انسان و کل محیط‌زیست به بار می‌آورند (افیونی، 1379). فاکتورهای سهمیم در آلودگی، گسترش شهرنشینی، توسعه‌ی شهرها، افزایش جمعیت، توسعه‌ی فعالیت‌های صنعتی، افزایش مصرف سوخت‌های فسیلی، کمبود سیستم حمل و نقل عمومی کارا، کیفیت کم سوخت و ترافیک، هستند که باعث شده روزانه حجم وسیعی از آلاینده‌های غیر سازگار با مکانیسم طبیعی در هوا تخلیه شود (S. Jain & Khare, 2010). از جمله این آلاینده‌ها و منابع تولیدکننده آن‌ها در جدول 1 آورده شده است. آلودگی هوا به طرق گوناگونی می‌تواند آثار زیان‌بار درازمدت و کوتاه‌مدتی بر سلامت انسان‌ها بگذارد. تأثیر آلودگی هوا بر افراد مختلف متفاوت است. آسیب‌پذیری برخی افراد در برابر آلودگی هوا بسیار بیشتر از سایرین است. کودکان کم سن و سال و سالمندان بیشتر از دیگران از آلودگی هوا آسیب می‌بینند. برخی بیماری‌ها مانند آسم، بیماری قلبی و ریوی در مواقع آلودگی هوا تشدید می‌شوند. آثار کوتاه‌مدت آلودگی هوا عبارت است از حساسیت چشم‌ها، بینی و حلق، عفونت‌های دستگاه تنفسی فوقانی مانند برونشیت و ذات‌الریه. سردرد، تهوع، آثار درازمدت آلودگی هوا می‌تواند بیماری مزمن تنفسی، سرطان ریه، بیماری قلبی، و حتی آسیب به مغز، اعصاب، کبد و کلیه‌ها را شامل شود (R. Chen et al., 2012).

جدول 1-1) منابع آلاینده‌های اولیه (Enger et al., 2014).

| منابع  | آلاینده         |
|--|-----------------|
| سوختن ناقص سوخت‌های فسیلی  | مونوکسید کربن   |
| سوختن ناقص سوخت‌های فسیلی و مواد شیمیایی   | هیدروکربن‌ها    |
| سوزاندن سوخت‌های فسیلی و فعالیت‌های کشاورزی و فعالیت‌های ساختمانی و زائدات صنعتی و تخریب ساختمان | ذرات معلق       |
| سوزاندن سوخت‌های فسیلی و ذوب کردن سنگ  | دی‌اکسید گوگرد  |
| سوزاندن سوخت‌های فسیلی   | ترکیبات نیتروژن |

همچنین آلاینده‌های هوا، توان گیاهان را برای مقابله با بیماری‌ها و حشرات کاهش داده و در رشد آن‌ها تأثیر منفی می‌گذارند (افیونی، 1379).

آثار آلودگی هوا به حدی گسترده است که تحقیقات در این باره همچنان ادامه دارد. بیماری‌های ناشی از آلودگی هوا می‌تواند بسیار پرهزینه باشد. هزینه‌های درمانی، کاهش بهره‌وری در محل کار می‌تواند سالیانه میلیاردها دلار هزینه بر جامعه تحمیل کند. مشکلات آلودگی نه تنها در ایران بلکه در سراسر جهان وجود دارد، بیشتر شهرهای بزرگ به خصوص کشورهای در حال توسعه از آن رنج می‌برند. از حادثه‌های مهم در آلودگی هوا به دره میوز در بلژیک در سال 1930 و حوادث لندن، در سال 1952 و وقوع ریزگردها در ایران در اثر تخریب و تغییر کاربری‌ها می‌توان اشاره نمود (افیونی، 1379). با توجه به موارد گفته شده، پیش‌بینی وضعیت آلودگی هوای شهرهای بزرگ و پرجمعیت و ارزیابی عوامل مختلف تأثیرگذار بر غلظت آلاینده‌ها می‌تواند در برنامه‌ریزی‌های جامعی که در راستای کنترل و کاهش آلودگی هوا و اثرات آن انجام پذیرد بسیار مؤثر باشد (مساعدی، 1392). به‌طور کلی با توجه به حجم بسیار زیادی از آلاینده‌های مختلف، امروزه یکی از نیازهای مهم که نقش حیاتی بر سلامت افراد جامعه دارد، کنترل کیفیت هوا و تدوین سیاست‌های مناسب جهت کاهش میزان آلاینده‌های موجود در آن است. بنابراین با توجه نیاز به برنامه‌ریزی جهت اتخاذ سیاست‌گذاری و انجام اقدامات لازم جهت کاهش و جلوگیری از پیشرفت آلودگی و بحرانی شدن کیفیت هوا، پیش‌بینی از ملزومات اصلی هست (عابدی، 1392). در دهه‌های اخیر شهر تهران به دلیل افزایش بیش از حد جمعیت، افزایش بسیار زیاد وسیله‌ی نقلیه و نیز تمرکز و تجمع شدید صنایع با بحران‌های زیست‌محیطی گوناگونی از جمله آلودگی هوا دست به‌گریبان است (Golbaz, Farzadkia, & Kermani, 2010). شهر تهران یکی از آلوده‌ترین شهرهای جهان به شمار می‌رود. در سال از هر سه روز یک روز توسط آلاینده‌های اصلی آلوده است. عواقب این آلودگی به صورت بیماری‌های قلبی، عروقی، تنفسی، سکنه مغزی متوجه ساکنان این شهر است. از جمله عوامل تأثیرگذار بر آلودگی هوای شهرهای بزرگ مانند



تهران پارامترهای جوی مانند دما، رطوبت، فشار، سرعت باد و جهت باد هست (تقوی، 1392). روش‌های مختلفی در منابع مطالعاتی جهت پیش‌بینی غلظت آلاینده‌های هوا ارائه شده و مورد استفاده قرار گرفته است که به روش‌های کمی و کیفی تقسیم‌بندی می‌شوند. در حالت کلی می‌توان روش‌های کمی را به دو گروه رگرسیونی و غیر رگرسیونی تقسیم‌بندی کرد. روش‌های غیر رگرسیونی شامل روش میانگین ساده، میانگین متحرک و انواع روش‌های تعدیل نمایی است. اما از بین همه روش‌ها، رگرسیون چندگانه (MLR)<sup>1</sup> و (ARIMA)<sup>2</sup> جز روش‌های خطی و شبکه عصبی مصنوعی (ANN)<sup>3</sup> جز روش‌های غیرخطی بوده و در پیش‌بینی کیفیت هوا و غلظت آلاینده‌های هوا استفاده می‌شود. بیشترین مدلی که در آلودگی استفاده می‌شود، مدل شبکه عصبی است. شبکه عصبی دارای خصوصیات ویژه‌ای همچون قابلیت یادگیری، تعمیم، خوشه‌بندی، داده‌هاست، توپولوژی شبکه عصبی به وسیله تعداد لایه‌ها، تعداد نورون‌ها در هر لایه، الگوریتم یادگیری و تابع انتقال در شبکه تعیین می‌گردد. شبکه عصبی از چند لایه تشکیل شده است که شامل لایه ورودی، خروجی و لایه یا لایه‌های مخفی است. خروجی لایه اول، بردار ورودی لایه دوم به حساب می‌آید. به همین ترتیب خروجی لایه دوم، بردار ورودی لایه سوم را تشکیل می‌دهد. در مطالعات گذشته از این پارامترها به‌طور گسترده‌ای در تخمین یا پیش‌بینی غلظت آلاینده‌ها به‌عنوان ورودی شبکه عصبی استفاده شده است ولی از داده‌های نیمرخ عمودی جو در تخمین میزان کیفیت هوا یا غلظت آلاینده‌های هوا استفاده نشده است که در مطالعه حاضر علاوه بر در نظر گرفتن پارامترهای معمول از داده‌های پایداری و ناپایداری استفاده خواهد شد از مهم‌ترین عوامل در جو در تعیین میزان تجمع آلاینده‌ها یا پراکنش آن‌ها و احتمال وقوع ریزگردها، تعیین میزان وقوع پایداری و ناپایداری در جو هست. از جمله داده‌های در دسترس برای پیش‌بینی پایدار یا ناپایدار بودن جو می‌توان به داده‌های رادیوسوند<sup>4</sup> اشاره نمود که با استفاده از آن‌ها شاخص‌هایی ویژه‌ای محاسبه شده که میزان همرفت و جابجایی توده‌های هوا محاسبه می‌شود. در حقیقت با استفاده از نمودارهای ترمودینامیکی موسوم به skew-t رسم شده شاخص‌های پایداری و ناپایداری جو محاسبه شده می‌شوند. در کل با تحلیل اطلاعات نمودار skew-t می‌توان به اطلاعات ذیل دست یافت:

- 1- ارزیابی پایداری و ناپایداری جو
  - 2- بررسی چگونگی عناصر آب و هوایی در لایه‌های مختلف
  - 3- تعیین پدیده‌هایی مانند توفان و تندباد
  - 4- تهیه اطلاعات برای مدل‌های پیش‌بینی سینوپتیکی مورد استفاده قرار می‌گیرد (Golbaz et al., 2010).
- از شاخص‌های معمول در تعیین پایداری و ناپایداری جو، شاخص‌های ذیل جزء پرکاربردترین شاخص‌ها می‌باشند. در تعیین مدل‌های پیش‌بینی از این شاخص‌ها به‌عنوان داده‌های ورودی استفاده می‌شود.

---

1- Multiple line regression  
2 - Autoregression Integrated Moving Average  
3 -Artificial neural network  
4- Radio Sound Data

## الف - پایه ابر فرارفتی (LCL)<sup>5</sup>

منظور از پایه ابر فرارفتی، ارتفاعی است که اگر هوای سطحی به صورت آزاد یا واداشته صعود کند، در آن ارتفاع به نقطه شبنم خود رسیده و بنابراین اشباع خواهد شد. و در تعیین سایر پارامترهای جوی نقش بسزایی را ایفا می‌کند. با رسم خط دمای پتانسیل برای دمای سطحی و نیز خط میزان اختلاط مربوط به دمای نقطه شبنم و به دست آوردن محل تلاقی آن‌ها این ارتفاع به دست خواهد آمد (بایگی، 1393).

## ب - سطح فرارفت آزاد (FCL)<sup>6</sup>

این سطح، سطحی است که اگر هوا تحت هر شرایطی (آزاد یا واداشته) به آن برسد، از آن پس آزادانه سقوط خواهد کرد، زیرا انرژی لازم برای صعود را به صورت پتانسیل در خوددار است. به گونه‌ای که هر چه بالاتر می‌رود انرژی پتانسیل آن افزایش می‌یابد. این صعود تا وقتی که انرژی نهفته ناشی از تراکم بخار آب و رها شدن گرمای نهان تبخیر، به دلیل افت رطوبت جو کاهش می‌یابد، ادامه خواهد داشت برای تعیین این سطح باید از سطح LCL در امتداد خط دمای پتانسیل اشباع، حرکت نمود تا جایی که این خط نمایه قائم دمای هوا را قطع کند (بایگی، 1393).

## پ - شاخص موجودی انرژی پتانسیل حرارتی (CAPE)<sup>7</sup>

این شاخص، نشان‌دهنده بیشینه انرژی جنبشی ممکن بسته‌هوا، ناپایدار، در صورت در نظر گرفتن بخار آب و آب متراکم شده در اثر صعود می‌باشد، محاسبه این شاخص با فرض عدم اختلاط بسته‌هوا با محیط در هنگام صعود و انطباق فشار آن با فشار محلی محیط صورت می‌گیرد، مقدار شاخص موجودی انرژی پتانسیل فرارفتی در حقیقت برابر با مساحت ناحیه مثبت بین دمای بسته‌هوا و دمای محیط است که با انتگرال‌گیری عمودی از نیروی شناور بسته‌هوا، از سطح همرفت آزاد (FCL) تا سطح تعادل (EL) و با استفاده از رابطه زیر محاسبه می‌شود.

$$CAPE = g \int_{FCL}^{EL} \frac{\theta_p - \theta_E}{\theta_E} \quad (1-1)$$

که در این رابطه CAPE شاخص موجودی انرژی پتانسیل فرارفتی (ژول بر کیلوگرم)،  $g$  شتاب جاذبه (متر

بر مجذور ثانیه)،  $\theta_p$  دمای پتانسیل بسته‌هوا (درجه سانتی‌گراد)،  $\theta_E$  دمای پتانسیل محیط (درجه سانتی‌گراد)،

$d_z$  ارتفاع صعود بسته‌هوا (بر حسب متر)، می‌باشد (McIlveen, 1991).

به‌طور کلی مقادیر مثبت این شاخص، نشان‌دهنده وجود ناپایداری است و هرچه مقدار آن زیادتر باشد اختلاف دمای بسته‌هوا با دمای محیط بیشتر شده و در نتیجه نیروی شناوری آن قوی‌تر بوده و بنابراین شتاب بالارو بیشتر خواهد شد (Miller, 1972).

5- Lifting convection level

6- free convection level

7- Convective Available Potential Energy

### ت - شاخص شوالتر (SHOW)<sup>8</sup>

این شاخص توسط شوالتر و به صورت زیر بیان شده است :

$$SHOW = T_{E500} - T_{P500} \quad (2-1)$$

در این رابطه SHOW شاخص شوالتر (درجه سانتی گراد)،  $T_{E500}$  دمای محیط در سطح 500 هکتوپاسکالی (درجه سانتی گراد)،  $T_{P500}$  دمای بسته هوا در سطح 500 هکتوپاسکالی (درجه سانتی گراد) است به شرط آنکه بسته هوای اولیه از سطح 850 هکتوپاسکالی شروع به صعود کرده باشد. به طور کلی مقادیر صفر تا (3-) این شاخص نشان دهنده ناپایداری کم، و (4-) تا (7-) نشان دهنده پایداری زیاد می باشد و در صورتی که مقادیر محاسبه شده بیشتر از (8-) باشد ناپایداری خیلی شدید وجود خواهد داشت و در نتیجه بسته هوا بیشتر صعود خواهد کرد (رضائیان، 1385).

### ث - شاخص K (KINX)<sup>9</sup>

مقدار این شاخص با استفاده از رابطه زیر به دست می آید:

$$KINX = (T_{850} - T_{500}) + T_{d850} - (T_{700} - T_{d700}) \quad (3-1)$$

که در آن  $T_d$  و  $T$  به ترتیب دما و دمای نقطه شبنم (درجه سانتی گراد) در سطوح ذکر شده هستند. در صورتی که مقدار این شاخص کم تر از 15 باشد، هوا کاملاً پایدار است و در حقیقت مقدار بالای 15 این شاخص، گویای ناپایداری هوا است، به گونه ای که مقادیر بالای 15 تا 20 ناپایداری بسیار کم و 21 تا 25 ناپایداری کم، 26 تا 30 ناپایداری متوسط، 31 تا 35 ناپایداری زیاد، 36 تا 40 ناپایداری بسیار زیاد را نشان می دهد و مقادیر بزرگ تر از 40 نشان دهنده هوای کاملاً ناپایدار است (George, 1960).

### ج - شاخص هوای مخرب (SWEAT)<sup>10</sup>

این شاخص بیشتر در مناطقی که در معرض توفان های سهمگین قرار دارند، کاربرد دارد و مقدار آن از رابطه (4) به دست می آید:

$$SWEAT = 12(T_{d850}) + 125[\text{Sin}(W_{D500} - W_{D850})] + (2F_{850} + F_{500}) \quad (4-1)$$

که در آن  $T_{d850}$  دمای نقطه شبنم در سطح 850 هکتوپاسکالی (درجه سانتی گراد)،  $F$  سرعت باد در سطوح ذکر شده (نات)،  $WD$  جهت باد در سطوح ذکر شده (درجه)،  $TT$  شاخص مجموع مجموع ها بوده و برابر با:

8- Showalter index

9- K Index

10- Storm Weather

$$TT = (T_{850} - T_{500}) + (T_{a850} - T_{a500}) \quad (5-1)$$

در این رابطه،  $T$  و  $(T_d)$  به ترتیب دما و دمای نقطه‌ی شبنم (درجه سانتی‌گراد) در سطوح ذکر شده هستند. در مورد این شاخص، مقادیر کم‌تر از 300 نشان‌دهنده ناپایداری ضعیف، 300 تا 399 ناپایداری ضعیف، 400 تا 599 ناپایداری زیاد و بیشتر از 600 ناپایداری خیلی زیاد می‌باشند (بداقپور، 1387).

### 1-2 اهداف پژوهش

- بررسی وضعیت کیفیت هوا و تعیین آلاینده‌های شاخص تهران در سال 1392 و 1393
- تعیین تأثیر پارامترهای اقلیمی بررسی شده بروی آلاینده‌های شاخص یا آلودگی هوا
- پیش‌بینی زمانی کیفیت هوا و غلظت آلاینده‌های شاخص با پارامترهای اقلیمی با استفاده از شبکه عصبی مصنوعی
- امکان‌سنجی استفاده از داده‌ها و شاخص‌های پایداری و ناپایداری در پیش‌بینی کیفیت هوا با استفاده از شبکه عصبی مصنوعی

### 1-3 سؤالات پژوهش

- آیا شبکه عصبی مصنوعی قابلیت پیش‌بینی کیفیت هوای تهران را دارد؟
- آیا شاخص‌های پایداری و ناپایداری باکیفیت هوای شهر تهران و غلظت آلاینده‌های شاخص ارتباط معنی‌دار دارد؟
- آیا خروجی شبکه عصبی (غلظت‌های پیش‌بینی شده) از استاندارد هوای پاک بالاتر هستند؟

### 1-4 فرضیه

- ارتباط معناداری بین شاخص‌های پایداری و ناپایداری و کیفیت هوای شهر تهران وجود دارد.
- شبکه عصبی مصنوعی برازش شده قابلیت بالایی (خطای کم) در پیش‌بینی غلظت آلاینده‌های شاخص دارند.
- غلظت‌های پیش‌بینی شده توسط شبکه عصبی از استانداردهای هوای پاک بالاتر هستند.

## فصل دوم : مبانی نظری

### 1-2 مقدمه

انسان گام‌های بلندی در راستای تمدن و توسعه برداشته که این بی‌شک به بهبود شرایط زندگی و ارتقاء آسایش وی منجر شده است. اما او توازن حیاتی محیط‌زیست اطراف خود را که چندین میلیون سال از جانب طبیعت ایجاد شده است را به‌طور غیرعمدی بر هم زده است. فعالیت انسان و توسعه‌ی همه‌جانبه او، هراسی همه‌جانبه را در پی تخریب تمامی وجوه فیزیکی - شیمیایی و اجتماعی محیط طبیعی برانگیخته است و این تأثیری نامناسب بر کیفیت زندگی گذاشته است، یعنی تضادی آشکار با تمامی آنچه قصد بهبودش را داشته‌ایم. خوشبختانه آگاهی از مشکلات محیط‌زیست، جهانی و روبه افزایش است، همچنین باید به این نکته توجه داشت که انسان قادر به تطابق سریع و عمده ایجاد شده در ترکیب شیمیایی اطرافش نمی‌باشد، لذا بررسی تغییرات ایجاد شده در محیط‌زیست و پیدا کرده راه‌حل‌های مناسب برای کاهش اثرات آن امری اجتناب‌ناپذیر است. یکی از این مشکلات و معضلات زیست‌محیطی که ایران و حتی جهان را به چالش کشیده و در تلاش پیدا کرده راه‌حلی برای آن می‌باشند آلودگی هوا است، که توسعه فناوری و افزایش روزافزون جمعیت و تولید فرآورده‌های جدید و متنوع شیمیایی مورد نیاز در صنعت، منجر به افزایش آلودگی شده است. مواد آلاینده صرف‌نظر از منشأ تولید و مصرف بر اثر نیروهای باد و آب در تمامی کره مسکونی انتشار می‌یابد و تا زمان تجزیه‌ی کامل تأثرات بهداشتی را بر موجودات زنده از جمله انسان خواهند داشت.

### 2-2 آلودگی هوا

انجمن مشترک مهندسين آلودگی هوا و کنترل آن، این تعریف را برای آلودگی هوا بیان کرده است "آلودگی هوا یعنی وجود ماده‌ی آلوده‌کننده‌ای مانند گردوغبار، گازها، دود، بخارت در هوای آزاد با کمیت و ویژگی‌هایی که برای انسان، گیاه یا زندگی حیوانات خطرناک باشد، یا به‌طور غیرقابل قبولی مخل استفاده‌ی راحت از زندگی و اموال شود" (وائقی و زیبایی، 1387).

### 3-2 آلاینده‌های شاخص

همان ماده آلوده‌کننده است که شامل مونوکسید کربن، ذرات معلق، هیدروکربن‌ها، اکسیدهای ازت، دی‌اکسید گوگرد هست. که جز ترکیبات طبیعی محسوب نمی‌شوند و وجود آن‌ها در اتمسفر در نتیجه پیشرفت تکنولوژی، افزایش

جمعیت، افزایش مصرف انرژی می‌باشد (دبیری، 1379). در این مطالعه از میان آلاینده‌های شاخص ذرات معلق و مونوکسید کربن انتخاب شدند، زیرا آلاینده‌های اصلی تهران که باعث آلودگی هوا می‌شوند همین دو آلاینده شاخص هستند

### 2-3-1- مونوکسید کربن (CO)

باعث کاهش دقت بینایی، کاهش توان کاری، عدم قابلیت یادگیری و انجام فعالیت‌های دشوار می‌شود که بیماری‌هایی مثل بیماری‌های قلبی و ریوی و عصبی و بیماری‌های دوران زایمان می‌شود (افیونی، 1379).

### 2-3-2- ذرات معلق (PM<sub>10</sub>)

ذرات معلق در تشدید بیماری‌های قلبی - ریوی - کاهش سیستم ایمنی بدن در مقابل بیماری‌ها، از بین رفتن بافت ریه، آسم کودکان، مرگ‌ومیر زودرس و سرطان نقش عمده‌ای دارد (افیونی، 1379).

### 2-4- روش‌های پیش‌بینی آلاینده‌ها

به‌طور کلی باوجود حجم بسیار زیاد آلاینده‌های مختلف در کلان‌شهرها، امروزه یکی از نیازهای مهم که نقش اساسی در سلامت جامعه دارد، کنترل کیفیت هوا و تدوین سیاست‌های مناسب جهت کاهش آلاینده‌های موجود در آن است بنابراین با توجه به نیاز به برنامه‌ریزی جهت اتخاذ سیاست‌گذاری و انجام اقدامات لازم جهت کاهش و جلوگیری از پیشرفت آلودگی و بحرانی شدن کیفیت هوا، پیش‌بینی از ملزومات اصلی هست (عابدی، 1392). تحقیقات زیادی با استفاده از روش‌های مختلف برای پیش‌بینی آلودگی غلظت آلاینده‌ها صورت گرفته است. در حالت کلی می‌توان روش‌های پیش‌بینی را به دو گروه رگرسیون و غیر رگرسیون تقسیم‌بندی کرد. روش‌های غیر رگرسیونی شامل روش میانگین ساده، میانگین متحرک و انواع روش‌های تعدیل‌نمایی است و روش‌های رگرسیونی نیز به دو گروه علی و غیر علی تقسیم‌بندی می‌شوند. از جمله روش‌های علی می‌توان به مدل خود رگرسیون با واریانس ناهمسانی شرطی (ARCH)<sup>11</sup> و مدل خود رگرسیون با واریانس ناهمسانی شرطی تعمیم‌یافته (GARCH)<sup>12</sup> اشاره کرد. روش‌های رگرسیون غیر علی نیز شامل روش هارمونیک و فرایند ARMA<sup>13</sup> و ARIMA<sup>14</sup> هستند (واتقی، 1387).

11-Autoregressive conditionally Heteroscedastic

12- Generalized Autoregressive conditionally Heteroscedastic

13- Autoregressive Moving Average

14- Autoregressive Integrated Moving Average

## 1-4-2 روش‌های پیش‌بینی غیر رگرسیونی

**1-1-4-2 روش میانگین ساده<sup>۱۵</sup>**: در این روش، پیش‌بینی آینده برابر با میانگین تمام داده‌های موجود یک مجموعه زمانی است. یکی از معایب این روش این است که مقدار پیش‌بینی برای تمام دوره آینده یکسان است (واتقی، 1387).

**2-1-4-2 روش میانگین متحرک<sup>۱۶</sup>**: در این روش پیش‌بینی آینده مبتنی بر میانگین (وزنی یا غیر وزنی) تعدادی از آخرین داده‌های مجموعه زمانی است که به آن میانگین متحرک می‌گویند (واتقی، 1387).

**3-1-4-2 روش میانگین متحرک با روند زمانی خطی<sup>۱۷</sup>**: این روش مشابه با روش میانگین متحرک است، با این تفاوت که روند خطی در آن در نظر گرفته می‌شود. در این روش برای هر سال مقداری متفاوت پیش‌بینی می‌شود (واتقی، 1387).

**4-1-4-2 روش رهیافت تعدیل نمایی یگانه<sup>۱۸</sup>**: در این روش هدف به صفر رساندن خطای پیش‌بینی، در صورتی که خطای پیش‌بینی منفی، یا مثبت باشد، مقادیر پیش‌بینی شده به ترتیب کاهش، یا افزایش می‌یابد (واتقی، 1387).

## 2-4-2 روش‌های پیش‌بینی رگرسیونی

### 1-2-4-2 آریما (ARIMA)

مدل آریما به عنوان مدل باکس - جکینز شناخته می‌شود و یک مدل خطی است که برای پیش‌بینی کوتاه‌مدت و تجزیه و تحلیل سری‌های زمانی مورد استفاده قرار می‌گیرد (Adebiyi, Adewumi, & Ayo, 2014). سه مرحله اصلی که باید در ساخت مدل برای پیش‌بینی در نظر گرفته شود، شناسایی، برخورد پارامتر، تشخیص خطا می‌باشد که بر مبنای سه پارامتر خطی: خود توضیح (AR)، جمعی (I) و میانگین متحرک (MA) استوار است (Díaz-Robles et al., 2008). که به آن مدل خود توضیح جمعی میانگین متحرک گفته می‌شود و به صورت  $ARIMA(p, q, d)$  نشان داده می‌شود (Haizum, Rahman, Hisyam, & Talib, 2013).

---

15- Simple Average

16- Moving Average

17- Moving Average With linear tend

18- Single Exponential Smoothing

## 2-2-4-2 رگرسیون خطی چندگانه (MLR)

روشی است که برای ارتباط خطی بین یک متغیر وابسته و یک یا چند متغیر مستقل مورد استفاده قرار می‌گیرد. که شکل عمومی آن به شرح زیر می‌باشد:

$$Y_i = \beta_0 + \beta_1 X_{1i} + \dots + \beta_k X_{ki} + \varepsilon \quad (1-2)$$

که در این فرمول،  $\beta_1, \dots, \beta_k$  ضرایب رگرسیون بوده و  $X_{1i}, \dots, X_{ki}$  متغیرها هستند در حالی که  $\varepsilon$  خطای رگرسیون هست (Biancofiore et al., 2015).

## 3-2-4-2 شبکه عصبی مصنوعی (ANN)

### 1-3-2-4-2 تعریف شبکه

در حقیقت یک شبکه، مجموعه‌ای از ساختارهای ساده است که در کنار یکدیگر یک سیستم پیچیده نهایی را توصیف می‌کنند. همگی شبکه‌ها دو مؤلفه دارند:

1- مجموعه‌ای از گره‌ها: هر گره در حقیقت واحد محاسباتی شبکه است که ورودی‌ها را گرفته و بروی آن‌ها پردازش انجام می‌دهند تا خروجی به دست آید.

2- اتصالات بین گره‌ها: نحوه گذر اطلاعات بین گره‌ها را مشخص می‌کند که می‌تواند تک‌سویه یا دوسویه باشد. که این اتصالات یا تعامل بین گره‌ها سبب بروز یک رفتار کلی از سوی شبکه می‌گردد که چنین رفتاری به تنهایی در هیچ‌یک از عناصر شبکه دیده نمی‌شود (Haykin, 1998).

### 2-3-2-4-2 شبکه عصبی زیستی

این شبکه مجموعه بسیار عظیم از پردازشگرهایی به نام نورون‌اند که به صورت هماهنگ برای حل مسئله عمل می‌کنند و توسط سیناپس‌ها اطلاعات را منتقل می‌کنند. در این شبکه‌ها اگر یک سلول آسیب ببیند بقیه سلول‌ها می‌توانند نبود آن را جبران کرده و در بازسازی آن‌ها سهیم باشند. و این شبکه‌ها قادر به یادگیری‌اند مثلاً با اعمال سوزش به سلول‌های عصبی لامسه سلول یاد می‌گیرد که به طرف جسم داغ نرود و با این الگوریتم سیستم می‌آموزد که خطای خود را اصلاح کند (Haykin, 1998).

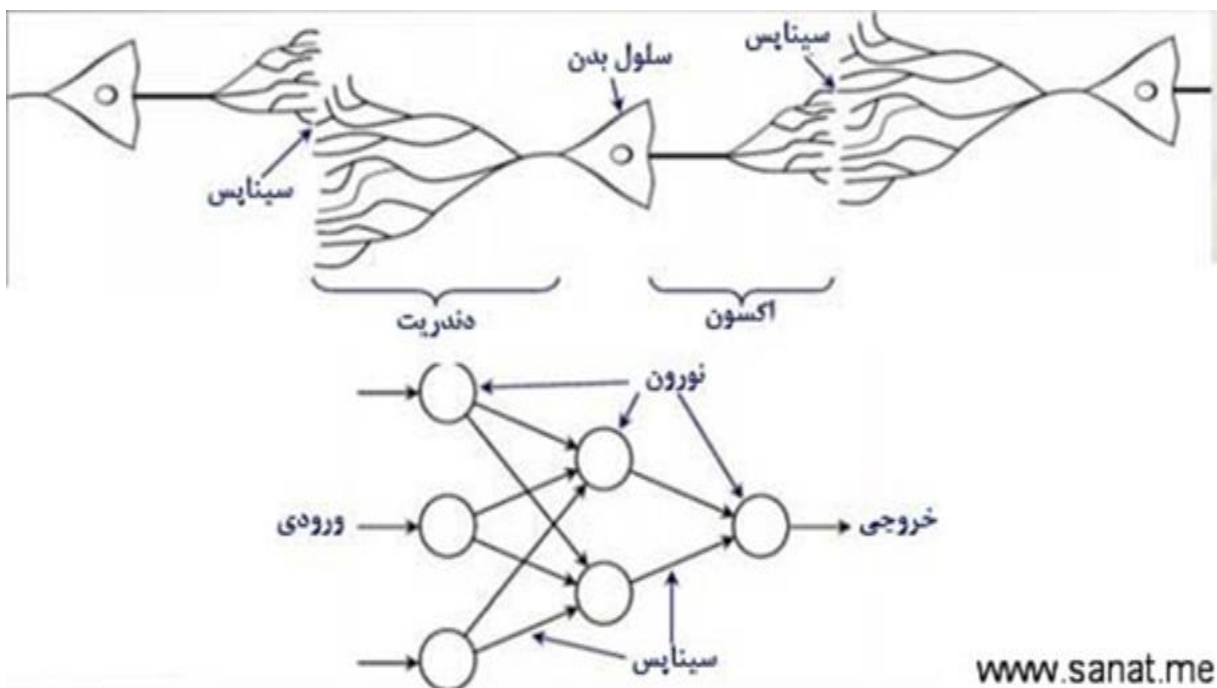
### 3-3-2-4-2 تعریف شبکه عصبی مصنوعی

شبکه‌ها انواع مختلفی دارند که در این میان شبکه‌ای وجود دارد که گره‌ها را به‌عنوان یک نورون مصنوعی در نظر می‌گیرد که چنین شبکه‌هایی را شبکه عصبی مصنوعی گویند (صیادی، 1387). روش کلی شبیه‌سازی شبکه‌های عصبی مصنوعی عبارت‌اند از:



- ارائه بردارهای ورودی و خروجی
- ارائه تابع انتقال
- انتخاب ساختار شبکه
- انتخاب وزنهای تصادفی
- انتخاب روش یادگیری
- ارائه الگوی آزمون و پیش‌بینی یا داده اعتبار سنجی برای تعمیم شبکه


شبکه‌های عصبی انواع متفاوتی دارند که می‌توان به انواع زیر اشاره کرد شبکه عصبی پرسپترون<sup>۱۹</sup>، شبکه عصبی هاپفیلد<sup>۲۰</sup>، شبکه عصبی همینگ<sup>۲۱</sup>، شبکه عصبی کوهنن<sup>۲۲</sup>، شبکه عصبی تاخیر زمانی<sup>۲۳</sup>، شبکه عصبی انتشار رو به عقب<sup>۲۴</sup>.



شکل 1-2) ساختار شبکه عصبی زیستی و شبکه عصبی مصنوعی (www.google.com)

- 
- 19- Perceptron Neural Network
  - 20- Hopfield neural network
  - 21- Hamming neural network
  - 22- Kohonen Neural Network
  - 23- Time delay neural network
  - 24- Backward propagation neural network

## 2-4-3-4 انواع شبکه عصبی مصنوعی



نمودار 1-2 یک تقسیم بندی از معماری شبکه عصبی مصنوعی (A. K. Jain, Mao, & Mohiuddin, 1996)

## 2-4-3-5 ساختار شبکه عصبی مصنوعی

در یک شبکه عصبی مصنوعی یک لایه ورودی، و تعدادی لایه مخفی و در نهایت یک لایه خروجی وجود دارد.

**1- لایه ورودی:** دریافت اطلاعات خارجی که به شبکه تغذیه شده است توسط این لایه اتفاق می افتد.


**2- لایه پنهان:** عملکرد این لایه ها به وسیله ورودی ها و وزن ارتباط بین آن ها و لایه های پنهان تعیین می شود و اطلاعات را از لایه های قبلی می گیرد .

**3- لایه خروجی:** عملکرد واحد خروجی بسته به فعالیت واحد پنهان و وزن ارتباط بین واحد پنهان و خروجی می باشد که نتیجه محاسبات به آنجا می رود و جواب ها در آن قرار می گیرد.

در یک نگاه ساده مدل یک عصب باید شامل ورودی هایی باشد که در نقش سیناپس انجام وظیفه می کنند . این ورودی ها در وزن هایی ضرب می شود تا قدرت سیگنال را تعیین کند ، نهایتاً یک عملگر ریاضی تصمیم می گیرد که آیا نورون فعال شود یا خیر و اگر جواب مثبت بود میزان خروجی مشخص می شود.

وزن ها می تواند مثبت یا منفی باشد توابع مورد استفاده برای آستانه گذاری می تواند سیگموئید یا آرک تانژانت یا آرک سینوس باشد و برای تعیین وزن ها و تنظیم مقدار آن ها از قواعد و داده های آموزشی استفاده می شود و با

استفاده از قابلیت یادگیری شبکه الگوریتم‌های متنوعی پیشنهاد می‌گردد که همگی سعی دارد خروجی تولیدشده را به خروجی مطلوب نزدیک کند (Enger et al., 2014).



شکل 2-2) ساختار شبکه عصبی مصنوعی (Enger et al., 2014)

#### 2-4-2-3-6- مزایای شبکه عصبی

- 1- خودسازمان‌دهی
- 2- یادگیری تطبیقی
- 3- عملگرهای بی‌درنگ
- 4- تحمل خطا
- 5- دسته‌بندی
- 6- تعمیم‌دهی
- 7- انعطاف‌پذیری (Haykin, 1998).

#### 2-4-2-3-7- معایب شبکه عصبی

- 1- قواعد یا دستورات مشخصی برای طراحی شبکه جهت یک کاربرد اختیاری وجود ندارد.
- 2- دقت نتایج بستگی زیادی به اندازه مجموعه آموزش دارد.
- 3- آموزش شبکه ممکن است مشکل باشد.
- 4- پیش‌بینی عملکرد آینده شبکه به سادگی امکان‌پذیر نیست (Haykin, 1998).

## 2-4-2-3-8 کاربرد شبکه‌های عصبی مصنوعی

- 1- کنترل هواپیما بدون خلبان
  - 2- آنالیز کیفیت جوشکاری
  - 3- مدیریت و برنامه‌ریزی
  - 4- پیش‌بینی ریسک محیطی
  - 5- بهینه‌سازی محصول
  - 6- تخمین غلظت آلاینده‌ها
- و.....

## 2-4-2-3-9 کاربرد شبکه عصبی مصنوعی در علوم محیط‌زیست

فرایندها و پدیده‌هایی که در دستگاه‌های زیست‌محیطی وجود دارد اغلب دو خاصیت عمده دارند 1- وابسته به متغیرهای زیادی هستند 2- روابط بسیار پیچیده‌ای بین اجزا وجود دارد که تحلیل آن را بسیار مشکل می‌کند. این مشکلات همواره باعث خطا در دقت و صحت پیش‌بینی مدل‌های مرسوم می‌شود. شبکه عصبی مصنوعی از جمله روش‌های پیشرفته در شبیه‌سازی می‌باشند که امروزه به‌عنوان یک ابزار قوی در شبیه‌سازی پدیده‌هایی که تحلیل مفهومی آن‌ها با مشکل مواجه است، کاربرد بسیاری پیدا کرده است. در زمینه‌ی محیط‌زیست از شبکه عصبی مصنوعی استفاده فراوانی شده است در این زمینه می‌توان به پیش‌بینی مقدار شوری رودخانه توسط دسیلتز در سال 1992، پیش‌بینی غلظت دی‌اکسید گوگرد در مناطق صنعتی آلوده توسط بوزنار در سال 1993، پیش‌بینی تأثیر آب‌وهوایی بر اکولوژی و هیدرولوژی رودخانه توسط بوف در سال 1996، پیش‌بینی افزایش جلبک‌های سبز آبی توسط مایر در سال 1997 و... اشاره کرد (ژولیده سر، 1392).

## 2-5 پیشینه تحقیق

امروزه پیش‌بینی کیفیت هوا در نواحی شهری به دلیل تأثیر آن بر روی سلامت انسان، یکی از موضوعات مهم در تحقیقات محیط زیستی می‌باشد. غلظت‌های بالای آلاینده‌ها، تأثیرات سویی مانند مرگ زودرس گروه‌های حساس و آسیب‌پذیر جامعه از جمله افراد مسن و افراد مبتلا به بیماری‌های تنفسی و قلبی و عروقی را به دنبال دارد (Ruushkanen. et al., 1999). تحقیقات زیادی با استفاده از روش‌های مختلف برای پیش‌بینی آلودگی غلظت آلاینده‌ها صورت گرفته است. یکی از دیدگاه‌ها برای پیش‌بینی انتشار این غلظت‌ها استفاده از مدل انتشار اتمسفری می‌باشد. مدل‌های گوسین<sup>۲۵</sup> و مدل عددی از عمومی‌ترین این روش‌ها می‌باشد. مدل انتشار نیاز به معادلات فیزیکی شیمیایی توصیف‌کننده تغییرات غلظت آلاینده‌ها، داده‌های انتشار جزئی‌تر، و همچنین پارامترهای آب و

هوایی است که مشخصه‌های آب و هوایی به‌عنوان ورودی<sup>۲۶</sup> و غلظت آلودگی به‌عنوان خروجی<sup>۲۷</sup> در نظر گرفته می‌شود. اما در این مدل‌ها توزیع غلظت آلاینده‌ها در یک‌جهت و در یک مبدأ زمانی، باید به شکل توزیع نرمال باشد، به خاطر این محدودیت، این مدل در بررسی آلودگی هوا مورد توجه اساسی قرار نگرفته است. پس دومین دیدگاه ارائه‌ی یک مدل آماری می‌باشد که هدفش مشخص کردن داده‌های ورودی و خروجی است. مدل رگرسیون یکی از شیوه‌های مهم برای این نوع مدل‌ها، یادگیری کم آن‌ها در سیستم‌های غیرخطی می‌باشد (Gardner & Dorling, 1998). شبکه‌های عصبی مصنوعی یکی از روش‌هایی است که در مدل‌سازی سیستم‌های غیرخطی توانایی فراوانی دارد.

پی و پریباتوک<sup>۲۸</sup> (1996) در تحقیقی سه روش شبکه عصبی، رگرسیون و آریمای جهت پیش‌بینی غلظت ازون در یک منطقه در تگزاس به کاربردند که طبق تحقیقات نشان داد که شبکه عصبی نسبت به دو مدل دیگر دقیق‌تر است. کاربرد شبکه عصبی در پیش‌بینی وضعیت آلاینده‌های هوا از اوایل دهه 1990 رایج گردید.

اولین بار بزنا<sup>۲۹</sup> و همکاران (1993) برای پیش‌بینی غلظت دی‌اکسید گوگرد در نواحی صنعتی آلوده‌شده‌ی کشور اسلوانی از آن استفاده کردند و به این نتیجه رسیدند که بهترین مدل برای پیش‌بینی غلظت دی‌اکسید گوگرد در کشور اسلوانی شبکه عصبی مصنوعی است ولی معیارها برای انتخاب آموزش باید اصلاح شود و قوانین کلی برای این شبکه هنوز تعریف نشده و همچنین اینکه چگونه الگوریتم پس انتشار خطا را تنظیم کنیم تا بهترین همگرایی ممکن با فرایندهای یادگیری به دست آید و مهم‌ترین سؤال اینکه چه هنگام فرایند یادگیری را متوقف کنیم تا بهترین نتایج با الگوی ناشناخته به دست آید. در پیش‌بینی آلودگی‌های هوایی، انتخاب متغیرهای ورودی تأثیرگذار، یکی از مراحل مهم مدل‌سازی می‌باشد. به این دلیل که اندازه‌گیری‌ها، از منابع آلاینده مختلف انجام شده و ارتباط این منابع آلوده‌کننده اغلب پیچیده و غیرخطی است (Jiang et al., 2004). بنابراین کاربرد شبکه‌های عصبی در مدل‌سازی غلظت‌ها معمولاً نتایج بهتری را نسبت به روش‌های خطی دارند. شبکه عصبی خود شامل چندین نوع می‌باشد که از بین آن‌ها شبکه عصبی پرسپترون چندلایه (MLP) بهترین است.

هویرگز<sup>۳۰</sup> و دیگران (2005) غلظت PM<sub>10</sub> را با استفاده از شبکه‌های عصبی در بلژیک پیش‌بینی کردند که پرسپترون چندلایه، با یک‌لایه مخفی و چهار نورون در آن مورد استفاده قرار گرفت. میزان خطا با الگوریتم پس انتشار خطا کاهش یافت. و برای پرهیز از افراط در آموزش از داده‌های تأیید استفاده کردند. در این بررسی از داده‌های ده مرکز اندازه‌گیری آلودگی هوا در سال‌های 1997-2001 بهره‌گیری شد و برای ورودی شبکه از داده

---

26- input  
27- output  
28- Prybutok  
29 - Boznar  
30- Hooyberghs

های هواشناسی نیز بهره‌گیری شد و نتایج به‌دست‌آمده با مدل‌های خطی مورد مقایسه قرار گرفت. نتایج به‌دست‌آمده نشان داد که شبکه سه لایه پرسپترون، برای پیش‌بینی غلظت آلودگی هوا مناسب می‌باشد.

گاردنر<sup>۳۱</sup> و درلینگ<sup>۳۲</sup> (1999) با استفاده از شبکه عصبی پرسپترون چندلایه در بخش مرکزی لندن، اقدام به پیش‌بینی غلظت ساعتی اکسید نیتروژن و دی‌اکسید نیتروژن کردند که ورودی شبکه اطلاعات ساعتی  $\text{NO}_2$  و  $\text{NO}_x$  از دپارتمان محیط‌زیست و حمل‌ونقل و ایستگاه‌های پایش آلودگی بین سال 1990 تا 1991 برای دو مکان در لندن و داده‌های هواشناسی از مرکز هواشناسی لندن شامل سرعت باد، فشار بخار و دما، بود. نتایج این تحقیق در مقایسه با تحقیقات صورت گرفته با استفاده از مدل‌های رگرسیونی شی و هاریسون در سال 1997، برتری شبکه عصبی را به اثبات رساند.

اما در ایران نوری و همکاران (1385) از مدل رگرسیون چند متغیره و شبکه عصبی برای پیش‌بینی میانگین روزانه غلظت مونوکسید کربن در شهر تهران استفاده کردند که از پارامترهای هواشناسی شامل دما، رطوبت نسبی، فشار هوا، سرعت باد، جهت باد، تابش خورشیدی و داده‌های آلودگی شامل گوگرد دی‌اکسید، کل هیدروکربن‌ها، ازن، اکسیدهای نیتروژن و ذرات معلق با قطر کم‌تر از 10 میکرومتر در ایستگاه قلهک در سال‌های 1383 و 1384 استفاده شد و با بررسی‌های انجام‌شده نشان داد که با توجه به سری زمانی غلظت مونوکسید کربن که برای شهر تهران دارای نوسانات زیادی است روش رگرسیون خطی چند متغیره توانایی ارائه مدلی که بتواند این نوسانات را در نظر بگیرد ندارد و در این موارد استفاده از شبکه عصبی که قادر به پیش‌بینی روابط غیرخطی و پیچیده بین ورودی‌ها و خروجی باشد راه‌حل مناسبی برای جایگزینی با رگرسیون خطی چند متغیره است.

صدر موسوی و همکاران (1387) برای پیش‌بینی غلظت مونوکسید کربن در شهر تبریز از شبکه عصبی مصنوعی استفاده کردند و نتایج را با مدل ARIMA مقایسه کردند برای این بررسی از داده‌های هواشناسی، اداره هواشناسی تبریز و داده‌های آلودگی هوا از اداره کل محیط‌زیست آذربایجان شرقی به‌عنوان ورودی شبکه عصبی استفاده شد و نتایج نشان داد که بین مشخصه‌های آب و هوایی و غلظت مونوکسید کربن یک رابطه غیرخطی برقرار است بنابراین شبکه عصبی نسبت به روش آریمای نتیجه بهتری دارد.

تقوی و همکاران (1392) غلظت آلاینده‌های هوای شهر مشهد را بر اساس عوامل اقلیمی پیش‌بینی کردند که برای این کار از شبکه عصبی استفاده کردند. آلاینده‌های موردبررسی شامل  $\text{CO}$  و  $\text{SO}_2$  و  $\text{PM}_{2.5}$  و داده‌های هواشناسی مورد استفاده در این بررسی پوشش ابری، سرعت باد، دما، بارندگی، رطوبت و تشعشع و فشار هوا می‌باشد. نتایج حاصل از مدل‌سازی نشان داد که میانگین تغییرات روزانه غلظت آلاینده‌های مذکور در طی سال

31- Gardner

32- Dorling

متفاوت بود و به شدت تحت تأثیر عوامل اقلیمی می باشد به طوری که ضریب همبستگی (R) بین غلظت آلاینده ها با عوامل اقلیمی برای CO معادل 0/81، PM<sub>2.5</sub> معادل 0/71، و SO<sub>2</sub> معادل 0/82 محاسبه گردید. رحیمی و همکاران (1387)، برای پیش بینی غلظت ازن از شبکه عصبی مصنوعی بهره گرفتند که از داده های هواشناسی به عنوان ورودی های شبکه استفاده کردند. با افزودن NO و NO<sub>2</sub> به ورودی های شبکه جواب بهینه تری به دست می آید و از طرفی بهینه ترین مدل شبکه عصبی با استفاده از روش آزمون و خطا به دست می آید. همانطور که گفته شد در خصوص مدل سازی پیش بینی غلظت آلاینده ها با استفاده از مدل های گوناگون در خارج از ایران تحقیقات زیادی صورت گرفته است اما در داخل ایران به این امر توجه کمتری مبذول گردیده است. لذا هدف اصلی این مقاله توسعه مدلی است که بر اساس داده های هواشناسی و پایداری و ناپایداری که از جمله مهم ترین عوامل تأثیرگذار بر غلظت آلاینده های هوا می باشد میزان غلظت آلاینده ها را پیش بینی نمایند.

## فصل سوم : مواد و روش‌ها

### 3-1 منطقه مورد مطالعه

شهر تهران از آلوده‌ترین شهرهای جهان به شمار می‌آید. در ۵۱ درجه و ۶ دقیقه تا ۵۱ درجه و ۳۸ دقیقه طول شرقی و ۳۵ درجه و ۳۴ دقیقه تا ۳۵ درجه و ۵۱ دقیقه عرض شمالی قرار گرفته است در جنوب رشته‌کوه البرز قرار گرفته و دارای مساحتی حدود ۷۳۰ کیلومتر مربع است. این شهر بر اساس تقسیمات شهرداری دارای ۲۲ منطقه است (بداقپور، ۱۳۹۰). عوامل متعددی در آلودگی هوای شهر تهران مؤثرند که در بین آنها عوامل جغرافیایی و هواشناسی حائز اهمیت هستند:

- کوه‌های اطراف به‌خصوص رشته‌کوه‌های البرز که آن را احاطه کرده است مانند سدی عمل می‌کنند و باعث تجمع آلاینده‌ها در سطح شهر می‌شوند.


- همچنین عوامل هواشناسی از جمله وارونگی دمایی و استقرار مداوم سامانه‌های پرفشار همراه با هوای پایدار در دوره‌های سرد سال باعث افزایش آلاینده‌های هوا می‌شوند.

- در تهران آلودگی هوا تحت تأثیر تردد وسایل نقلیه می‌باشد.

- توپوگرافی شهر تهران (رحیمی، ۱۳۸۷).

غلظت آلاینده‌ها توسط دستگاه‌های پایش آنلاین کیفیت هوا اندازه‌گیری می‌شود، تعداد این ایستگاه‌ها ۴۱ عدد است که در سطح شهر استقرار یافته و تهیه و ثبت داده‌ها بر عهده سازمان محیط‌زیست و شرکت کنترل کیفیت هوا شهر تهران می‌باشد. در شکل ۳-۱ تعداد ۲۲ ایستگاه تحت نظارت شرکت کنترل کیفیت هوای تهران و در شکل ۳-۲ ایستگاه‌های هواشناسی نشان داده شده است.





شکل 3-1) ایستگاه تحت نظارت شرکت کنترل کیفیت هوای تهران



شکل 3-2) پراکندگی ایستگاه‌های پایش کیفیت هوا و هواشناسی سینوپتیکی و کیماتولوژی شهر تهران

### 2-3 روش انجام تحقیق

### 1-2-3 نقاط نمونه‌گیری

ابتدا با مراجعه به شرکت کنترل کیفیت هوای تهران، سازمان محیط‌زیست و سازمان هواشناسی کشور، اطلاعات مربوط به آلاینده‌های هوا و پارامترهای هواشناسی و داده‌های رادیوسوند از تاریخ 1392/1/1 تا 1393/7/31 کسب گردید. ایستگاه‌های مورد مطالعه به گونه‌ای انتخاب شد که بتواند سطح قابل قبولی از شهر تهران را در برگیرند به همین جهت غرب تهران انتخاب گردید.

### 1-1-2-3 ایستگاه‌های هواشناسی

در بین ایستگاه‌های هواشناسی، ایستگاه‌هایی که دوره آماری کامل‌تر و همچنین از لحاظ مکانی نزدیک‌تر به ایستگاه‌های سنجش آلودگی مورد مطالعه بودند انتخاب شدند.

جدول 1-3 ایستگاه هواشناسی مورد مطالعه در شهر تهران

| نام ایستگاه | محل ایستگاه   | عرض جغرافیایی شمالی | طول جغرافیایی شرقی | وابسته به سازمان |
|-------------|---|---------------------|--------------------|------------------|
| مهرآباد     | میدان آزادی، بلوار معراج، داخل باند فرودگاه مهرآباد | ' 41/318 °          | ' ۱۸/۷۳۷ ۵۱°       | هواشناسی         |

### 2-1-2-3 ایستگاه‌های سنجش کیفیت هوا

به منظور پایش کیفیت هوا از ایستگاه‌های سنجش آلودگی هوا استفاده می‌شود. این ایستگاه‌ها شامل اتاقک‌های ساکن و متحرکی هستند که تحلیل‌گرهای مختلفی در آن قرار گرفته است که اطلاعات آلودگی هوا را با استفاده از نرم‌افزار مرتبط و خطوط تافن با اینترنت به مراکز پایش آلودگی هوا منتقل می‌کنند. در این ایستگاه‌ها هر پنج آلاینده اصلی هوا ( $CO$ ,  $O_3$ ,  $NO_2$ ,  $SO_2$ ,  $PM_{10}$ ) و در برخی ایستگاه‌ها آلاینده  $PM_{2.5}$  و گروهی از ترکیبات آلی فرار اندازه‌گیری می‌شوند. در بین ایستگاه‌های سنجش آلودگی هوا تمام ایستگاه‌ها غلظت آلاینده‌ها را به‌طور پیوسته ثبت نکرده‌اند در نتیجه در این تحقیق از آن‌ها صرف‌نظر شده است و فقط ایستگاه‌هایی که دارای دوره آماری کامل‌تری در سال‌های مورد مطالعه در این تحقیق بودند انتخاب شدند.

جدول 2-3 ایستگاه‌های سنجش کیفیت هوا مورد مطالعه در شهر تهران

| نام ایستگاه | محل ایستگاه                                  | منطقه<br>شهرداری | طول<br>جغرافیایی شرقی | عرض جغرافیایی<br>شمالی |
|-------------|--|------------------|-----------------------|------------------------|
| شریف        | دانشگاه صنعتی شریف، جنب<br>کارگاه‌های آموزشی | 2                | ' 21/112° 51          | ' 42/284° 35           |
| آزادی       | میدان آزادی- ابتدای جناح                     | 5                | ' 20/275° 51          | ' 42/162° 35           |

### 3-3 تبدیل مقدار داده‌ها به میانگین روزانه

داده‌های سازمان هواشناسی برای برخی پارامترها به صورت 3 ساعته و برخی دیگر از پارامترها به صورت میانگین روزانه و داده‌های شرکت کنترل کیفیت هوا و سازمان محیط‌زیست برای غلظت آلاینده‌ها به صورت یک ساعته و داده‌های رادیوسوند دوازده ساعته می‌باشد. در نتیجه برای استفاده از داده‌ها به صورت همزمان داده‌ها به میانگین روزانه تبدیل شدند.

### 3-4 شاخص‌های پایداری و ناپایداری

از جمله داده‌های در دسترس برای پیش‌بینی پایدار یا ناپایدار بودن جو می‌توان به داده‌های رادیوسوند اشاره نمود که بعد از به دست آوردن میانگین روزانه‌ی داده‌ها، با استفاده از نرم‌افزار Raob شاخص‌های S, TT, LCL محاسبه شد که با آن میزان همرفت و جابجایی توده‌های هوا محاسبه می‌شود. در حقیقت با استفاده از نمودارهای ترمودینامیکی موسوم به skew-t رسم شده شاخص‌های پایداری و ناپایداری جو محاسبه شده می‌شوند.

### 3-5 شاخص کیفیت هوا

کیفیت هوا به وسیله تعیین غلظت آلاینده‌های اصلی در ایستگاه‌های سنجش اندازه‌گیری می‌شود. این ایستگاه‌ها بسته به جمعیت شهر و وسعت آن ممکن است متعدد باشند. داده‌های خام به دست آمده از سنجش آلاینده‌ها با استفاده از رابطه زیر به AQI تبدیل می‌شوند. پارامترهای مورد استفاده در رابطه بر مبنای کلاس‌های جدول 3-3 محاسبه می‌شوند. در این تحقیق برای استانداردسازی از مونوکسید کربن هشت ساعته و ذرات معلق بیست و چهار ساعته استفاده شده است (اردکانی، 1382).

$$I_p = \frac{I_{Hi} - I_{LO}}{BP_{Hi} - BP_{LO}}(C_p - BP_{LO}) + I_{LO} \quad (1-3)$$

که در این رابطه :

$$I_p = \text{شاخص کیفیت هوا برای آلاینده } C_p \quad P = \text{غلظت اندازه گیری شده آلاینده } P$$

$BP_{Hi}$  = نقطه شکستی که بزرگ تر یا مساوی  $C_p$  است  $BP_{Lo}$  = نقطه شکستی که کوچک تر یا مساوی  $C_p$  باشد

$$I_{Hi} = \text{مقدار AQI منطبق با } I_{Lo} \quad BP_{Hi} = \text{مقدار AQI منطبق با } BP_{Lo}$$

جدول 3-3 طبقات غلظت آلاینده‌ها جهت محاسبات شاخص کیفیت هوا (گلباز و همکاران، 1388)

| آلاینده                 |  |             |                          |                          | طبقه         | مقدار شاخص |
|-------------------------|--|-------------|--------------------------|--------------------------|--------------|------------|
| O <sub>3</sub><br>(ppb) | PM <sub>10</sub><br>(Mg/m <sup>3</sup> ) | CO<br>(ppm) | SO <sub>2</sub><br>(ppm) | NO <sub>2</sub><br>(ppm) |              |            |
| 0-0/06                  | 0-50                                     | 0-4/5       | 0-0/03                   | -                        | خوب          | 0-50       |
| 0/06-0/12               | 50-150                                   | 4/5-9       | -0/14<br>0/03            | -                        | سالم         | 51-100     |
| 0/12-0/20               | 150-350                                  | 9-15        | -0/3<br>0/14             | -                        | ناسالم       | 200-101    |
| 0/20-0/40               | 350-420                                  | 15-30       | 0/3-0/6                  | 0/6-1/2                  | بسیار ناسالم | 300-201    |
| > 0/40                  | > 420                                    | > 300       | >0/6                     | >1/2                     | خطرناک       | >300       |

جدول 3-4 نقاط شکست آلاینده‌ها در محاسبه شاخص کیفیت هوا (سامانه کنترل کیفیت هوای تهران)

| نقاط شکست                            |                                     |   |  |                          |                                      |                                      | AQI                | طبقه بندی کیفیت هوا       |
|--------------------------------------|-------------------------------------|---|--|--------------------------|--------------------------------------|--------------------------------------|--------------------|---------------------------|
| O <sub>3</sub><br>(ppm)<br>هشت ساعته | O <sub>3</sub><br>(ppm)<br>یک ساعته | PM <sub>2.5</sub><br>(μg/m <sup>3</sup> )<br>24 ساعته | PM <sub>10</sub><br>(μg/m <sup>3</sup> )<br>24 ساعته | CO<br>(ppm)<br>هشت ساعته | SO <sub>2</sub><br>(ppm)<br>24 ساعته | NO <sub>2</sub><br>(ppm)<br>یک ساعته |                    |                           |
| 0-0/059                              | -                                   | 0-15/4  | 0-5/4  | 0-4/4                    | 0-0/34                               | 0-0/053                              | 0-50               | پاک                       |
| 0/06-0/075                           | -                                   | 15/5-35/0   | 5/5-15/4   | 4/5-9/4                  | 0/35-0/144                           | 0/054-0/1                            | 51-100             | سالم                      |
| 0/076-0/095                          | 0/125-0/164                         | 35/1-65/4   | 15/5-25/4  | 9/5-12/4                 | 0/145-0/224                          | 0/101-0/360                          | 101-150            | ناسالم برای گروه‌های حساس |
| 0/096-0/115                          | 0/165-0/204                         | 65/5-150/4  | 25/5-35/4  | 12/5-15/4                | 0/225-0/304                          | 0/361-0/640                          | 151-200            | ناسالم                    |
| 0/116-0/374                          | 0/205-0/404                         | 150/5-250/4   | 35/5-42/4  | 15/5-30/4                | 0/305-0/604                          | 0/65-0/24                            | 201-300            | بسیار ناسالم              |
| (0)                                  | 0/405-0/504<br>0/505-0/604          | 250/5-350/4<br>350/5-500/4                            | 42/5-50/4<br>50/5-60/4                               | 30/5-40/4<br>40/5-50/4   | 0/605-0/804<br>0/805-0/1004          | 0/245-0/64<br>0/65-0/204             | 301-400<br>401-500 | خطرناک                    |

در زیر مثال‌هایی برای نحوه تعیین شاخص کیفیت هوا ارائه شده است.

مثال 1: در یک ایستگاه سنجش آلودگی هوا غلظت ازن یک‌ساعته 0/156 ppm، غلظت ازن 8 ساعته 0/130 ppm و غلظت PM<sub>10</sub> 210 µg/m<sup>3</sup> اندازه‌گیری شده است. شاخص کیفیت هوا را برای آلاینده‌های نامبرده محاسبه کنید.

حل: نقطه شکست برای PM<sub>10</sub> معادل 210 µg/m<sup>3</sup> را از جدول 2 تعیین می‌کنیم. 210 µg/m<sup>3</sup> در ردیفی قرار دارد که کمترین مقدار آن 155 µg/m<sup>3</sup> و بیشترین مقدار آن 254 µg/m<sup>3</sup> و با AQI برابر 101 تا 150 مطابقت دارد. بنابراین AQI برای PM<sub>10</sub> با داده‌های زیر قابل محاسبه است.

$$I_p = ?$$

$$C_p = 210 \mu\text{g/m}^3$$

$$BP_{Hi} = 150$$

$$BP_{Lo} = 101$$

$$I_{Hi} = 150$$

$$I_{Lo} = 101$$

$$I_{PM10} = \frac{150-101}{254-155}(210-155)+101$$

$$= \frac{49}{99}(55)+101=128$$

همین محاسبات را برای ازن یک‌ساعته معادل 0/156 ppm انجام می‌دهیم:

$$I_{O3-1-hour} = \frac{150-101}{0.164-0.125}(0.156-0.125)+101$$

$$I_{O3-1-hour} = \frac{49}{0.039}(0.039)+101=140$$

و برای ازن 8 ساعته معادل 0/130 ppm خواهیم داشت:

$$I_{O3-8-hour} = \frac{300-201}{0.374-0.116}(0.130-0.116)+201$$

$$I_{O3-8-hour} = \frac{99}{0.258}(0.014)+201=206$$

با توجه به اینکه AQI مربوط به ازن 8 ساعته از همه بالاتر است بنابراین ازن 8 ساعته مسئول آلودگی هوا شناخته می‌شود (با فرض اینکه سایر آلاینده‌ها در مقادیر پایین‌تر از استاندارد وجود داشته باشند)

مثال 2. فرض کنید غلظت PM<sub>2.5</sub> معادل 4/87 µg/m<sup>3</sup> و PM<sub>10</sub> معادل 178 µg/m<sup>3</sup> از یک ایستگاه سنجش آلاینده‌های هوا گزارش شده است. شاخص کیفیت هوا را برای این دو آلاینده محاسبه کنید.

$$I_{PM2.5} = \frac{150-101}{55.4-35.5}(48.7-35.5)+101=133$$

$$I_{PM10} = \frac{150-101}{254-155}(178-155)+101=112$$

### 3-6 تجزیه و تحلیل آماری

در ابتدا نرمال بودن داده‌ها با استفاده از آزمون Kolmogrov-Smirnov مورد بررسی قرار گرفت. غلظت آلاینده‌ها در ایستگاه مورد مطالعه توزیع نرمالی نداشتند ( $P < 0.05$ ) که با استفاده از تبدیل لگاریتمی آن‌ها نرمال‌سازی انجام پذیرفت. به منظور بررسی اختلاف معنی‌دار بین غلظت آلاینده‌ها بین فصل‌های مورد مطالعه از آنالیز واریانس یک طرفه (ANOVA) استفاده گردید. کلیه تجزیه تحلیل‌های آماری در این بخش از مطالعه، با استفاده از نرم‌افزار SPSS نسخه 16 انجام شد.

### 3-7 آنالیز حساسیت

به منظور تعیین مهم‌ترین عوامل موثر بر AQI, PM<sub>10</sub>, CO در محیط نرم افزار SPSS از ضریب پیرسون استفاده شد بدین صورت که متغیرهای آب و هواشناسی و شاخص‌های پایداری و ناپایداری همراه با مقدار AQI و PM<sub>10</sub> و CO در نرم افزار وارد شدند و تاثیر هر یک از پارامترهای هواشناسی و شاخص‌های پایداری و ناپایداری برای تخمین غلظت AQI و PM<sub>10</sub> و CO مورد بررسی قرار گرفت. بدین صورت که از آزمون پیرسون برای میزان رابطه و تاثیر همبستگی بین متغیرها استفاده شد. متغیری که بیشترین ضریب همبستگی را با غلظت آلاینده داشت اگر مثبت بود، رابطه مستقیم و متغیری که منفی باشد، بیشترین رابطه معکوس را دارد.

### 3-8 مدل‌سازی

یکی از مهم‌ترین ابزارها در بررسی اثرات منابع آلاینده و پایش آلودگی هوا و همچنین محاسبه پراکنش آلاینده‌ها در منطقه، استفاده از مدل‌سازی آلودگی هوا می‌باشد. از مدل‌های آلودگی هوا می‌توان در اهداف وسیعی از جمله بررسی اثربخشی استراتژی‌ها و راه‌کارهای کنترل و کاهش آلودگی هوا و همچنین پیش‌بینی‌های آلودگی هوا استفاده کرد. برای این منظور مدل‌های متفاوتی با کاربردهای ویژه وجود دارند. مدل بر پایه دینامیک سیالات و مدل‌های داده محور و مدل‌های اویلری فتوشیمیایی CAMx و CMAQ از جمله این مدل‌ها هستند که در مقیاس‌های بزرگ و در اهداف بررسی پراکنش آلاینده‌ها بر روی شهر تهران و همچنین پیش‌بینی‌ها روزانه وضعیت آلودگی هوا در حال استفاده می‌باشند. هدف مدل‌های داده محور پیش‌بینی با دقت بالا هستند (Wang et al, 2009). مدل‌های کیفیت هوا در چندین دهه اخیر به صورت گسترده به کار می‌روند و بر پایه محاسبات انجام شده توسط کامپیوتر شکل گرفته است. گوناگونی مدل‌ها، به درجه مهارت و روابط، نوع و تعداد منابع بستگی دارد و برای مدل‌هایی با توانمندی بالاتر، به محیط عمل وسیع‌تر و داده‌های هواشناسی کامل‌تر نیاز است. در مناطق شهری با شرایط توپوگرافی پیچیده مانند شهر تهران مدل باید به خوبی قادر به لحاظ نمودن تأثیرات غلظت زمینه آلاینده‌ها، آلاینده‌های ثانویه و تغییرات توپوگرافی در ناحیه شبیه‌سازی باشد (Moustris et al, 2010). مدل داده محوری که اخیراً توجه بسیاری را به خود معطوف نموده‌اند، شبکه‌های عصبی مصنوعی می‌باشد که در این تحقیق با استفاده از این مدل به پیش‌بینی کیفیت هوای شهر تهران پرداخته شد. از مزایای این مدل می‌توان به شبیه‌سازی سیستم‌های

غیرخطی، دقت بالا، و انجام محاسبات آن اشاره کرد (Nayak, et al, 2005). ساختار این شبکه بر مبنای ساختار مغز هست. این ساختار شامل گره‌هایی است که به یکدیگر متصل شده‌اند. هر گره، یک واحد پردازش می‌باشد و اتصال بین این گره‌ها بیانگر نحوه‌ی ارتباط بین آن‌ها می‌باشد (Jang & Gully, 1995).

### 3-8-1 شبکه عصبی مصنوعی

به منظور استفاده از شبکه‌های عصبی مصنوعی مراحل زیر انجام گرفت.

#### 3-8-1-1 ورودی‌های شبکه

انتخاب متغیرهای ورودی برای یک مدل پیش‌بینی ANN-MLP یک موضوع کلیدی است، همچنان که متغیرهای بی‌ربط و یا نویز دار ممکن است اثرات منفی بر روند آموزش داشته باشد و منجر به یک ساختار مدل بی‌ارزش پیچیده و قدرت تعمیم ضعیف می‌شود (Eleuteri et al, 2005). در مورد انتخاب متغیرهای ورودی مستقل برای برآورد پیش‌بینی کیفیت هوا، عوامل مؤثر بر غلظت آلاینده‌ها در نظر گرفته شود. به‌طور کلی این‌ها شامل پارامترهای هواشناسی (سرعت باد (WS)، جهت باد (WD)، دما (T)، رطوبت نسبی (RH)) و شاخص‌های پایداری و ناپایداری (S, TT, LCL) است که در سال‌های 1391 و 1392 اندازه‌گیری شده بودند. بر اساس مجموعه داده، تجزیه و تحلیل همبستگی، برای تجزیه و تحلیل روابط متقابل میان آلاینده‌ها و عوامل هواشناسی و شاخص‌های پایداری و ناپایداری مورد استفاده قرار گرفته تا فاکتورهای اصلی تعیین شود.

#### 3-8-1-2 استاندارد کردن داده‌ها

برای جلوگیری از کوچک شدن بیش از حد وزن‌های شبکه عصبی مصنوعی و به دلیل آموزش بهینه شبکه، داده‌ها قبل از اینکه وارد شبکه شوند در محدوده 0 و 1 با استفاده از فرمول زیر نرمالیزه شدند (Gardner & Dorling, 1998).

$$X_{nor} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2-3)$$

که در این فرمول X داده اصلی،  $x_{min}$  و  $x_{max}$ ، به ترتیب میزان حداقل و حداکثر مقدار داده اصلی و  $X_{nor}$  داده‌های استانداردسازی شده می‌باشد.

#### 3-8-1-3 دسته‌بندی داده‌ها

مجموعه داده معتبر موجود 500 نمونه است، که مطابق با پیش فرض متلب به سه زیرمجموعه تقسیم شده، یعنی مجموعه آموزش<sup>33</sup> 350 نمونه (70٪ از نمونه‌ها)، مجموعه اعتبار سنجی<sup>34</sup> 75 نمونه (15٪ از نمونه‌ها) و مجموعه‌ی آزمون<sup>35</sup> 75 نمونه (15٪ از نمونه‌ها) است. مجموعه داده‌های آموزشی برای پردازش خود یادگیری

33- Training set  
34- Validation set  
35- Test set

مدل استفاده شده، سپس با توجه به خطا تنظیم شده است. مجموعه داده‌های اعتبار سنجی برای اندازه‌گیری تعمیم شبکه استفاده است؛ مجموعه تست برای ارزیابی عملکرد شبکه پس از یادگیری استفاده می‌شود (W. C. Wang et al., 2009).

### 3-8-1-4 توابع متحرک

در این تحقیق هم برای لایه پنهان<sup>36</sup> هم برای لایه خروجی<sup>37</sup> از تابع پیش فرض متلب، تانژانت سیگموئید<sup>38</sup> استفاده شده است.

### 3-8-1-1-4 تابع انتقال سیگموئید

از این تابع انتقال در شبکه‌های پس انتشار استفاده می‌شود. این تابع انتقال مقادیر ورودی را در محدوده مثبت بی‌نهایت تا منفی بی‌نهایت دریافت کرده و بر مبنای فرمول زیر یک مقدار خروجی بین 1 و -1 تولید می‌کند

$$f(x) = \frac{1}{1+e^{-x}} \quad (3-3)$$

### 3-8-1-5 معماری و الگوریتم آموزش شبکه

شبکه عصبی پرسپترون فقط می‌تواند برای مسائل خطی مورد استفاده قرار بگیرد. اما با اضافه کردن یک لایه پنهان می‌تواند برای مسائل غیرخطی نیز مورد استفاده قرار بگیرد که پرسپترون چندلایه نامیده می‌شود. این شبکه بیشترین کاربرد را در پیش‌بینی آلودگی‌های هوا دارند (نوری و همکاران، 2008). زیرا در صورتی که شبکه به درستی آموزش داده شود با یک لایه میانی قادر به حل بسیاری از توابع است. هرچند که استفاده از چند لایه انعطاف‌پذیری را بیشتر می‌کند (رفیع پور و همکاران، 1392). با توجه به موارد گفته شده، در این تحقیق شبکه عصبی از دو لایه پنهان با 2 تا 20 نورون و یک لایه پنهان با 2 تا 20 نورون امتحان شد، و آن که کم‌ترین خطا را داشت انتخاب شد. در ساختمان شبکه عصبی تعداد لایه‌های پنهان یکی از فاکتورهای قابل توجه است. به عنوان یک نتیجه، اگر تعداد بیش از حد کوچک باشد، شبکه ممکن است برای همگرا شدن در طول آموزش، شکست بخورد. در مقابل، گره بیش از حد ممکن است منجر به بیش برآزش در طول آموزش و در نتیجه، منجر به عملکرد تعمیم ضعیف شبکه شود. پژوهش‌ها نشان داده است که یک شبکه با تنها یک لایه پنهان شامل تعداد زیادی از نورون‌ها می‌تواند هرگونه تابع تقریبی و قابل اندازه‌گیری و ساده بین عوامل ورودی و خروجی باشد (Zhang & Peng, 2014). از این رو، یک شبکه عصبی با یک لایه پنهان با 10 نورون در این تحقیق معرفی شد (Hagan, et al, 1996). خروجی

36- Hiden layer

37- Output layer

38- Tang Sigmoid function



لایه اول بردار ورودی لایه دوم را تشکیل می‌دهد. به همین ترتیب خروجی لایه دوم، بردار ورودی لایه سوم را تشکیل می‌دهد. خروجی‌های لایه دوم پاسخ واقعی شبکه را نشان می‌دهد. نورون‌های موجود در لایه بالادست با نورون‌های موجود در لایه پایین‌دست ارتباط دارند. نقش هر نورون محاسبه مجموع وزن داده‌شده به ورودی (NET) می‌باشد در کل شبکه به صورت زیر تعریف می‌شود

$$NET = \sum(W_i X_i) \quad (4-3)$$

که در آن  $X_i$  ها همان ورودی ها و  $W_i$  همان وزن ها می باشد. و سپس این مجموع از میان یک تابع به نام تابع انتقال<sup>39</sup> می باشد. تابع انتقال می تواند یک تابع خطی یا غیر خطی باشد. دو نوع از تابع مرسوم در شبکه پرسپترون چند لایه تابع سیگموئید و تابع تانژانت سیگموئید می باشد که در این تحقیق از تابع انتقال سیگموئید استفاده شده است (Agirre-Basurko et al, 2006).

$$F(NET) = \frac{1}{1+e^{-net}} \quad (5-3)$$

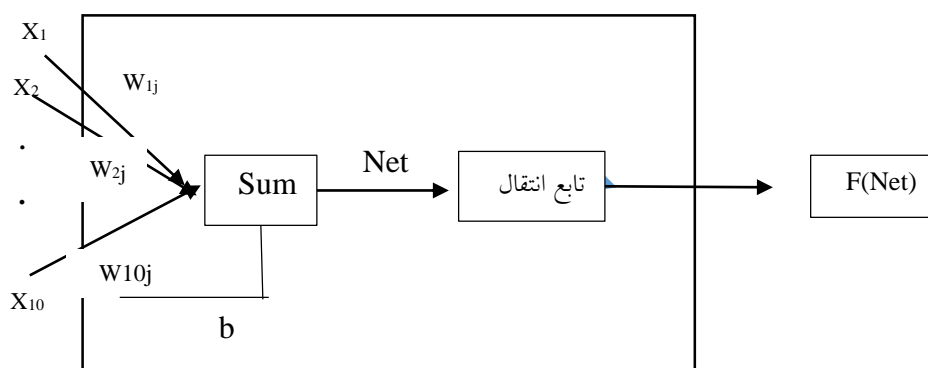
که فرایند پیش بینی شبکه مانند شکل 3-3 می باشد، که در شکل 3-3 x همان ورودی ها، w وزن ها و b بایاس، می باشد. نحوه عمل پرسترون چند لایه شبیه پرسترون تک لایه است. بدین صورت الگویی به شبکه عرضه می شود و خروجی آن محاسبه می گردد. مقایسه خروجی واقعی و خروجی مطلوب، باعث می شود که ضریب وزنی شبکه تغییر یابد به طوریکه در دفعات بعد خروجی دقیق تری حاصل می شود. قاعده فراگیری میزان کردن، ضریب وزنی شبکه را بیان می کند. در این تحقیق برای آموزش و یادگیری از الگوریتم لوبنبرگ مارکوورت (LMA)<sup>40</sup> استفاده شده است. الگوریتم لوبنبرگ - مارکوورت، به دلیل همگرایی سریعتر در آموزش شبکه های با اندازه ی متوسط، برای استفاده در تحقیق حاضر انتخاب شده است

$$\Delta W = (J^T J + \mu I)^{-1} J^T e \quad (6-3)$$

که در آن J ماتریس ژاکوبین از مشتقات هر خطا با توجه به هر وزن است،  $\mu$  یک عدد است و e خطای بردار و I ماتریس تشخیص است. پارامتر  $\mu$  تعیین وزن نزول شیب و گاوس نیوتن را از دو روش جستجو می کند .


نزول شیب زمانی که  $\mu$  بالا است، و گاوس نیوتن، درحالی که  $\mu$  پایین است (نزدیک به صفر).

39- Transfer function  
40- Levenberg Marquardt



شکل 3-3 فرایند پیش بینی شبکه عصبی مصنوعی

شکل (3-4) شمایی از شبکه عصبی مصنوعی مورداستفاده در این تحقیق را نشان می‌دهد.



شکل 3-4 شمایی از شبکه عصبی مصنوعی

3-8-1-6 ارزیابی مدل

به منظور عملکرد شبکه عصبی مصنوعی از آماره‌های ریشه میانگین مربعات خطا (RMSE)<sup>41</sup> و ضریب همبستگی (R)<sup>42</sup> استفاده گردید. مقدار (RMSE) بین 0 و 1 قرار دارد و مقدار آن هرچه به صفر نزدیک‌تر باشد نشان از دقت بالای مدل در تخمین غلظت آلاینده‌ها می‌باشد. همچنین در R<sup>2</sup> هر چه مقدار به یک نزدیک‌تر باشد مدل دقت بیشتری در تخمین غلظت آلاینده‌ها خواهد داشت


$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (q_{o(t)} - q_{p(t)})^2} \quad (7-3)$$

$$R = \frac{\sum (q_{o(t)} - q_{o(t)}) (q_{p(t)} - q_{p(t)})}{(\sum (q_{o(t)} - q_{o(t)})^2)^{0.5} (\sum_{i=1}^n (q_{p(t)} - q_{p(t)})^2)^{0.5}} \quad (8)$$

که در آن  $q_{o(t)}$  غلظت مشاهده شده با درصد t و  $q_{p(t)}$  غلظت برآورد شده با درصد t، n تعداد داده‌های مشاهداتی و  $q_{o(t)}$  میانگین غلظت برآورد شده با درصد t و  $q_{p(t)}$  میانگین دبی برآورد شده با درصد t می‌باشد. در این تحقیق در کل ایستگاه‌ها 70 درصد داده‌های برای آموزش<sup>43</sup>، 15 درصد داده‌ها برای اعتبار سنجی<sup>44</sup> و 15 درصد داده‌ها برای آزمون<sup>45</sup> به صورت تصادفی انتخاب شدند.

---

41- Root Mean Squar Error  
 42- Correlation Coefficient  
 43- Training  
 44- Validation  
 45- Test



نمودار 2-4: نمودار جریان روش تحقیق

## فصل چهارم : تجزیه و تحلیل داده‌ها و نتایج

### 1-4 جمع‌آوری داده‌ها و مدل‌سازی

همانطور که در فصل سوم عنوان شد، داده‌های هواشناسی، رادیوسوند و غلظت آلاینده‌ها به ترتیب از سازمان هواشناسی کشور و سازمان کنترل کیفیت هوای تهران، اخذ شد و پس از به دست آوردن میانگین روزانه داده‌ها و شاخص‌های پایداری و ناپایداری از روی داده‌های رادیوسوند با استفاده از نرم‌افزار Raob و به دست آوردن شاخص‌های کیفیت هوا (AQI)، داده‌ها برای ورود به شبکه استانداردسازی شد و بعد از اینکه شبکه‌های عصبی مختلف امتحان شد، شبکه عصبی پرسپترون دولایه (MLP) با 10 نورون در لایه پنهان با تابع انتقال سیگموئید انتخاب شد و برای یادگیری و آموزش آن از الگوریتم لوبنبرگ مارکوات استفاده شد و نتایج زیر به دست آمد.

### 2-4 نتایج حاصل از آنالیز حساسیت

جدول 1-4 نتایج حاصل از آنالیز حساسیت را برای CO و PM<sub>10</sub> و AQI را در ایستگاه مورد مطالعه نشان می‌دهد. همان‌گونه که مشاهده می‌شود نتایج حاصل از آنالیز حساسیت نشان داد که بیشترین میزان همبستگی مستقیم بین AQI و LCL با میزان همبستگی 0/118 وجود دارد و بیشترین میزان همبستگی معکوس AQI با S با میزان همبستگی 0/118- وجود دارد. همبستگی بین (AQI و LCL) و (AQI و رطوبت نسبی) و (AQI و جهت باد) و (AQI و سرعت باد) مثبت و مستقیم و در بقیه موارد دارای همبستگی منفی و معکوس می‌باشد، ولی در کل ارتباط AQI با تمام متغیرها پایین و نزدیک به صفر می‌باشد، ولی نسبت به ارتباط بین CO با پارامترها و PM<sub>10</sub> با پارامترها رابطه و تأثیر پایین‌تری را می‌بینیم (همبستگی دارای مقداری بین 1- و 1+ می‌باشد، هرچه همبستگی به 1+ نزدیک‌تر باشد همبستگی قوی‌تر و مستقیم می‌باشد و هرچه به 1- نزدیک‌تر باشد همبستگی قوی‌تر و معکوس‌تر می‌باشد). بیشترین میزان همبستگی مستقیم بین CO و دما با میزان همبستگی 0/167 وجود دارد و بیشترین میزان همبستگی معکوس بین رطوبت با میزان همبستگی 0/168- وجود دارد. همبستگی بین (CO و LCL) و (CO با دما) مثبت و مستقیم و در بقیه موارد دارای همبستگی منفی و معکوس می‌باشد، ولی در کل ارتباط CO با تمام متغیرها پایین و نزدیک به صفر می‌باشد و بیشترین میزان همبستگی مستقیم بین PM<sub>10</sub> و LCL با میزان همبستگی 0/267 وجود دارد و بیشترین میزان همبستگی معکوس PM<sub>10</sub> با S با میزان همبستگی 0/258- وجود دارد. همبستگی بین (PM<sub>10</sub> و LCL) و (PM<sub>10</sub> و دما) مثبت و مستقیم و در بقیه موارد دارای همبستگی منفی و معکوس می‌باشد، ولی در کل ارتباط PM<sub>10</sub> با تمام متغیرها پایین و نزدیک به صفر می‌باشد، ولی نسبت به ارتباط بین CO با پارامترها رابطه و تأثیر بهتری را می‌بینیم

| ضریب همبستگی | LCL   | S      | TT     | رطوبت  | جهت باد | سرعت باد | دما    |
|--------------|-------|--------|--------|--------|---------|----------|--------|
| CO           | 0/060 | -0/054 | -0/043 | -0/168 | -0/012  | -0/105   | 0/167  |
| PM10         | 0/267 | -0/258 | -0/234 | -0/113 | -0/069  | -0/123   | 0/205  |
| AQI          | 0/118 | -0/118 | -0/106 | 0/112  | 0/026   | 0/034    | -0/057 |

جدول 4-1: میزان همبستگی CO و PM<sub>10</sub> و AQI با پارامترهای هواشناسی و شاخص‌های پایداری و ناپایداری


3-4- شبیه‌سازی غلظت PM<sub>10</sub> و CO و AQI بر اساس همه پارامترهای هواشناسی و شاخص‌های پایداری و ناپایداری با استفاده از مدل شبکه عصبی

3-4-1 نتایج حاصل از شبیه‌سازی غلظت CO با استفاده از مدل شبکه عصبی مصنوعی


3-4-1-1 نتایج حاصل از شبیه‌سازی غلظت CO با پارامترهای هواشناسی و شاخص‌های پایداری و ناپایداری

با استفاده از پارامترهای هواشناسی و شاخص‌های پایداری و ناپایداری غلظت CO برای سه روز بعد شبیه‌سازی شد (شکل 4-1). همانطور که در شکل مشاهده می‌شود، در شکل الف و ب که غلظت فردا بر اساس غلظت روز جاری تخمین زده شده است RMSE و R به ترتیب 0/64 و 0/69 و در شکل پ و ت که غلظت دو روز بعد بر اساس غلظت روز جاری برای CO تخمین زده شده است، RMSE و R به ترتیب 0/80 و 0/40 و در شکل س و ج که غلظت سه روز بعد بر اساس غلظت روز جاری تخمین زده شده است RMSE و R به ترتیب 0/92 و 0/50 است و از آن جهت که هر چه R بیشتر و RMSE کمتر باشد نتایج بهتر است، در نتیجه پیش‌بینی فردای CO بر اساس غلظت روز جاری، نسبت به پیش‌بینی غلظت دو روز بعد و سه روز بعد بهتر بود. احتمالاً به این دلیل می‌تواند باشد که شرایط جوی امروز به فردا نزدیک‌تر است تا دو و سه روز بعد. مارتین<sup>۶</sup> و همکاران (2008) با شبکه عصبی مصنوعی، ماکسیمم غلظت روزانه سطح زمین CO را در خلیج آگسیراز اسپانیا پیش‌بینی کردند. به منظور پیش‌بینی پیک مونوکسید کربن از دو رویکرد مدل پرسپترون چندلایه (MLPs) با یادگیری رو به عقب و طبقه‌بندی نزدیک‌ترین همسایه (K-nn) استفاده کردند. یک استراتژی نمونه‌گیری مجدد با دو برابر اعتبار امکان مقایسه آماری از مدل‌ها و توپولوژی‌های مختلف در این مطالعه در نظر گرفته شد. رویکرد نمونه‌گیری مجدد


تصادفی، اجازه یک مقایسه چندگانه از مدل‌های آزمون شده را می‌دهد و همچنین امکان انتخاب یک گروه از بهترین مدل‌ها را می‌دهد. خطا برای بهترین مدل بر مبنای شبکه عصبی 20 درصد بود. در نهایت روش ارائه شده همراه با یک انتخاب مناسب از متغیرهای ورودی می‌تواند به پیش بینی حداکثر سطح آلاینده‌های جوی دیگر اعمال شود و برای پیک غلظت آلاینده CO در چهار فصل جهت مقایسه میانگین از آزمون Duncan استفاده گردید. نتایج نشان داد که بیشترین غلظت یا میانگین در تابستان و کم‌ترین غلظت در زمستان می‌باشد. یکی از دلایل آن می‌تواند این باشد که، از آنجائی که اتوبان تهران- کرج در غرب تهران قرار گرفته است، هنگامی که تردد خودروها افزایش می‌یابد منجر به افزایش ترافیک شده و در نتیجه کندی حرکت و استفاده از دنده‌های سنگین در خودروها و میزان مصرف سوخت افزایش و به تبع آن آلوده‌کننده بیشتری در هوا انتشار خواهد یافت و زمانی که وسایل نقلیه قدیمی و فرسوده باشد، انتشار آلاینده‌ها بیشتر خواهد بود. و یکی دیگر از دلایل آن می‌تواند کمبود فضاهای سبز شهری باشد و همچنین وجود بیشینه در فصل گرم می‌تواند ناشی از وارونگی دمای سطحی و کاهش بارش و شست‌وشوی آلاینده‌ها باشد. از سوی دیگر بادهای شدید غربی هم که قادر به خارج کردن هوای آلوده می‌باشند، در آسمان شهر تهران خیلی کم می‌وزند و تنها 30٪ بادهای که معمولاً در اوایل بهار و اواخر تابستان می‌وزند سرعتی بیش از 5 متر بر ثانیه دارند و قادرند هوا را پاک کنند (واحدی، 1367). البته موقعیت جغرافیایی شهر تهران نیز سبب وزش بادهای محلی می‌گردد. این بادهای حدود 66/2٪ از تمام بادهای تهران را تشکیل می‌دهد، ولی چون سرعت و قدرت کافی نداشته و از طرف دیگر ارتفاع وزش آن‌ها بین 150 تا 800 متر است، لذا قادر به خارج کردن آلودگی‌های هوای تهران نمی‌باشند. تأثیر جریان‌های اخیر آن است که در طی روز، آلودگی‌های نواحی جنوبی را به طرف شمال شهر و شمیرانات برده و در شب به نواحی جنوبی برمی‌گرداند (پور احمد، 1377). در هر حال مشکل این است که بادهای عمده از سوی غرب، جنوب و جنوب شرق که محل استقرار بیشتر صنایع است، می‌وزند. این بادهای به جای پاک کردن هوا ممکن است بیش از پیش هوا را آلوده کنند (سلطانی، 1373).




الف - RMSE



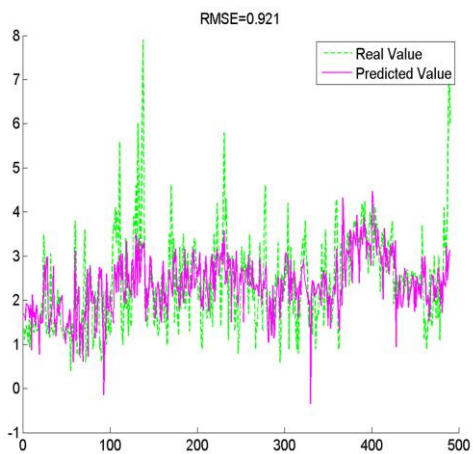
ب - R




پ - RMSE



ت - R



س - RMSE




ج - R


شکل 4-1- شکل الف و ب- غلظت CO فردا بر اساس غلظت روز جاری و شکل پ و ت- غلظت دو روز بعد بر اساس غلظت روز جاری و شکل س و ج غلظت سه روز بعد را بر اساس غلظت روز جاری نشان می دهد.



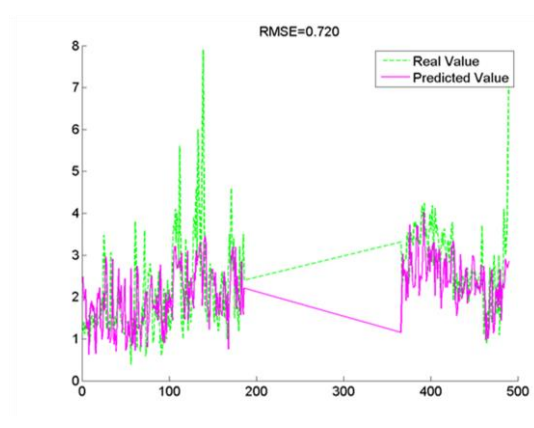
4-3-1-2 نتایج حاصل از شبیه‌سازی غلظت CO با پارامترهای هواشناسی و شاخص‌های پایداری و ناپایداری برای فصول گرم



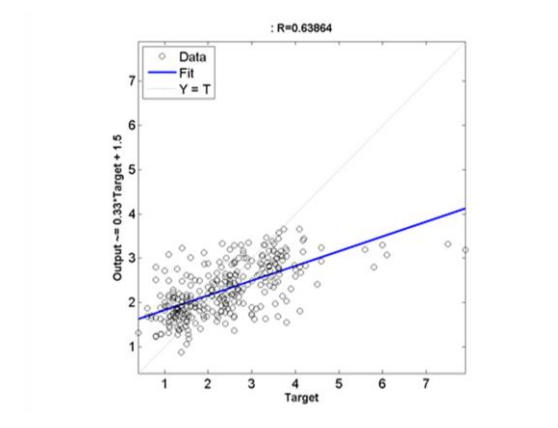
الف - RMSE



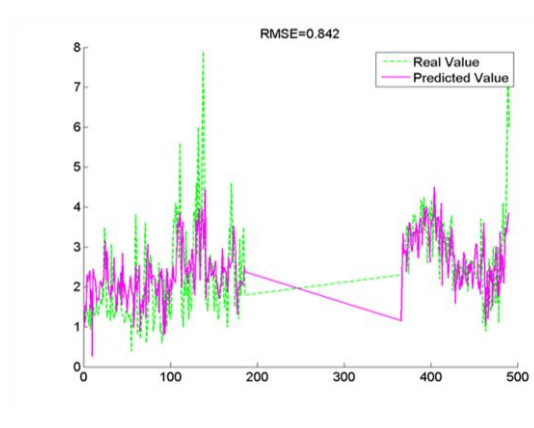
ب - R




پ - RMSE



ت - R



س - RMSE



ج - R

شکل 4-2- شکل الف و ب- غلظت CO فردا بر اساس غلظت روز جاری و شکل پ و ت- غلظت دو روز بعد بر اساس غلظت روز جاری و شکل س و ج- غلظت سه روز بعد را بر اساس غلظت روز جاری نشان می دهد.

با استفاده از پارامترهای هواشناسی و شاخص‌های پایداری و ناپایداری برای فصول گرم سال غلظت CO برای سه روز بعد شبیه‌سازی شد (شکل 4-2). همانطور که در شکل مشاهده می‌شود، در شکل الف و ب که غلظت فردا بر اساس غلظت روز جاری تخمین زده شده است RMSE و R به ترتیب 0/74 و 0/73 و در شکل پ و ت که غلظت دو روز بعد بر اساس غلظت روز جاری برای CO تخمین زده شده است، RMSE و R به ترتیب 0/73 و 0/63 و در شکل س و ج که غلظت سه روز بعد بر اساس غلظت روز جاری تخمین زده شده است RMSE و R ترتیب 0/84 و 0/47 است بنابراین پیش‌بینی فردای CO بر اساس غلظت روز جاری، نسبت به پیش‌بینی غلظت دو روز بعد و سه روز بعد بهتر بود. این نتایج به این دلیل می‌تواند باشد که احتمالاً شرایط جوی امروز به فردا نزدیک‌تر است تا دو و سه روز بعد. و با توجه به این که هر چه R بیشتر و RMSE کم‌تر باشد نتایج بهتر است در اینجا با وجود اینکه R مقدار بیشتری نشان داد ولی به همان نسبت RMSE هم بیشتر شد و در کل برای فصل گرم نتایج خوبی حاصل نشده است. روح‌الله نوری و همکاران (2010) برای پیش‌بینی غلظت روزانه مونوکسید کربن تهران از مدل توسعه‌یافته‌ی ANFIS و ANN استفاده کردند. در مطالعه آن‌ها روش‌های روبه‌جلو (FS)<sup>47</sup> و آزمون گاما (GT)<sup>48</sup> برای انتخاب متغیرهای ورودی و مدل ANFIS و ANN انتخاب شده است. از 12 متغیر، 9 متغیر با آزمون FS و GT استفاده شد. مدل‌های هیبریدی توسعه‌یافته ارزیابی شد و با مدل‌های ANFIS و ANN مقایسه شد و از همه متغیره‌ی ورودی استفاده شد و نتایج آن‌ها نشان داد که هر دو روش FS و GT، نه‌تنها خطای خروجی را کاهش می‌دهد بلکه هزینه‌های محاسباتی منجر به متغیرهای ورودی کم‌تر می‌شود. مدل‌های FS-ANN و FS-ANFIS با توجه به  $R^2$  و میانگین مطلق خطا بهترین مدل‌ها انتخاب شد و همچنین نشان داد که این دو مدل در پیش‌بینی آلاینده‌ها برتر هستند. سرانجام آنالیزهای عدم قطعیت بر مبنای شبیه‌سازی مونتو کارلو<sup>49</sup> برای مدل‌های FS-ANN و FS-ANFIS اجرا شد که مدل FS-ANN، عدم قطعیت کم‌تری دارد و همچنین این مدل به‌طور رضایت‌بخش، سطوح غلظت روزانه CO را پیش‌بینی می‌کند.

#### 3-1-3-4 نتایج حاصل از شبیه‌سازی غلظت CO با پارامترهای هواشناسی و شاخص‌های پایداری و

##### ناپایداری برای فصول سرد

با استفاده از پارامترهای هواشناسی و شاخص‌های پایداری و ناپایداری برای فصول سرد سال غلظت CO برای سه روز بعد شبیه‌سازی شد (شکل 4-3). همانطور که در شکل مشاهده می‌شود، در شکل الف و ب که غلظت فردا بر اساس غلظت روز جاری تخمین زده شده است RMSE و R به ترتیب 0/74 و 0/73 و در شکل پ و ت

47 - Forward selection

48- Gamma test

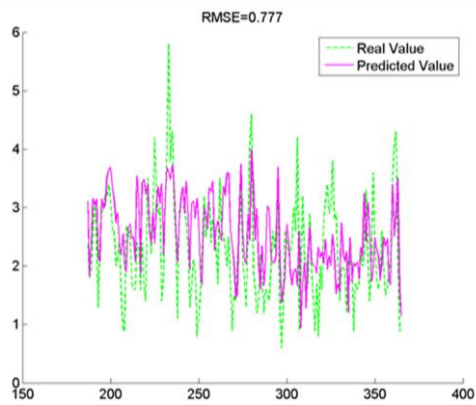
49- Monte-Carlo

که غلظت دو روز بعد بر اساس غلظت روز جاری برای CO تخمین زده شده است، RMSE و R به ترتیب 0/73 و 0/63 و در شکل س و ج که غلظت سه روز بعد بر اساس غلظت روز جاری تخمین زده شده است RMSE و R ترتیب 0/84 و 0/47 است. در این پیش‌بینی مقدار RMSE بالا رفته و مقدار R کم‌تر شده است در نتیجه پیش‌بینی فردای CO بر اساس غلظت روز جاری، نسبت به پیش‌بینی غلظت دو روز بعد و سه روز بعد بهتر بود این نتایج نشان می‌دهد که در کل برای فصل سرد سال نتایج خوبی حاصل نشده است و با توجه به توضیحات برای پیش‌بینی فصول گرم، و با توجه به RMSE و R حاصل شده برای فصل گرم نتایج بهتری نسبت به فصل سرد داشت. پیتر و زیتو<sup>50</sup> و همکاران (2008) با استفاده از شبکه عصبی CO و NO<sub>2</sub> جاده‌ها را پیش‌بینی کردند که برای این پیش‌بینی از داده‌های هواشناسی و ترافیک استفاده شد. مکان مورد مطالعه یک جاده بین بخشی در ایالت کینگ دام است. شبکه مورد استفاده در این تحقیق شامل پرسپترون چندلایه (MLP) و شبکه عصبی مدو لار (MNN) و شبکه عصبی پایه شعاعی RBF بود که برای روابط غیرخطی برای غلظت آلاینده‌ها توسعه یافت. عملکرد مدل‌ها ارزیابی شد و باهم مقایسه شد و مشخص شد که عملکرد مدل RBF بهتر از MLP و MNN<sup>51</sup> بود و MNN عملکرد پایین‌تری از RBF و MLP دارد و نشان داد که مدل RBF قادر به نمایش 97 درصد تنوع دوره‌های پیک CO و 75 درصد تنوع دوره‌های خارج از پیک برای NO<sub>2</sub> دارد. حدس زده می‌شود که تنوع باقی‌مانده به علت وجود سایر پارامترهای مهم مانند ازن و تابش خورشیدی و... در مدل‌ها باشد. آنالیز حساسیت برای تعیین مهم‌ترین متغیرهای ورودی که در برآورد غلظت آلاینده‌ها تأثیر می‌گذارند انجام شد. که این آنالیز نشان داد که آب و هوا مهم‌ترین نقش را در روند شکل‌گیری غلظت آلاینده‌ها بازی می‌کند. مطالعه استفاده از NN ها برای پیش‌بینی کوتاه‌مدت غلظت آلاینده‌های کنار جاده‌ای نشان می‌دهد که یک ارتباط عادلانه بین ترافیک حاضر و داده‌های آب هواشناسی و غلظت آلاینده وجود دارد. در نهایت این نتیجه حاصل شد که تمام مدل‌های شبکه عصبی برای پیش‌بینی با استفاده از اطلاعات محدود شده و داده‌های نویز دار، قابل اعتماد هستند.


---

50- Pietro Zito


51- modular network




الف - RMSE



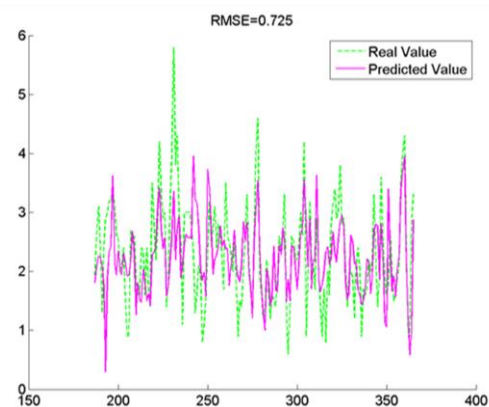
ب - R




پ - RMSE



ت - RMSE



س - RMSE



ج - R

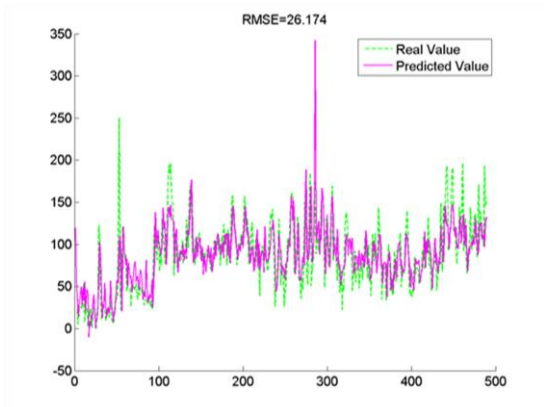
شکل 3-4- شکل الف و ب- غلظت CO فردا بر اساس غلظت روز جاری و شکل پ و ت- غلظت دو روز بعد بر اساس غلظت روز جاری و شکل س و ج غلظت سه روز بعد را بر اساس غلظت روز جاری نشان می دهد.

#### 4-3-2 نتایج حاصل از شبیه‌سازی غلظت PM<sub>10</sub> با استفاده از مدل شبکه عصبی مصنوعی


#### 4-3-2-1 نتایج حاصل از شبیه‌سازی غلظت PM<sub>10</sub> با پارامترهای هواشناسی و شاخص‌های پایداری و

##### ناپایداری


با استفاده از پارامترهای هواشناسی و شاخص‌های پایداری و ناپایداری غلظت PM<sub>10</sub> برای سه روز بعد شبیه‌سازی شد (شکل 4-4). همانطور که در شکل مشاهده می‌شود، در شکل الف و ب که غلظت فردا بر اساس غلظت روز جاری تخمین زده شده است RMSE و R به ترتیب 0/26 و 0/80 و در شکل پ و ت که غلظت دو روز بعد بر اساس غلظت روز جاری برای PM<sub>10</sub> تخمین زده شده است، RMSE و R به ترتیب 0/28 و 0/69 و در شکل س و ج که غلظت سه روز بعد بر اساس غلظت روز جاری تخمین زده شده است RMSE و R به ترتیب 0/29 و 0/64 است نتایج خوبی برای سه روز حاصل شد ولی نتیجه پیش‌بینی فردای PM<sub>10</sub> بر اساس غلظت روز جاری، نسبت به پیش‌بینی غلظت دو روز بعد و سه روز بعد بهتر بود. چالولاکو<sup>۲</sup> و همکاران (2003) در آتن<sup>۳</sup> با استفاده از مدل شبکه عصبی مصنوعی و رگرسیون خطی چندگانه به پیش‌بینی ذرات معلق (PM<sub>10</sub>) پرداختند. این مطالعه به بررسی امکان استفاده از روش شبکه عصبی به عنوان ابزاری برای پیش‌بینی غلظت روزانه ذرات (PM<sub>10</sub>) پرداخت، و به عنوان یک جایگزین برای مدل‌های آماری، استفاده شد. با داده‌های هواشناسی به عنوان متغیر ورودی طی یک دوره دو ساله، مدل‌های شبکه عصبی و مدل رگرسیون خطی چندگانه توسعه یافته، مورد بررسی قرار گرفت. مقایسه آماری، نشان داد که روش شبکه عصبی، از نظر خطای پیش‌بینی (میانگین ریشه مربعات خطا کمتر از 82٪) و توانایی پیش‌بینی دارای یک برتری نسبت به مدل‌های رگرسیون هستند. نتایج نشان می‌دهد که (ANNs)، اگر به درستی آموزش دیده شود، می‌تواند راه‌حل مناسبی برای پیش‌بینی ذرات فراهم کند. نتایج حاصل از آزمون Duncan برای مقایسات میانگین برای پیک غلظت PM<sub>10</sub> نشان داد که پیک غلظت PM<sub>10</sub> در پاییز در این ایستگاه از همه بیشتر و در بهار کم‌تر است. احتمالاً یکی از دلایل آن افزایش مصرف سوخت‌های ناشی از منابع حرارتی و پایداری هوا و وارونگی دما رخ دهد. از طرف دیگر احتمالاً شرایط هواشناسی و افزایش سرما و افزایش سرعت باد و وقوع پدیده گردوغبار (عمدتاً با منشأ خارج از تهران) مهم‌ترین عامل افزایش PM<sub>10</sub> می‌باشد و همچنین قرار گرفتن صنایع مختلف در مناطق غربی تهران که در جهت بادهای ورودی می‌باشند و همچنین آلاینده‌های خروجی از وسایل نقلیه قدیمی از جمله دلایل افزایش PM<sub>10</sub> در هوای شهر تهران گزارش شده است (اژدرپور، 1385).




الف- RMSE



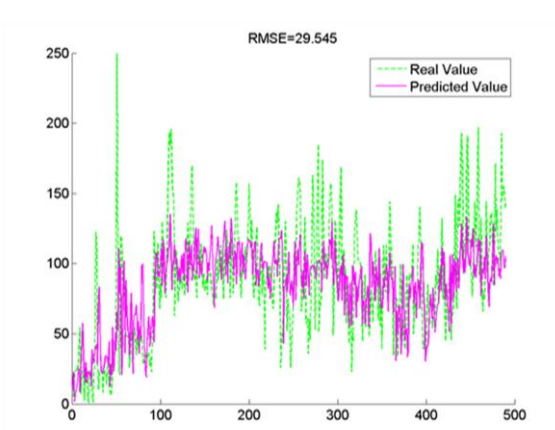
ب- R




پ- RMSE



ت- R



س- RMSE

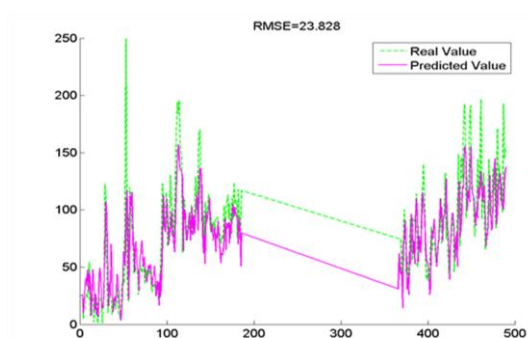


ج- R


شکل 4-4- شکل الف و ب- غلظت PM<sub>10</sub> فردا بر اساس غلظت روز جاری و شکل پ و ت- غلظت دو روز بعد بر اساس غلظت روز جاری و شکل س و ج غلظت سه روز بعد را بر اساس غلظت روز جاری نشان می

دهد


4-3-2 نتایج حاصل از شبیه‌سازی غلظت PM10 با پارامترهای هواشناسی و شاخص‌های پایداری و ناپایداری برای فصول گرم




الف- RMSE




ب- R




پ- RMSE



ت- R



س- RMSE



ج- R

شکل 4-5- شکل الف و ب- غلظت فردا بر اساس غلظت روز جاری و شکل پ و ت- غلظت دو روز بعد بر اساس غلظت روز جاری و شکل س و ج غلظت سه روز بعد را بر اساس غلظت روز جاری نشان می دهد(منبع:نگارنده)

با استفاده از پارامترهای هواشناسی و شاخص‌های پایداری و ناپایداری غلظت PM<sub>10</sub> برای فصول گرم سال برای سه روز بعد شبیه‌سازی شد (شکل 4-5). همانطور که در شکل مشاهده می‌شود، در شکل الف و ب غلظت فردا بر اساس غلظت روز جاری تخمین زده شده است. در شکل الف، مقدار RMSE، 0/23 و R به 0/80 و در شکل پ و ت، غلظت دو روز بعد بر اساس غلظت روز جاری برای PM<sub>10</sub> تخمین زده شده است، در شکل پ مقدار RMSE، 0/27 و در شکل ت، مقدار R 0/87 است و در شکل س و ج، غلظت سه روز بعد بر اساس غلظت روز جاری تخمین زده شده است. در شکل س مقدار RMSE 0/27 و در شکل ج 0/62 است، برای این سه روز نتایج خوبی به دست آمد ولی نتیجه پیش‌بینی فردای PM<sub>10</sub> بر اساس غلظت روز جاری، نسبت به پیش‌بینی غلظت دو روز بعد و سه روز بعد بهتر بود. میزان RMSE پایین، R بالا بود در نتیجه برای فصول گرم نتایج خوبی حاصل شد. پینگ وانگ<sup>۵۴</sup> و همکاران (2015) برای پیش‌بینی غلظت روزانه PM<sub>10</sub> و SO<sub>2</sub> از مدل هیبریدی شبکه عصبی مصنوعی<sup>۵۵</sup> (ANN) و ماشین بردار پشتیبان (SVM)<sup>۵۶</sup> استفاده کردند که به طور مؤثر باعث افزایش دقت پیش‌بینی شبکه عصبی مصنوعی (ANN) و ماشین بردار پشتیبان (SVM) با بازیابی خطای روش‌های سنتی می‌شود. روش هیبریدی می‌تواند در دو مرحله توصیف شود. در مرحله اول ما یک مدل پیش‌بینی (ANN) و یا (SVM) را با داده‌های تاریخی و برون‌زاد مانند پارامترهای هواشناسی به کار می‌بریم. سپس هدف پیش‌بینی توسط مدل پیش‌بینی تیلور<sup>۵۷</sup> با استفاده از اطلاعات باقی‌مانده در مرحله قبل تجدیدنظر می‌شود. نوآوری که در این رویکرد است این است که به اندازه کافی و معتبر از اطلاعات باقی‌مانده مفید در یک متغیر ورودی ناقص بهره می‌گیرد. برای ارزیابی عملکرد مدل شبکه عصبی (ANN) از فاکتورهای MAE<sup>۵۸</sup> ( میانگین خطای مطلق) و RMSE (ریشه‌ی میانگین مربعات خطا) و DA<sup>۵۹</sup> (دقت جهت) و IA<sup>۶۰</sup> (شاخص توافق) و FA<sub>2</sub><sup>۶۱</sup> (فاکتور 2) و FV<sup>۶۲</sup> (واریانس کسری) استفاده شد و برای ارزیابی عملکرد مدل (SVM) برای PM<sub>10</sub> از فاکتور MFB<sup>۶۳</sup> (میانگین انحراف کسری) و MFE<sup>۶۴</sup> (میانگین خطای کسری) و برای SO<sub>2</sub> از فاکتور IA (شاخص توافق) و DA (دقت جهت) استفاده شد. روش هیبریدی ارائه شده با یک مجموعه داده 2 ساله از غلظت روزانه PM<sub>10</sub> (ذرات با قطر کمتر از 10 میکرومتر) و غلظت SO<sub>2</sub> (سولفور دی‌اکسید) برای چهار ایستگاه کنترل آلودگی هوا در تایوان چین مورد بررسی قرار گرفت و تحلیل نظری و نتایج تجربی نشان داد که دقت مدل پیشنهادی بسیار امیدوارکننده است.

54- Ping Wang

55- Hybrid forecasting model

56- Support vector machine

57- Taylor expansion forecasting model

58- mean absolute error

59- direction accuracy

60- index of agreement

61- factor of two

62- fractional variance

63- mean fractional bias

64- mean fractional error



#### 4-3-2-3 نتایج حاصل از شبیه‌سازی غلظت PM<sub>10</sub> با پارامترهای هواشناسی و شاخص‌های پایداری و

##### ناپایداری برای فصول سرد

با استفاده از پارامترهای هواشناسی و شاخص‌های پایداری و ناپایداری غلظت PM<sub>10</sub> برای فصول سرد سال برای سه روز بعد شبیه‌سازی شد (شکل 4-6). همانطور که در شکل مشاهده می‌شود، در شکل الف و ب که غلظت فردا بر اساس غلظت روز جاری تخمین زده شده است RMSE و R به ترتیب 0/26 و 0/55 و در شکل پ و ت که غلظت دو روز بعد بر اساس غلظت روز جاری برای PM<sub>10</sub> تخمین زده شده است، RMSE و R به ترتیب 0/28 و 0/24 و در شکل س و ج که غلظت سه روز بعد بر اساس غلظت روز جاری تخمین زده شده است RMSE و R به ترتیب 0/26 و 0/57 است. نتایج خوبی برای دو روزه دست آمد ولی نتیجه پیش‌بینی غلظت سه روز بعد PM<sub>10</sub> بر اساس غلظت روز جاری، نسبت به پیش‌بینی غلظت فردا و دو روز بعد بهتر بود. و با توجه به اینکه R ها نسبت به فصول گرم پایین‌تر بود ولی در کل نتایج نسبتاً خوبی حاصل شد.


در کل نتایج شبیه‌سازی غلظت PM<sub>10</sub> برای سه روز بعد، نسبت به شبیه‌سازی غلظت CO برای سه روز بعد هم برای فصول گرم، هم برای فصول سرد و هم برای کل سال، نتایج بهتری حاصل شد. هونگ دی<sup>65</sup> و همکاران (2014) برای پیش‌بینی ذرات معلق در سطح خیابان از شبکه عصبی مصنوعی (MLP) با الگوریتم بهینه‌سازی ازدحام ذرات (PSO)<sup>66</sup> و مدل هیبریدی (MLP-CPSO) استفاده کردند و برای آموزش مدل (MLP) از سه الگوریتم (ML, PSO, <sup>67</sup>CPSO) استفاده کردند و متغیرهای ورودی شامل غلظت PM و ترافیک و شرایط آب و هواشناسی بود و برای ارزیابی عملکرد شبکه از R (ضریب همبستگی) و MSE<sup>68</sup> (میانگین مربعات خطا) استفاده شد. نتایج نشان داد که الگوریتم CPSO در مدل (MLP-CPSO) مؤثرتر از دو الگوریتم دیگر هم در توانایی پیش‌بینی و هم در صحت است و به علاوه مدل پیشنهادی، عملکرد بهتری برای ذرات ریز نسبت به ذرات درشت دارد به خاطر اینکه ذرات ریز بیشتر وابسته به پارامترهای هواشناسی دارند تا ذرات درشت و همچنین مدل نتایج بهتری را برای زمستان نسبت به بهار فراهم آورد به خاطر اینکه در بین پارامترهای هواشناسی، سرعت باد نقش مهمی را در PM<sub>10</sub> در مناطق بین بخشی شهرها دارد.

65- Hong-di


66- particle swarm optimization algorithm

67- Chaotic particle swarm optimization


68- mean square error




الف-RMSE




ب-R




پ-RMSE



ت-R



س-RMSE




ج-R


شکل 4-6- شکل الف و ب- غلظت  $PM_{10}$  فردا بر اساس غلظت روز جاری و شکل پ و ت- غلظت دو روز بعد بر اساس غلظت روز جاری و شکل س و ج غلظت سه روز بعد را بر اساس غلظت روز جاری نشان می دهد

3-3-4 نتایج حاصل از شبیه‌سازی AQI با استفاده از مدل شبکه عصبی مصنوعی


1-3-3-4 نتایج حاصل از شبیه‌سازی AQI با پارامترهای هواشناسی شاخص‌های پایداری و ناپایداری




الف-RMSE




ب-R




پ-RMSE



ت-R



س-RMSE



ج-R

شکل 4-7- شکل الف و ب-AQI فردا بر اساس روز جاری و شکل پ و ت-AQI دو روز بعد بر اساس AQI

روز جاری و شکل س و ج-AQI سه روز بعد را بر اساس AQI روز جاری نشان می‌دهد.


با استفاده از پارامترهای هواشناسی و شاخص‌های پایداری و ناپایداری AQI برای سه روز بعد شبیه‌سازی شد (شکل 4-7). همانطور که در شکل مشاهده می‌شود، در شکل الف و ب که AQI فردا بر اساس AQI روز جاری تخمین زده شده است RMSE و R به ترتیب 0/22 و 0/48 و در شکل پ و ت که AQI دو روز بعد بر اساس AQI روز جاری تخمین زده شده است، RMSE و R به ترتیب 0/22 و 0/14 و در شکل س و ج که AQI سه روز بعد بر اساس AQI روز جاری تخمین زده شده است RMSE و R به ترتیب 0/21 و 0/34 است. در این پیش‌بینی با وجود اینکه RMSE پایین است ولی با توجه به پایین بودن R نتایج خوبی حاصل نشد ولی در کل نتایج برای روز اول با توجه به بالاتر بودن R نسبت به دو روز و سه روز بعد بهتر بود. با توجه به نتایج حاصل از آزمون مقایسات میانگین دانکن بیشترین میانگین AQI در زمستان و بعد از آن پاییز و کم‌ترین میانگین در بهار بود. پیتر<sup>69</sup> (2013) و همکاران به پیش‌بینی شاخص‌های کیفیت هوا توسط شبکه‌های عصبی و سیستم استنتاج فازی<sup>70</sup> پرداختند. مجموعه‌ای از متغیرهای ورودی برای هر پیش‌بینی آلودگی هوا توسط الگوریتم ژنتیک بهینه‌سازی شد. بر اساس داده‌های اندازه‌گیری شده توسط ایستگاه نظارت جمهوری چک، مدل‌ها برای پیش‌بینی شاخص کیفیت هوا برای هر آلاینده هوا به طور جداگانه و به تبع آن، برای پیش‌بینی شاخص کیفیت هوا طراحی شد. با توجه به ریشه میانگین مربعات خطا، نتایج نشان می‌دهد که ترکیبی از مدل‌های پیش‌بینی انفرادی بهتر از پیش‌بینی توسط هر یک از مدل‌ها برای شاخص کیفیت هوا است. بنابراین، این مدل‌ها می‌تواند برای به دست آوردن دقیق‌تر پیش‌بینی‌های یک روز بعد شاخص‌های کیفیت هوا استفاده شود.

#### 4-3-3-2 نتایج حاصل از شبیه‌سازی AQI با پارامترهای هواشناسی شاخص‌های پایداری و ناپایداری برای فصول گرم


با استفاده از پارامترهای هواشناسی و شاخص‌های پایداری و ناپایداری AQI برای فصول گرم سال برای سه روز بعد شبیه‌سازی شد (شکل 4-8). همانطور که در شکل مشاهده می‌شود، در شکل الف و ب که AQI فردا بر اساس AQI روز جاری تخمین زده شده است RMSE (الف) و R (ب) به ترتیب 0/22 و 0/48 و در شکل پ و ت که AQI دو روز بعد بر اساس AQI روز جاری تخمین زده شده است، RMSE (پ) و R (ت) به ترتیب 0/22 و 0/14 و در شکل س و ج که AQI سه روز بعد بر اساس AQI روز جاری تخمین زده شده است RMSE (س) و R (ج) به ترتیب 0/21 و 0/34 است. در این مطالعه با وجود اینکه RMSE پایین است ولی با توجه

به پایین بودن R نتایج خوبی به دست نیامد و برای فصول گرم هم مثل کل سال برای روز اول نتایج نسبت به دو روز و سه روز بعد بهتر بود و در کل نتایج شبیه‌سازی AQI برای سه روز بعد بر اساس AQI روز جاری، نتایج در فصل گرم نسبت به کل سال ( با توجه به توضیحات شکل (4-8)) بهتر بود. جوز جان<sup>۷۱</sup> و همکاران (2012) برای ارزیابی و پیش‌بینی کیفیت هوا از سیستم منطق فازی و مدل‌های خود رگرسیون<sup>۷۲</sup> استفاده کردند. در این کار، دو مدل برای ارزیابی و پیش‌بینی کیفیت هوا در نظر گرفت. اول، یک مدل محاسباتی جدید برای ارزیابی کیفیت هوا به منظور ارزیابی ترکیبات سمی<sup>۷۳</sup> که می‌تواند به افراد حساس در مناطق شهری آسیب برساند، فعالیت‌های عادی را تحت تأثیر قرار دهد، توسعه داده شد. در این مدل، استفاده از یک عملگر سیگما<sup>۷۴</sup> برای ارزیابی آماری، پارامترهای سنجش کیفیت هوا با استفاده از اطلاعات داده‌های تاریخی و تعیین تأثیر منفی در کیفیت هوا بر اساس وسعت سمیت<sup>۷۵</sup>، میانگین فرکانس<sup>۷۶</sup> و انحراف آزمون<sup>۷۷</sup> پیشنهاد شد. همچنین یک سیستم استنتاج فازی برای انجام طبقه‌بندی پارامترها با استفاده از یک فرایند استدلال و یکپارچه‌سازی آن‌ها در شاخص کیفیت هوا برای توصیف میزان آلودگی در پنج مرحله: عالی<sup>۷۸</sup>، خوب<sup>۷۹</sup>، منظم<sup>۸۰</sup>، بد<sup>۸۱</sup> و خطرناک<sup>۸۲</sup>، به ترتیب معرفی شد. مدل دوم ارائه‌شده در این کار غلظت کیفیت هوا را با استفاده از یک مدل اتو رگرسیون پیش‌بینی می‌کند، و پیش‌بینی شاخص کیفیت هوا را بر اساس سیستم استنتاج فازی توسعه‌یافته قبلی فراهم می‌آورد. با استفاده از داده‌های سیستم نظارت میکزیکو سیتی<sup>۸۳</sup>، یک مقایسه میان شاخص کیفیت هوا<sup>۸۴</sup> برای سازمان‌های محیط‌زیست<sup>۸۵</sup> و مدل‌های مشابه انجام شد. نتایج نشان داد که مدل‌های استفاده‌شده یک ابزار مناسبی برای سنجش آلودگی سایت و برای ارائه راهنمایی به بهبود اقدامات احتمالی در مناطق شهری است.


- 
- 71- José Juan
  - 72- Autoregressive model
  - 73- Toxicity compand
  - 74- Sigma operator
  - 75- Toxicity limits
  - 76- Frequency average
  - 77- Deviations of toxicological tests
  - 78- Excellent
  - 79- Good
  - 80- Regular
  - 81- Bad
  - 82- Danger
  - 83- Mexico City
  - 84- Air quality index
  - 85- Environmental agencies and




الف- RMSE




ب- R




پ- RMSE



ت- R



س- RMSE




ج- R


شکل 4-8- شکل الف و ب- AQI فردا بر اساس روز جاری و شکل پ و ت- AQI دو روز بعد بر اساس AQI روز جاری و شکل س و ج- AQI سه روز بعد را بر اساس AQI روز جاری نشان می دهد.

### 3-3-4 نتایج حاصل از شبیه‌سازی AQI با پارامترهای هواشناسی شاخص‌های پایداری و ناپایداری برای


فصول سرد




الف-RMSE




ب-R




پ-RMSE



ت-R



س-RMSE



ج-R

شکل 4-9- شکل الف و ب-AQI فردا بر اساس روز جاری و شکل پ و ت-AQI دو روز بعد بر اساس AQI روز

جاری و شکل، س، و ج AQI سه روز بعد را بر اساس AQI روز جاری نشان می‌دهد.

با استفاده از پارامترهای هواشناسی و شاخص‌های پایداری و ناپایداری AQI برای فصول سرد سال برای سه روز بعد شبیه‌سازی شد (شکل 4-9). همانطور که در شکل مشاهده می‌شود، در شکل الف و ب که AQI فردا بر اساس AQI روز جاری تخمین زده شده است RMSE (الف) و R (ب) به ترتیب 0/18 و 0/55 و در شکل پ و ت که AQI دو روز بعد بر اساس AQI روز جاری تخمین زده شده است، RMSE (پ) و R (ت) به ترتیب 0/23 و 0/33 و در شکل س و ج که AQI سه روز بعد بر اساس AQI روز جاری تخمین زده شده است RMSE (س) و R (ج) به ترتیب 0/23 و 0/47 است. در این پیش‌بینی با وجود اینکه RMSE پایین است ولی با توجه به پایین بودن R نتایج خوبی به دست نیامد. ولی با توجه به بالاتر بودن R برای پیش‌بینی فردا نسبت به دو روز و سه روز بعد، نتایج بهتر بود. در کل برای AQI پیش‌بینی در فصل گرم نسبت به فصل سرد و کل سال بهتر بود. کومار<sup>86</sup> و گوپال<sup>87</sup> (2013) برای پیش‌بینی کیفیت هوا در دهلی از شبکه عصبی مصنوعی بر مبنای تجزیه به مؤلفه‌های اصلی<sup>88</sup> استفاده کردند. هدف اصلی مطالعه حاضر، پیش‌بینی AQI روزانه از طریق یک شبکه عصبی بر اساس تجزیه به مؤلفه اصلی (PCA) است. AQI معیار آلاینده‌های هوا با استفاده از AQI روز قبل و متغیرهای آب و هواشناسی، که برای تعطیلات آخر هفته و روزهای هفته تقریباً یکسان است، پیش‌بینی شده است. اجزای اصلی یک شبکه عصبی بر اساس PCA (PCA-NN) با استفاده از ماتریس همبستگی داده‌های ورودی محاسبه شد. مدل شبکه عصبی (PCA-NN) ارزیابی شد و نتایج آن با نتایج حاصل از شبکه عصبی ساخته شده و مقادیر مشاهده شده در طول 2000-2006 در چهار فصل مختلف از طریق پارامترهای آماری، مقایسه شد و نشان داد که عملکرد شبکه PCA-NN بهتر از شبکه عصبی در تمام چهار فصل است.

#### 4-4 شبیه‌سازی غلظت PM<sub>10</sub> و CO و AQI بر اساس فقط پارامترهای هواشناسی با استفاده از مدل شبکه عصبی

##### 4-4-1 نتایج حاصل از شبیه‌سازی غلظت CO با استفاده از مدل شبکه عصبی مصنوعی

##### 4-4-1-1 نتایج حاصل از شبیه‌سازی غلظت CO با پارامترهای هواشناسی برای کل سال

با استفاده از پارامترهای هواشناسی غلظت CO برای سه روز بعد شبیه‌سازی شد (شکل 4-10). همانطور که در شکل مشاهده می‌شود، در شکل الف و ب که غلظت فردا بر اساس غلظت روز جاری تخمین زده شده است RMSE و R به ترتیب 0/69 و 0/66 و در شکل پ و ت که غلظت دو روز بعد بر اساس غلظت روز جاری برای CO تخمین زده شده است، RMSE و R به ترتیب 0/86 و 0/44 و در شکل س و ج که غلظت سه روز

86- KUMAR

87- GOYAL

88- Principal Component Analysis



بعد بر اساس غلظت روز جاری تخمین زده شده است RMSE و R به ترتیب 0/79 و 0/59 است در این پیش‌بینی با توجه به اینکه R نسبتاً بالا است ولی RMSE هم بالاست و نتایج خوبی حاصل نشد، ولی پیش‌بینی برای روز اول نسبت به دو روز دیگر بهتر است. کازو تاناکا<sup>89</sup> و همکاران (1995)، غلظت مونوکسید کربن را با سیستم نورو فازی<sup>90</sup>، مدل سازی و کنترل کردند. یک الگوریتم خودسازمان‌دهی تشخیص فازی (SOFIA)<sup>91</sup> برای شناسایی سیستم‌های پیچیده مانند غلظت CO ارائه شده است. هدف اصلی SOFIA کاهش نیاز محاسباتی برای شناسایی یک مدل فازی است. به‌طور خاص، یک روش ساده برای پیدا کردن ساختار مطلوب اجزا فازی استفاده شده است. قانون  $\partial$ <sup>92</sup>، که یک روش یادگیری اساسی در شبکه‌های عصبی است، برای شناسایی پارامترهای مدل فازی استفاده می‌شود. SOFIA شامل چهار مرحله است که به‌طور مؤثر برای فهمیدن شناسایی ساختار و شناسایی پارامتر است. روش SOFIA به‌طور مشخص با یک مثال ساده است که در برخی از تمرینات مدل سازی استفاده می‌شود. نتیجه، شناسایی اثر SOFIA را نشان می‌دهد. بعداً، SOFIA به یک مشکل پیش‌بینی برای غلظت CO در هوا در شلوغ‌ترین تقاطع ترافیک در شهرستان‌های بزرگ ژاپن اعمال می‌شود. نتایج پیش‌بینی نشان می‌دهد که مدل فازی بسیار بهتر از یک مدل خطی<sup>93</sup> است. علاوه بر این، یک سیستم کنترل برای حفظ غلظت CO در یک سطح ثابت با استفاده از مدل شناسایی فازی شبیه‌سازی شده است. به دلیل پویایی تغییرات تدریجی سیستم غلظت CO در طول یک دوره زمانی طولانی، یک خود یادگیری<sup>94</sup> برای اصلاح سازی پارامترهای کنترل وار توسط قانون  $\partial$  معرفی شده است. دو کنترل‌کننده خود یادگیری در این شبیه‌سازی طراحی شده است. یک کنترل‌کننده PI<sup>95</sup> خطی خود یادگیری است. از سوی دیگر یک کنترل‌کننده PI فازی خود یادگیری<sup>96</sup> است. استحکام و سازگاری این سیستم کنترل برای اختلال و اغتشاش پارامتر مدل غلظت CO بررسی شده است. نتایج شبیه‌سازی نشان می‌دهد که کنترل‌کننده فازی خود یادگیری قوی‌تر و سازگار است.

89- Kazuo Tanaka

90- neuro-fuzzy system

91- self-organizing fuzzy identification algorithm


92-  $\partial$  Rule

93- Linear Model


94- self-learning

95- self-learning linear PI controller


96- self-learning fuzzy PI controller




الف-RMSE




ب-R




پ-RMSE



ت-R




س-RMSE




ج-R

شکل 4-10- شکل الف و ب-AQI فردا بر اساس روز جاری و شکل پ و ت-AQI دو روز بعد بر اساس AQI روز جاری و شکل س و ج-AQI سه روز بعد را بر اساس AQI روز جاری نشان می دهد.


#### 2-1-4-4 نتایج حاصل از شبیه‌سازی غلظت CO با پارامترهای هواشناسی برای فصول گرم




الف- RMSE




ب- R




پ- RMSE



ت- R



س- RMSE



ج- R

شکل 4-11- شکل الف و ب- غلظت CO فردا بر اساس غلظت روز جاری و شکل پ و ت- غلظت دو روز بعد CO بر اساس غلظت روز جاری و شکل س و ج غلظت سه روز بعد CO را بر اساس غلظت روز جاری نشان می دهد

با استفاده از پارامترهای هواشناسی برای فصول گرم غلظت CO برای سه روز بعد شبیه‌سازی شد (شکل 4-11). همانطور که در شکل مشاهده می‌شود، در شکل الف و ب که غلظت فردا بر اساس غلظت روز جاری تخمین زده شده است RMSE و R به ترتیب 0/63 و 0/74 و در شکل پ و ت که غلظت دو روز بعد بر اساس غلظت روز جاری برای CO تخمین زده شده است، RMSE و R به ترتیب 0/87 و 0/53 و در شکل س و ج که غلظت سه روز بعد بر اساس غلظت روز جاری تخمین زده شده است RMSE و R به ترتیب 0/87 و 0/69 است در این پیش‌بینی با توجه به اینکه R بالا است ولی RMSE هم بالاست و نتایج خوبی حاصل نشد، ولی پیش‌بینی برای روز اول نسبت به دو روز دیگر بهتر است و نتایج برای شبیه‌سازی غلظت سه روز بعد CO بر اساس غلظت روز جاری CO برای فصول گرم بهتر از پیش‌بینی غلظت برای کل سال بود. محمودزاده و همکاران (2013) برای پیش‌بینی مونوکسید کربن از شبکه عصبی مصنوعی و الگوریتم رقابت استعماری<sup>97</sup> استفاده کردند. در این تحقیق، مشکل پیش‌بینی غلظت CO با ترکیبی از شبکه‌های عصبی مصنوعی و روش جستجو اکتشافی سیاسی و اجتماعی به نام الگوریتم رقابت استعماری (ICA) حل شده است. ICA یک روش جستجوی اکتشافی با استفاده از فرایند رقابت استعمارطلبی و بهره‌جویانه است که به عنوان یک منبع الهام‌بخش است. توپولوژی شبکه پرسپترون چندلایه (MLP) با روش آموزش لونیبرگ-مارکوارت در پیش‌بینی به‌کاربرده شده است. به‌منظور افزایش بهره‌وری از شبکه مربوطه، ICA در شبکه MLP تحت عنوان (ICA-NN) برای بهینه‌سازی وزن شبکه هیبرید شده است. این پژوهش از مجموعه‌ای از نمونه سمی هوا جمع‌آوری شده در سایت‌های شبکه‌های نظارت در دالاس، فورت ورت در طول 2001-2006 استفاده کرده است. عملکرد روش پیشنهادی توسط میانگین مربعات خطا، برای هر دو مراحل تست و آموزش اندازه‌گیری شده است. مقایسه بین روش ترکیبی ICA-NN و شبکه MLP، ذکر این واقعیت است که ICA-NN در عملکرد قابل‌اعتماد برتر است و دقت قابل‌قبولی را برای پیش‌بینی آلاینده CO فراهم می‌کند.


#### 4-4-1-3 نتایج حاصل از شبیه‌سازی غلظت CO با پارامترهای هواشناسی برای فصول سرد

با استفاده از پارامترهای هواشناسی برای فصول سرد سال غلظت CO برای سه روز بعد شبیه‌سازی شد (شکل 4-12). همانطور که در شکل مشاهده می‌شود، در شکل الف و ب که غلظت فردا بر اساس غلظت روز جاری تخمین زده شده است RMSE (الف) و R (ب) به ترتیب 0/71 و 0/50 و در شکل پ و ت که غلظت دو روز بعد بر اساس غلظت روز جاری برای CO تخمین زده شده است، RMSE (پ) و R (ت) به ترتیب 0/87 و 0/35 و در شکل س و ج که غلظت سه روز بعد بر اساس غلظت روز جاری تخمین زده شده است RMSE


(س) و R (ج) به ترتیب 0/80 و 0/34 است، با توجه به اینکه R پایین است و RMSE هم بالاست نتایج خوبی حاصل نشد، و پیش‌بینی برای غلظت فردای CO بر اساس غلظت روز جاری نسبت به پیش‌بینی غلظت دو روز بعد و سه روز بعد غلظت CO بر اساس غلظت روز جاری CO بهتر است. در نهایت با توجه به توضیحات شکل (10-4) و (11-4) و (12-4) بهترین نتایج پیش‌بینی غلظت سه روز بعد CO بر اساس غلظت روز جاری با فقط پارامترهای هواشناسی، برای فصول سرد نسبت به فصول گرم سال و پیش‌بینی با پارامترهای هواشناسی برای کل سال بود. شاکر خطیبی<sup>98</sup> و همکاران (2015) با استفاده از شبکه عصبی مصنوعی و مدل EPR<sup>99</sup>، غلظت مونواکسید کربن را در مناطق شهری تبریز پیش‌بینی کردند. در این تحقیق، توانایی این مدل برای پیش‌بینی غلظت مونواکسید کربن (CO) در منطقه شهری تبریز مقایسه شده است. مجموعه داده غلظت CO در ایستگاه‌های ثابت توسط دفتر محیط‌زیست آذربایجان شرقی همراه با داده‌های هواشناسی به دست آمده از دفتر هواشناسی آذربایجان شرقی از مارس 2007 تا مارس 2013، به عنوان ورودی برای ANN و مدل EPR استفاده شد. و قبل از استفاده داده‌ها نرمال‌سازی شد و برای ارزیابی عملکرد مدل شبکه عصبی از میانگین مربع خطا (MSE) و ریشه میانگین مربعات خطا (RMSE) و میانگین مطلق خطا (MAE) و ضریب همبستگی ( $R^2$ ) استفاده شد. بر اساس نتایج، مدل EPR نمی‌تواند بر روابط غیرخطی داده‌های ورودی غلبه کند با این حال، مدل ANN نتایج دقیق‌تری نسبت به EPR نشان داد و عملکرد ANN در مقایسه با EPR قابل اعتمادتر بود. با استفاده از مدل شبکه عصبی مصنوعی، مقدار ضریب همبستگی ( $R^2$ ) در تمام ایستگاه‌های مانیتورینگ بالای 0/85 محاسبه شد. در حالی که،  $R^2$  برای این ایستگاه با استفاده از مدل EPR مقدار 0.41 به دست آمد. از این رو، مدل ANN ابزار قوی برای پیش‌بینی غلظت آلاینده هوا هستند.

98- Shakerkhatibi


99- evolutionary polynomial regression




الف- RMSE




ب- R




پ- RMSE



ت- R



س- RMSE




ج- R


شکل 4-12- شکل الف و ب- غلظت CO فردا بر اساس غلظت روز جاری و شکل پ و ت- غلظت دو روز بعد CO بر اساس غلظت روز جاری و شکل س و ج غلظت سه روز بعد CO را بر اساس غلظت روز جاری نشان می دهد

4-4-2 نتایج حاصل از شبیه سازی غلظت PM10 با استفاده از مدل شبکه عصبی مصنوعی


#### 1-2-4-4 نتایج حاصل از شبیه‌سازی غلظت PM<sub>10</sub> با فقط پارامترهای هواشناسی برای کل سال




الف- RMSE




ب- R




پ- RMSE



ت- R



س- RMSE



ج- R

شکل 4-13- شکل الف و ب- غلظت PM<sub>10</sub> فردا بر اساس غلظت روز جاری و شکل پ و ت- غلظت دو روز بعد PM<sub>10</sub> بر اساس غلظت روز جاری و شکل س و ج غلظت سه روز بعد PM<sub>10</sub> را بر اساس غلظت روز جاری نشان می

با استفاده از پارامترهای هواشناسی و شاخص‌های پایداری و ناپایداری غلظت PM<sub>10</sub> برای سه روز بعد شبیه‌سازی شد (شکل 4-13). همانطور که در شکل مشاهده می‌شود، در شکل الف و ب که غلظت فردا بر اساس غلظت روز جاری تخمین زده شده است RMSE (الف) و R (ب) به ترتیب 0/24 و 0/77 و در شکل پ و ت که غلظت دو روز بعد بر اساس غلظت روز جاری برای PM<sub>10</sub> تخمین زده شده است، RMSE (پ) و R (ت) به ترتیب 0/26 و 0/67 و در شکل س و ج که غلظت سه روز بعد بر اساس غلظت روز جاری تخمین زده شده است RMSE (س) و R (ج) به ترتیب 0/29 و 0/53 است و با توجه به این، نتایج خوبی برای سه روز حاصل شد ولی نتیجه پیش‌بینی فردای PM<sub>10</sub> بر اساس غلظت روز جاری، نسبت به پیش‌بینی غلظت دو روز بعد و سه روز بعد بهتر بود. لوئیس<sup>۱۰۰</sup> و همکاران (2008) از مدل ترکیبی ARIMA و شبکه‌های عصبی مصنوعی برای پیش‌بینی ذرات در مناطق شهری Temuco، در شیلی استفاده کردند. با استفاده از اندازه‌گیری هواشناسی سطح و PM<sub>10</sub> یک مدل ترکیبی ARIMA و شبکه عصبی مصنوعی به منظور بهبود دقت پیش‌بینی برای یک منطقه با کیفیت هوا محدود و داده‌های هواشناسی برای Temuco، شیلی، که در آن سوزاندن چوب مسکونی یک منبع آلودگی بزرگ در طول دوره سرد زمستان است به کار گرفته شد. نتایج تجربی نشان داد که مدل ترکیبی می‌تواند یک ابزار مؤثر برای بهبود دقت پیش‌بینی PM<sub>10</sub> به دست آمده توسط هر یک از مدل‌های مورد استفاده به طور جداگانه، و در مقایسه با مدل قطعی MLR باشد. مدل ترکیبی به ترتیب قادر به دام انداختن 100٪ و 80٪ دوره‌ها یا حادثه‌های هشدار<sup>۱۰۱</sup> و پیش‌اضطراری<sup>۱۰۲</sup> بود، این رویکرد به طور بالقوه در سایر شهرستان‌ها و کشورها برای پیش‌بینی کیفیت هوا به کار برده شد.

#### 4-4-2-2-4-2 نتایج حاصل از شبیه‌سازی غلظت PM<sub>10</sub> با فقط پارامترهای هواشناسی برای فصول گرم

با استفاده از پارامترهای هواشناسی غلظت PM<sub>10</sub> برای فصول گرم برای سه روز بعد شبیه‌سازی شد (شکل 4-14). همانطور که در شکل مشاهده می‌شود، در شکل الف و ب که غلظت فردا PM<sub>10</sub> بر اساس غلظت روز جاری تخمین زده شده است RMSE (الف) و R (ب) به ترتیب 0/21 و 0/84 و در شکل پ و ت که غلظت دو روز بعد PM<sub>10</sub> بر اساس غلظت روز جاری برای PM<sub>10</sub> تخمین زده شده است، RMSE (پ) و R (ت) به ترتیب 0/27 و 0/74 و در شکل س و ج که غلظت سه روز بعد PM<sub>10</sub> بر اساس غلظت روز جاری PM<sub>10</sub> تخمین زده شده است RMSE (س) و R (ج) به ترتیب 0/29 و 0/65 است و نتایج خوبی برای سه روز حاصل شد ولی نتیجه پیش‌بینی فردای PM<sub>10</sub> بر اساس غلظت روز جاری، نسبت به پیش‌بینی غلظت PM<sub>10</sub> در دو روز بعد

100- Luis A. Díaz-Robles

101- alert episodes


102- pre-emergency episodes




و سه روز بعد بهتر بود.. و در نهایت با توجه به توضیحات شکل (4-13) و شکل (4-14) نتایج برای پیش‌بینی غلظت سه روز بعد  $PM_{10}$  بر اساس غلظت روز جاری  $PM_{10}$  برای فصول گرم با پارامترهای هواشناسی نسبت به پیش‌بینی غلظت سه روز بعد  $PM_{10}$  بر اساس غلظت  $PM_{10}$  روز جاری با فقط پارامترهای هواشناسی، برای کل سال بهتر بود. پاناستازیوس<sup>۱۰۳</sup> و همکاران (2007) شبکه‌های عصبی و مدل‌های رگرسیون چندگانه را به منظور پیش‌بینی سطح  $PM_{10}$  در شهرهای متوسط مقیاس مدیترانه توسعه و ارزیابی کردند. هدف پژوهش حاضر، مدل‌های در حال توسعه با استفاده از رگرسیون چندگانه و روش شبکه‌های عصبی (NN) است که ممکن است به طور دقیق پیش‌بینی‌های غلظت روزانه 24 ساعت بعد  $PM_{10}$  را به طور متوسط تولید کند و تکنیک‌های ذکر شده را باهم مقایسه کند. داده‌های آلودگی و متغیرهای هواشناسی در منطقه شهری ولس، شهرستان ساحلی متوسط در یونان مرکزی، که جمعیت و صنعت به طور مداوم افزایش می‌یابد، جمع‌آوری شد. هر دو مدل پنج متغیر را به عنوان ورودی استفاده کردند، که متغیرهای آب و هواشناسی (تفاوت بین حداکثر و حداقل روزانه و حداقل مقدار ساعتی دمای زمین و مقدار میانگین روزانه سرعت باد)، تداوم در سطح  $PM_{10}$  و تنوع هفتگی و سالانه غلظت  $PM_{10}$ ، را ترکیب می‌کند. اعتبار مدل نشان داد که مدل NN مهارت‌های کمی بهتر در پیش‌بینی غلظت  $PM_{10}$  نسبت به مدل رگرسیون دارد، رگرسیون و مدل NN می‌تواند به ترتیب 55 و 61 درصد از واریانس داده‌ها<sup>۱۰۴</sup>، را پیش‌بینی کند. علاوه بر این، چندین شاخص آماری مانند انحراف استاندارد (SD)<sup>۱۰۵</sup> و میانگین خطای انحراف (MBE)<sup>۱۰۶</sup> و ریشه میانگین مربعات خطا (RMSE) و ضریب همبستگی (R) و شاخص توافق (d)<sup>۱۰۷</sup> و درصد تصحیح (PC)<sup>۱۰۸</sup> و احتمال تشخیص (POD)<sup>۱۰۹</sup> و احتمال تشخیص نادرست (POFD)<sup>۱۱۰</sup>، به منظور بررسی کیفیت و قابلیت اطمینان مدل‌های توسعه‌یافته محاسبه شد. نتایج نشان داد که مهارت‌ها رضایت‌بخش هستند، و تفاوت‌های جزئی را ارائه داد. همچنین مشخص شد که هر دو قادر به پیش‌بینی تجاوز مقدار حدود  $50Mg/m^3$  در سطح رضایت‌بخش است.

---


103- Papanastasiou  
 104- variance data  
 105- Standard deviation  
 106- Mean bias error  
 107- Index of agreement  
 108- Percent correct  
 109- Probability of detection  
 110-Probability of false detection




الف- RMSE




ب- R




پ- RMSE



ت- R



س- RMSE




ج- R


شکل 4-14- شکل الف و ب- غلظت  $PM_{10}$  فردا بر اساس غلظت روز جاری و شکل پ و ت- غلظت دو روز بعد  $PM_{10}$  بر اساس غلظت روز جاری و شکل س و ج غلظت سه روز بعد  $PM_{10}$  را بر اساس غلظت روز جاری نشان می

دهد.

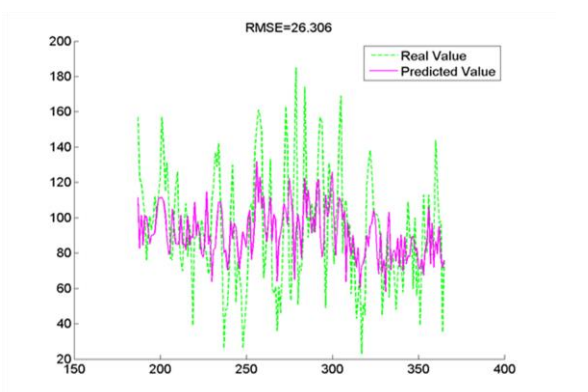
#### 3-2-4-4 نتایج حاصل از شبیه‌سازی غلظت PM<sub>10</sub> با فقط پارامترهای هواشناسی برای فصول سرد




الف-RMSE




ب-R




پ-RMSE



ت-R



س-RMSE



ج-R

شکل 4-15- شکل الف و ب- غلظت PM<sub>10</sub> فردا بر اساس غلظت روز جاری و شکل پ و ت- غلظت دو روز بعد PM<sub>10</sub> بر اساس غلظت روز جاری و شکل س و ج غلظت سه روز بعد PM<sub>10</sub> را بر اساس غلظت روز جاری

۰۰۰۰

با استفاده از پارامترهای هواشناسی غلظت PM<sub>10</sub> برای فصول سرد سال برای سه روز بعد شبیه‌سازی شد (شکل 4-14). همانطور که در شکل مشاهده می‌شود، در شکل الف و ب که غلظت فردا PM<sub>10</sub> بر اساس غلظت روز جاری PM<sub>10</sub> تخمین زده شده است RMSE (الف) و R (ب) به ترتیب 0/22 و 0/55 و در شکل پ و ت که غلظت دو روز بعد PM<sub>10</sub> بر اساس غلظت روز جاری برای PM<sub>10</sub> تخمین زده شده است، RMSE (پ) و R (ت) به ترتیب 0/26 و 0/25 و در شکل س و ج که غلظت سه روز بعد PM<sub>10</sub> بر اساس غلظت روز جاری PM<sub>10</sub> تخمین زده شده است RMSE (س) و R (ج) به ترتیب 0/29 و 0/61 است و با وجود RMSE پایین، R هم پایین بود ولی نتیجه پیش‌بینی سه روز بعد PM<sub>10</sub> (با مقدار R 0/61) بر اساس غلظت روز جاری، نسبت به پیش‌بینی غلظت PM<sub>10</sub> برای فردا (با مقدار R 0/55) و دو روز بعد (با مقدار R 0/25) بهتر بود و در نهایت نتایج برای پیش‌بینی غلظت سه روز بعد PM<sub>10</sub> با پارامترهای هواشناسی برای فصول گرم نسبت به پیش‌بینی غلظت سه روز بعد PM<sub>10</sub> برای فصول سرد و پیش‌بینی غلظت سه روز بعد با پارامترهای هواشناسی برای کل سال بهتر بود. آل صفوفی<sup>111</sup> و عبدالحمید<sup>112</sup> (2011) برای پیش‌بینی غلظت سطح PM<sub>10</sub> بر اساس پارامترهای گازی و اب و هواشناسی، رگرسیون خطی چندگانه و مدل شبکه عصبی انتشار روبه‌جلو را مقایسه کردند. هدف این مطالعه تعیین بهترین روش بین رگرسیون خطی چندگانه (MLR) و مدل شبکه عصبی مصنوعی پس انتشار پیش‌خور (ANN)<sup>113</sup> برای پیش‌بینی غلظت در پولاتو پینانگ<sup>114</sup> است. مدل‌های رگرسیون چندگانه و شبکه‌های عصبی برای سبرانگ جایا<sup>115</sup>، پولاتو پینانگ با همان متغیرهای مستقل مورد بررسی قرار گرفت، یک مطالعه مقایسه‌ای بین دو روش فراهم آورد. مقایسه مدل‌های آماری با استفاده از دقت پیش‌بینی (PA)<sup>116</sup>، ضریب تعیین (R<sup>2</sup>)، شاخص توافق (IA)، خطای مطلق نرمال شده (NAE)<sup>117</sup> و میانگین مربعات خطا (RMSE) نشان می‌دهد که شبکه‌های عصبی مصنوعی بهتر از MLR است.

#### 4-4-3 نتایج حاصل از شبیه‌سازی AQI با استفاده از مدل شبکه عصبی مصنوعی

#### 4-4-3-1 نتایج حاصل از شبیه‌سازی AQI با فقط پارامترهای هواشناسی برای کل سال

با استفاده از پارامترهای هواشناسی AQI برای سه روز بعد شبیه‌سازی شد (شکل 4-16). همانطور که در شکل مشاهده می‌شود، در شکل الف و ب که AQI فردا بر اساس AQI روز جاری تخمین زده شده است RMSE (الف) و R (ب) به ترتیب 0/21 و 0/55 و در شکل پ و ت که AQI دو روز بعد بر اساس AQI روز جاری

111- UI-Sauffie

112- Abdul Hamid

113- Feedforward Backpropagation Artificial Neural Network

114- Pulau Pinang

115- Seberang Jaya

116- Prediction Accuracy

117- Normalised Absolute Error

تخمین زده شده است، RMSE (پ) و R (ت) به ترتیب 0/22 و 0/32 و در شکل س و ج که AQI سه روز بعد بر اساس AQI روز جاری تخمین زده شده است RMSE (س) و R (ج) به ترتیب 0/20 و 0/41 است. و باتوجه به اینکه RMSE پایین است ولی با توجه به پایین بودن R نتایج خوبی حاصل نشد ولی در نهایت نتایج برای پیش بینی فردای AQI بر اساس AQI روز جاری، با توجه به بالاتر بودن R (با مقدار 0/55) نسبت به پیش بینی AQI دو روز بعد و سه روز بعد (با مقدار 0/32 و 0/41) بر اساس AQI روز جاری بهتر بود. دانگ شن چنگ<sup>118</sup> و همکاران (2015) یک روش ترکیبی را برای پیش بینی کیفیت هوا در طول دوره آلودگی با غلظت بالای PM استفاده کردند. در این مطالعه، یک رویکرد ترکیبی از ترکیب پیش بینی عددی با آنالیزهای آماری برای پیش بینی غلظت بالای PM<sub>10</sub> (ذرات آئروسول با قطر ایرودینامیکی کمتر از 10 میکرومتر) در پکن، چین ارائه شد. این رویکرد برای پیش بینی روزانه PM<sub>10</sub> در پکن، از 1 ژانویه 2013 تا 30 دسامبر مورد استفاده قرار گرفت. سیستم مدل سازی WRF-CMAQ نیز برای شبیه سازی PM<sub>10</sub> در همان دوره در پکن استفاده شد. پس از آن عملکرد دو روش با توجه به میانگین انحراف (MB)<sup>119</sup>، انحراف میانگین نرمال (NMB)<sup>120</sup>، میانگین خطای ناخالص نرمال (MNE)<sup>121</sup>، و میانگین انحراف نرمال (MNB)<sup>122</sup>، خطای ناخالص نرمال میانگین (MNE)<sup>123</sup>، و ریشه میانگین مربعات خطا (RMSE) مورد بررسی قرار گرفت. نتایج نشان می دهد که هر دو روش در طول دوره غلظت کم PM<sub>10</sub> (غلظت  $PM_{10}Mg/m^3 < 250$ ) به خوبی عمل می کند، MB، NMB، MNB، MNE و RMSE برای رویکرد ترکیبی در طول دوره غلظت کم، PM<sub>10</sub> 24/88، 26/15، 41/94٪، 43/23٪، 56/35٪ و 61/67 درصد بود. MBV، NMB، NME، MNB، MNE و RMSE برای CMAQ در طول دوره غلظت کم، PM<sub>10</sub> 6/04، 57/47٪، 41/49٪، 21/52٪، 55/64٪ و 60/11 بود. در حالی که MB، NMB، NME، MNB، MNE و RMSE برای CMAQ در طول دوره غلظت بالا  $PM_{10} \leq 250Mg/m^3$ ، 162/87، 50/37٪، 50/37٪، 49/86٪، 175/93، به ترتیب، بود. MB، NMB، NME، MNB، MNE و RMSE برای رویکرد ترکیبی در طول دوره غلظت بالا PM<sub>10</sub> 30/3، 9/37٪، 23/21٪، 8/21٪، 24/25٪ و 97/37 بود. رویکرد ترکیبی، بهبود قابل توجهی در دقت در طول دوره غلظت بالای PM<sub>10</sub> را نشان می دهد.

118- Dongsheng Chen


119- mean bias

120- normalized mean bias


121- normalized mean gross error

122-mean normalized bias


123- mean normalized gross error




الف- RMSE




ب- R




پ- RMSE



ت- R




س- RMSE




ج- R

شکل 4-16- شکل الف و ب- AQI فردا بر اساس روز جاری و شکل پ و ت- AQI دو روز بعد بر اساس AQI روز جاری و شکل س و ج AQI سه روز بعد را بر اساس AQI روز جاری نشان می دهد.


#### 4-3-3-2 نتایج حاصل از شبیه‌سازی AQI با فقط پارامترهای هواشناسی برای فصول گرم




الف- RMSE




ب- R




پ- RMSE



ت- R



س- RMSE



ج- R

شکل 4-17- شکل الف و ب- غلظت فردا بر اساس غلظت روز جاری و شکل پ و ت- غلظت دو روز بعد بر اساس غلظت روز جاری و شکل س و ج غلظت سه روز بعد را بر اساس غلظت روز جاری نشان می دهد(منبع: نگارنده).

با استفاده از پارامترهای هواشناسی AQI برای سه روز بعد برای فصول گرم شبیه‌سازی شد (شکل 4-17). همانطور که در شکل مشاهده می‌شود، در شکل الف و ب که AQI فردا بر اساس AQI روز جاری تخمین زده شده است RMSE (الف) و R (ب) به ترتیب 0/18 و 0/61 و در شکل پ و ت که AQI دو روز بعد بر اساس AQI روز جاری تخمین زده شده است، RMSE (پ) و R (ت) به ترتیب 0/15 و 0/38 و در شکل س و ج که AQI سه روز بعد بر اساس AQI روز جاری تخمین زده شده است RMSE (س) و R (ج) به ترتیب 0/16 و 0/40 است. و از آن جهت که هر چه R بیشتر و RMSE کم‌تر باشد نتایج بهتر است، ولی در این پیش‌بینی با وجود اینکه RMSE پایین است ولی با توجه به پایین بودن R نتایج خوبی حاصل نشد ولی در نهایت نتایج برای پیش‌بینی فردای AQI بر اساس AQI روز جاری، با توجه به بالاتر بودن R (با مقدار 0/61) نسبت به پیش‌بینی AQI دو روز بعد و سه روز بعد (با مقدار 0/38 و 0/40) بر اساس AQI روز جاری بهتر بود. ماهان‌جی<sup>۱۲</sup> و همکاران (2006) بر اساس روش شبکه عصبی کیفیت هوای محیط را پیش‌بینی کردند. هدف از این مقاله، بررسی اثربخشی مدل شبکه عصبی مصنوعی شد (ANN) با شبکه عصبی انتشار روبه عقب (BPNN) برای پیش‌بینی کیفیت هوای محیط برای کنترل کیفیت هوا در ایالات مالزی، بود. داده‌ها شامل داده‌های جمع‌آوری دو ماه قبل، از شروع نوامبر 2004 بود. کیفیت هوای محیط نقش مهمی در ارزیابی کیفیت هوا بازی می‌کند. شبکه عصبی مصنوعی ساده‌سازی می‌کنند و به محاسبه کیفیت هوای محیط، نسبت به روش حال حاضر موجود، سرعت می‌بخشند. برای این منظور، مدل شبکه عصبی یک جایگزین جالب برای هوا فراهم می‌کند. مقایسه بین داده‌ها پیش‌بینی مدل و مشاهدات واقعی، نشان می‌دهد که نتیجه امیدوارکننده‌ای در مدل ANN توسعه یافته در پیش‌بینی کیفیت هوای محیط (AAQ) مؤثر و دقیق وجود دارد.

#### 4-3-4-3 نتایج حاصل از شبیه‌سازی AQI با فقط پارامترهای هواشناسی برای فصول سرد

با استفاده از پارامترهای هواشناسی AQI برای سه روز بعد برای فصول سرد شبیه‌سازی شد (شکل 4-18). همانطور که در شکل مشاهده می‌شود، در شکل الف و ب که AQI فردا بر اساس AQI روز جاری تخمین زده شده است RMSE (الف) و R (ب) به ترتیب 0/20 و 0/43 و در شکل پ و ت که AQI دو روز بعد بر اساس AQI روز جاری تخمین زده شده است، RMSE (پ) و R (ت) به ترتیب 0/23 و 0/48 و در شکل س و ج که AQI سه روز بعد بر اساس AQI روز جاری تخمین زده شده است RMSE (س) و R (ج) به ترتیب 0/21 و 0/33 است. و در این پیش‌بینی با وجود اینکه RMSE پایین است ولی با توجه به پایین بودن R نتایج خوبی حاصل نشد ولی در نهایت نتایج برای پیش‌بینی دو روز بعد AQI بر اساس AQI روز جاری، با توجه به بالاتر بودن R (با



مقدار 0/48) نسبت به پیش‌بینی AQI فردا و سه روز بعد (با مقدار 0/38 و 0/40) بر اساس AQI روز جاری بهتر بود. و با توجه به توضیحات شکل (4-18) و شکل (4-17) و شکل (4-16)، نتایج پیش‌بینی سه روز بعد AQI بر اساس AQI روز جاری با پارامترهای هواشناسی برای فصول گرم نسبت به پیش‌بینی سه روز بعد AQI بر اساس AQI روز جاری با پارامترهای هواشناسی برای فصول سرد و پیش‌بینی سه روز بعد AQI بر اساس AQI روز جاری با پارامترهای هواشناسی برای کل سال، بهتر بود. گوپال<sup>۱۲۵</sup> و داشور<sup>۱۲۶</sup> (2011) مدل منطق فازی<sup>۱۲۷</sup> را برای نظارت شاخص کیفیت هوا استفاده کردند. شاخص کیفیت هوا یک راه ساده و قابل‌تعمیم برای توصیف کیفیت هوا در ایالات‌متحده، چین، هنگ‌کنگ، مالزی قرار گرفت، و در حال حاضر در هند است. در ایالات‌متحده، شاخص کیفیت هوا که عمدتاً شاخص مرتبط با سلامت است را با کلمات: "خوب (0-50)", "متوسط (51-100)", "ناسالم برای گروه‌های حساس (101-150)", "ناسالم (151-200)", "بسیار ناسالم (201-300)", "خطرناک (301-400)", "بسیار خطرناک (401-500)" توصیف می‌کند. آژانس حفاظت محیط‌زیست ایالات‌متحده<sup>۱۲۸</sup> مسئول اندازه‌گیری میزان آلودگی هوا در ایالات‌متحده است. در ایالات‌متحده AQI در سطح 5 آلاینده‌های جوی، یعنی دی‌اکسید گوگرد (SO<sub>2</sub>)، دی‌اکسید نیتروژن (NO<sub>2</sub>)، ذرات معلق (PM)، مونوکسید کربن (CO) و ازن (O<sub>3</sub>) در ایستگاه‌های نظارت در طول هر شهرستان اندازه‌گیری می‌شود. یک نمره فردی به سطح هر یک از آلاینده اختصاص می‌یابد و AQI نهایی بالاترین نمره را می‌گیرد. اندازه‌گیری کیفیت هوا معمولاً در شرایط میکروگرم در هر مترمکعب (μgm / M<sup>3</sup>) و یا قسمت در میلیون (ppm) گزارش می‌شود. روش متداول برای محاسبه AQI روش خطی است. در این مطالعه، سیستم منطق فازی با نرم‌افزار سیمولینک<sup>۱۲۹</sup> برای محاسبه AQI اعمال شده است. این روش نتیجه رضایت‌بخش می‌دهد و تحت حالت کار مداوم، کارآمد می‌باشد.

---


125- Gopal

126- Dashore


127- Fuzzy logic model

128- U.S. Environmental Protection Agency responsible


129- Simulink




الف- RMSE




ب- R




پ- RMSE



ت- R



س- RMSE



ج- R


شکل 4-18- شکل الف و ب- AQI فردا بر اساس روز جاری و شکل پ و ت- AQI دو روز بعد بر اساس AQI روز جاری و شکل س و ج- AQI سه روز بعد را بر اساس AQI روز جاری نشان می دهد.

#### 5-4 بررسی غلظت CO و PM<sub>10</sub> و AQI در روزهای هفته و پایان هفته

برای بررسی غلظت آلاینده CO و PM<sub>10</sub> و AQI در روزهای هفته و آخر هفته از نرم افزار sigmaplot 12.0 استفاده شد و نتایج زیر حاصل شد

#### 4-5-1 بررسی غلظت CO در روزهای هفته و پایان هفته


غلظت CO برای روزهای هفته و آخر هفته بررسی شد شکل (4-19). همانطور که در شکل مشاهده می شود، غلظت CO در روزهای اوایل هفته (شنبه و یکشنبه و دوشنبه)، بیشتر از پایان هفته (جمعه) بود. و در روزهای (سه شنبه و چهارشنبه و پنجشنبه) کمتر از پایان هفته (جمعه) بود. و بیشترین غلظت در دوشنبه بود. علت بالاتر بودن غلظت در روزهای شنبه تا دوشنبه می تواند به علت شروع هفته و باز شدن مدارس و ادارات و حجم ترافیک ناشی از وسایل نقلیه به خصوص وسایل نقلیه قدیمی باشد و پایین تر بودن غلظت آلاینده در روزهای هفته (سه شنبه و چهارشنبه و پنجشنبه) و پایان هفته (جمعه)، می تواند به علت تعطیل شدن مدارس و ادارات در روزهای پنجشنبه و جمعه باشد و علت بیشتر شدن بودن غلظت آن در روز دوشنبه می تواند ناشی از اوج ترافیک در وسط هفته و اثرات تجمعی شنبه و یکشنبه باشد.



شکل (4-19) غلظت CO در روزهای هفته و پایان هفته (منبع: نگارنده).

#### 4-5-2- بررسی غلظت PM<sub>10</sub> در روزهای هفته و پایان هفته

بررسی میزان غلظت PM<sub>10</sub> برای روزهای هفته و آخر هفته در شکل (4-20) نشان داده شده است. همانطور که در شکل مشاهده می‌شود، غلظت PM<sub>10</sub> در روزهای هفته در (شنبه و یکشنبه و دوشنبه) بیشتر از غلظت پایان هفته (جمعه) بود و روزهای سه‌شنبه و چهارشنبه و پنج‌شنبه غلظت کم‌تر از پایان هفته (جمعه) بود و بیشترین غلظت آن در دوشنبه بود ولی در دوره 0 تا 100 (20 مارس 2011 تا 31 ژوئن 2011) بیشترین غلظت در شنبه بود. یکی از دلایل افزایش غلظت PM<sub>10</sub>، ترافیک می‌باشد. چون در روزهای شروع هفته مدارس و اداره‌ها باز می‌شود غلظت افزایش می‌یابد. و روزهای آخر هفته (پنج‌شنبه و جمعه)، مدارس و اداره‌ها تعطیل می‌شود و غلظت این آلاینده کاهش می‌یابد. و نوسانات غلظت PM<sub>10</sub> نسبت به غلظت CO و AQI در طول این دوره بیشتر بود. البته الگوی تغییرات PM<sub>10</sub> نسبت به سایر آلاینده‌ها ممکن است تفاوت داشته باشد زیرا PM<sub>10</sub> هم منشأ انسانی و هم منشأ طبیعی دارد. بنابراین با تغییر عوامل هواشناسی مانند سرعت باد و نیز تغییر فصول میزان PM<sub>10</sub> تغییر می‌یابد.




شکل (4-20) غلظت PM<sub>10</sub> در روزهای هفته و پایان هفته (منبع: نگارنده).

#### 4-5-3- بررسی AQI در روزهای هفته و پایان هفته

AQI برای روزهای هفته و آخر هفته بررسی شد شکل (4-20). همانطور که در شکل مشاهده می‌شود، AQI تقریباً در طول هفته یکسان بوده و در دوره 0 تا 70 (20 مارس 2012 تا 7 می 2012)، در روز چهارشنبه بیشترین بود. با توجه به این که آلاینده‌ای که بیشترین غلظت را داشته باشد به‌عنوان شاخص AQI برای

آن روز محسوب می شود. در این دوره AQI مربوط به  $PM_{10}$  بوده است. و در دوره بین 70 تا 150 (7 می 2012 تا 21 اوت 2012)، یکشنبه بیشترین غلظت بوده که ناشی از آلاینده (اوزن که ده روز به خاطر بالاترین غلظت، AQI محسوب شده، و  $PM_{2.5}$  (38 روز) و  $PM_{10}$  (8 روز) و CO (3 روز)) می باشد. و بین دوره 150 تا 220 (21 اوت 2012 تا 31 اکتبر 2012)، دوشنبه بیشترین مقدار را داشته است که ناشی از آلاینده (ازون (5 روز) و  $PM_{2.5}$  (46 روز) و  $PM_{10}$  (15 روز) و CO (1 روز)) می باشد. و بین دوره 220 تا 500 (31 اکتبر 2011 تا 31 دسامبر 2012)، یکشنبه بیشترین غلظت بوده است که ناشی از آلاینده (ازون (2 روز) و  $PM_{2.5}$  (245 روز) و  $PM_{10}$  (43 روز) و CO (2 روز)) می باشد. پس در کل دوشنبه و یکشنبه بیشترین AQI را داشته و سه شنبه و چهارشنبه کمترین مقدار را داشته است و روزهای چهارشنبه و سه شنبه نسبت به جمعه پایین بوده است.



شکل 4-21) AQI برای روزهای هفته و پایان هفته (منبع: نگارنده)

#### 6-4 : بحث

به منظور پیش بینی زمانی کیفیت هوای تهران با شاخص های پایداری و ناپایداری با استفاده از شبکه عصبی مصنوعی، داده های هواشناسی و رادیوسوند و غلظت آلاینده های  $1391/1/1$  تا  $1392/7/31$ ، از سازمان هواشناسی کشور و کنترل کیفیت هوای تهران اخذ شد و بعد از استانداردسازی داده ها، با امتحان انواع شبکه عصبی، داده ها وارد شبکه عصبی پرسپترون دولایه با 10 نورون در لایه پنهان با تابع انتقال سیگموئید و الگوریتم آموزش لوبنبرگ مارکورات، شد. که یکبار شبکه با همه پارامترها (هواشناسی و شاخص های پایداری و ناپایداری) و غلظت آلاینده  $CO$  و  $PM_{10}$  و AQI، برای فصول گرم و سرد و کل سال آموزش داده شد و یکبار هم با

ورودی‌های، پارامترهای هواشناسی و غلظت آلاینده CO و PM<sub>10</sub> و AQI ( برای فصول گرم و سرد و کل سال) آموزش داده شد و نتایج زیر حاصل شد:

#### 4-6-1- نتایج حاصل از شبیه‌سازی غلظت سه روز بعد CO و PM<sub>10</sub> و AQI با همه پارامترها (هواشناسی و شاخص‌های پایداری و ناپایداری) برای فصول سرد و گرم و کل سال

1- نتایج حاصل از شبیه‌سازی غلظت سه روز بعد CO بر اساس غلظت روز جاری برای فصول گرم سال، بهتر از نتایج حاصل از شبیه‌سازی غلظت سه روز بعد CO بر اساس غلظت روز جاری برای فصول سرد و کل سال بود.

2- نتایج حاصل از شبیه‌سازی غلظت سه روز بعد PM<sub>10</sub> بر اساس غلظت روز جاری برای فصول گرم سال بهتر از نتایج حاصل از شبیه‌سازی غلظت سه روز بعد PM<sub>10</sub> بر اساس غلظت روز جاری برای فصول سرد و کل سال بود.

3- نتایج حاصل از شبیه‌سازی AQI سه روز بعد بر اساس غلظت روز جاری برای فصول گرم سال بهتر از نتایج حاصل از شبیه‌سازی غلظت سه روز بعد AQI بر اساس غلظت روز جاری برای فصول سرد و کل سال بود.

با توجه به نتایج بالا، پیش‌بینی برای غلظت سه روز بعد CO و PM<sub>10</sub> و AQI بر اساس غلظت روز جاری، در فصول گرم بهتر از نتایج حاصل از پیش‌بینی برای غلظت سه روز بعد CO و PM<sub>10</sub> و AQI بر اساس غلظت روز جاری، برای فصول سرد و کل سال بود.

#### 4-6-2- نتایج حاصل از شبیه‌سازی غلظت سه روز بعد CO و PM<sub>10</sub> و AQI با فقط پارامترهای هواشناسی برای فصول سرد و گرم و کل سال

1- نتایج حاصل از شبیه‌سازی غلظت سه روز بعد CO بر اساس غلظت روز جاری برای فصول گرم سال بهتر از نتایج حاصل از شبیه‌سازی غلظت سه روز بعد CO بر اساس غلظت روز جاری برای فصول سرد و کل سال بود.

2- نتایج حاصل از شبیه‌سازی غلظت سه روز بعد PM<sub>10</sub> بر اساس غلظت روز جاری برای فصول گرم سال بهتر از نتایج حاصل از شبیه‌سازی غلظت سه روز بعد PM<sub>10</sub> بر اساس غلظت روز جاری برای فصول سرد و کل سال بود.

3- نتایج حاصل از شبیه‌سازی AQI سه روز بعد بر اساس غلظت روز جاری برای فصول گرم سال بهتر از نتایج حاصل از شبیه‌سازی غلظت سه روز بعد AQI بر اساس غلظت روز جاری برای فصول سرد و کل سال بود.

با توجه به نتایج بالا، پیش‌بینی برای غلظت سه روز بعد CO و PM<sub>10</sub> و AQI بر اساس غلظت روز جاری، در فصول گرم بهتر از نتایج حاصل از پیش‌بینی برای غلظت سه روز بعد CO و PM<sub>10</sub> و AQI بر اساس غلظت روز جاری، برای فصول سرد و کل سال بود.

4- در کل پیش‌بینی برای غلظت سه روز بعد CO و PM<sub>10</sub> و AQI بر اساس غلظت روز جاری، با استفاده از همه پارامترها ( هواشناسی و شاخص‌های پایداری و ناپایداری) و هم فقط پارامترهای هواشناسی، برای هر دو، در فصول گرم، بهتر از نتایج حاصل از پیش‌بینی برای غلظت سه روز بعد CO و PM<sub>10</sub> و AQI بر اساس غلظت روز جاری، برای فصول سرد و کل سال بود. و از طرف دیگر شبیه‌سازی غلظت سه روز بعد PM<sub>10</sub> بر اساس غلظت روز جاری نسبت به شبیه‌سازی غلظت سه روز بعد CO و AQI برای فصول گرم و سرد و کل سال بهتر بود. و شبکه عصبی مصنوعی نتوانست AQI را به خوبی CO و PM<sub>10</sub> شبیه‌سازی کند شاید یکی از دلایل احتمالی آن انتخاب پارامترها بوده است.

5- از میان پارامترها، برای هر سه آلاینده بیشترین تأثیر و همبستگی مثبت را LCL و بیشترین همبستگی و تأثیر منفی را با S داشت. یعنی با افزایش شاخص LCL، غلظت آلاینده افزایش می‌یابد و با کاهش S غلظت آلاینده افزایش می‌یابد.

5- از طرف دیگر با شروع هفته ( روزهای شنبه تا دوشنبه) و باز شدن مدارس و اداره‌ها غلظت CO و PM<sub>10</sub> افزایش می‌یابد. و روزهای آخر هفته ( چهارشنبه و پنجشنبه) و پایان هفته ( جمعه) با تعطیل شدن مدارس و اداره‌ها غلظت این دو آلاینده کاهش می‌یابد و AQI در دوره 0 تا 70 (20 مارس 2012 تا 7 می 2012)، در روز چهارشنبه بیشترین بود. و در دوره 70 تا 150 (7 می 2012 تا 21 اوت 2012)، یکشنبه بیشترین غلظت بوده. و در دوره بین 150 تا 220 (21 اوت 2012 تا 31 اکتبر 2012)، دوشنبه بیشترین مقدار را داشته است.

#### 4-7: محدودیت‌های پژوهش

- در اختیار قرار ندادن داده‌های بالای سه سال آلاینده‌ها توسط سازمان هواشناسی تهران و حتی گرفتن هزینه برای داده‌های بالای سه سال
- نبود داده‌های کافی آلاینده‌های اندازه‌گیری شده توسط ایستگاه‌های سنجش کیفیت هوا. و به دلیل این‌که داده‌ها در هیچ ایستگاه‌ی کامل نبود و حتی به جرات می‌توان گفت خیلی ناقص بود و ایستگاه شریف از همه کامل‌تر بود به‌ناچار از داده‌های ایستگاه آزادی، استفاده کردیم.

## منابع:

- اردکانی، س. (1380). تعیین کیفیت بهداشتی هوای تهران با استفاده از شاخص AQI. پایان نامه کارشناسی ارشد محیط‌زیست، دانشکده منابع طبیعی و علوم دریایی دانشگاه تربیت مدرس.
- بوداقپور، ا.، چرخستانی، س. (1390). پیش‌بینی میزان غلظت آلاینده‌های هوای تهران با استفاده از شبکه عصبی مصنوعی. علوم و تکنولوژی محیط‌زیست. 11-1.
- پوراحمد، ا. نقش اقلیم و ساختار جغرافیایی در آلودگی هوای شهر تهران. پژوهش‌های جغرافیایی تقوی، ه.، دانش، ش.، مساعدی، ا.، پیش‌بینی غلظت آلاینده‌های شهر مشهد بر اساس عوامل اقلیمی. (1392). کنگره ملی مهندسی عمران. 7-1.
- سلطانی، ب. (1367). اندازه‌گیری آلودگی هوای شهر تهران. فصلنامه آبادی، 12، 72-75.
- چرخستانی، س.، بوداقپور، ا. (1387). پیش‌بینی میزان غلظت آلاینده‌های هوای تهران با استفاده از شبکه عصبی مصنوعی. دومین همایش و نمایشگاه تخصصی مهندسی محیط‌زیست 11-1.
- دبیری، م. (1379). آلودگی محیط‌زیست: هوا- آب- خاک- صوت. انتشارات دانشگاه تهران. ویراست دوم.
- رحیمی، ا.، صدر موسوی، م. (1387). ارزیابی کاربرد شبکه‌های عصبی مصنوعی در پیش‌بینی منو کسید کربن در هوای شهر تبریز. دانشکده منابع طبیعی. 4، 681-691.
- رحیمی، ا.، نبوی، ر.، نجفی، ع. (1387). پیش‌بینی غلظت ازن با استفاده از شبکه عصبی نوعی MLP در شهر تبریز. دومین همایش و نمایشگاه تخصصی مهندسی محیط‌زیست. تهران. 7-1.
- رفیع پور گتابی، م.، آل شیخ، ع.، علی محمدی، ع.، صادقی نیارکی، ع.، احمدی، م. (1393). مقایسه رگرسیون چند متغیره و شبکه‌های عصبی در مدل‌سازی مکانی غلظت NOx در تهران. کنفرانس بین‌المللی برنامه‌ریزی و مدیریت محیط‌زیست. 8-1.
- رضائیان، م.، صادقی حسینی، ع. (1385). بررسی تعدادی از شاخص‌های ناپایداری و پتانسیل بارورسازی ابرهای همرفتی منطقه اصفهان. مجله فیزیک زمین و فضا. 98-83.
- سلیمانپور مقدم، ن.، آگاه، ا.، ژولیده سر، ف. (1392). شبکه عصبی مصنوعی و کاربرد آن در محیط‌زیست. کنفرانس ملی خدمات شهری و محیط‌زیست.



صالحی، ح.، ثنایی نژاد، ح.، موسوی بایگی، م.، (1393) بررسی شاخص‌های ناپایداری هنگام وقوع پدیده‌های آب‌وهوایی مخرب در مشهد. جغرافیا و مخاطرات طبیعی. 113-123.

عابدی، س.، صالحی، ا.، عابدی، س.، تهامی پور، م.، عابدی، س. ارائه الگوی پیش‌بینی آلودگی هوا

عرفان منش، م.، افیونی، م. (1379). آلودگی محیط‌زیست، آب، خاک، هوا. شابک.

گلباز، س.، فرزاد کیا، م.، کرمانی، م. (1388). بررسی کیفیت بهداشتی هوای شهر تهران در سال 1387 با تکیه بر شاخص کیفیت هوا. فصلنامه سلامت کار ایران. 8-2.

نوری، ر.، اشرفی، خ.، اژدر پور، ا. (2008). مقایسه کاربرد روش‌های شبکه عصبی مصنوعی و رگرسیون خطی چند متغیره بر اساس تحلیل مولفه‌های اصلی برای پیش‌بینی غلظت میانگین روزانه مونوکسید کربن: بررسی موردی شهر تهران. مجله فیزیک زمین و فضا. 52-135.

واتقی، ا.، زیبایی، منصور. (1387). پیش‌بینی آلودگی هوای شیراز. 65-72.

واحدی، ا. (1367). تهران و مسائل محیط‌زیست، خلاصه مقاله سمینار دوام حیات در بافت شهرهای قدیمی. دانشگاه علم و صنعت.

Adebiyi, A. A., Adewumi, A. O., & Ayo, C. K. (2014). Comparison of arima and artificial neural networks models for stock price prediction. *Journal of Applied Mathematic*, 2014, 9–11.

Agirre-Basurko, E., Ibarra-Berastegi, G., & Madariaga, I. (2006). Regression and multilayer perceptron-based models to forecast hourly O<sub>3</sub> and NO<sub>2</sub> levels in the Bilbao area. *Environmental Modelling and Software*, 21(4), 430–446.

Beamish, L. A., Osornio-Vargas, A. R., Wine, E., &. (2011). Air pollution: An environmental factor contributing to intestinal disease. *Journal of Crohn's and Colitis*, 5(4), 279–286.

Biancofiore, F., Verdecchia, M., Di Carlo, P., Tomassetti, B., Aruffo, E., Busilacchio, M., ... Colangeli, C. (2015). Analysis of surface ozone using a recurrent neural network. *Science of the Total Environment*, 514, 379–387.

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), 221–230.

Carbajal-Hernandez, J. J., Ssment and prediction of air quality using fuzzy logic and autoregressive models. *Atmospheric Environment*, 60, 37–50.

Chaloulakou, A., Grivas, G., & Spyrellis, N. (2003). Neural network and multiple regression models for PM10 prediction in Athens: a comparative assessment. *Journal of the Air & Waste Management Association*, 53(10), 1183–1190.

Chen, D., Xu, T., Li, Y., Zhou, Y., Lang, J., Liu, X., & Shi, H. (2015). A hybrid approach to forecast air quality during high-PM concentration pollution period. *Aerosol and Air Quality Research*, 15(4), 1325–1337.

Chen, R., Samoli, E., Wong, C. M., Huang, W., Wang, Z., Chen, B., & Kan, H. (2012). Associations between short-term exposure to nitrogen dioxide and mortality in 17 Chinese cities: The China Air Pollution and Health Effects Study (CAPES). *Environment International*, 45(1), 32–38.

Demuth, H. (2002). Neural network toolbox. *networks*, 24(1), 1–8.

Díaz-Robles, L. a., Ortega, J. C., Fu, J. S., Reed, G. D., Chow, J. C., Watson, J. G., & Moncada-Herrera, J. a. (2008). A hybrid ARIMA and artificial neural networks model to forecast particulate matter in urban areas: The case of Temuco, Chile. *Atmospheric Environment*, 42(35), 8331–8340.

Eleuteri, A., Tagliaferri, R., & Milano, L. (2005). A novel information geometric approach to variable selection in MLP networks. *Neural Networks*, 18(10), 1309–1318.

Enger, E. D., Smith, B. F., Bockarie, A. T., Edward A Keller, Daniel Botkin, E. A. K., McIlveen, R., & R, M. (2014). Environmental science Earth as a living planet .pdf. (E. A. Keller, Ed.) *Environmental Science: A Study of Interrelationships* (ninth). Psychology Press.

(Keller, Ed.) *Environmental Science: A Study of Interrelationships* (ninth, Vol. 92). Psychology Press.

Gardner, M. ., & Dorling, S. . (1998). Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric Environment*, 32(14-15), 2627–2636.

Gardner, M. W., & Dorling, S. R. (1999). Neural network modelling and prediction of hourly NO and NO concentrations in urban air in London. *Atmospheric Environment*, 33(V), 709–719.

George, J.-J. (1960). *Weather Forecasting for Aeronautics*.

Golbaz, S., Farzadkia, M., & Kermani, M. (2010). Determination of Tehran air quality with emphasis on air quality index (AQI); 2008-2009. *Iran Occupational Health*, 6(4), 62–68.

Hagan, M. T., Demuth, H. B., Beale, M. H., & De Jesús, O. (1996). *Neural network design* (Vol. 20). PWS publishing company Boston.

Haizum, N., Rahman, A., Hisyam, M., & Talib, M. (2013). Forecasting of air pollution index with artificial neural network. *Jurnal Teknologi (Sciences & Engineering)*, 63(2), 59–64.

Hájek, P., & Olej, V. (2013). Prediction of air quality indices by neural networks and fuzzy inference systems—The Case of Pardubice Microregion. *Engineering Applications of Neural Networks*, 302–312.

Haykin, S. (1998). *Neural networks : Convergence*, 1–16.

Hong-di He, Wei-Zhen Lu b, ,YuXue c. (2014). Prediction of particulate matter at street level using artificial neural networks coupling with chaotic particle swarm optimization algorithm. *Building and Environment*, 78, 111–117.

Hooyberghs, J., Mensink, C., Dumont, G., Fierens, F., & Brasseur, O. (2005). A neural network forecast for daily average PM10 concentrations in Belgium. *Atmospheric Environment*, 39(18), 3279–3289.

Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, (3), 31–44.

Jain, S., & Khare, M. (2010). Adaptive neuro-fuzzy modeling for prediction of ambient CO concentration at urban intersections and roadways. *Air Quality, Atmosphere and Health*, 3(4), 203–212.

Jang, J. S. R., Gully, N. (1995). *Fuzzy logic toolbox for use with MATLAB*. The MathWorks .Inc.,Natick,Massachusetts.

Jiang, D., Zhang, Y., Hu, X., Zeng, Y., Tan, J., & Shao, D. (2004). Progress in developing an ANN model for air pollution index forecast. *Atmospheric Environment*, 38(40 SPEC.ISS.), 7055–7064.

Kamal, M. M., Jailani, R., & Shauri, R. L. a. (2006). Prediction of ambient air quality based on neural network technique. 2006 4th Student Conference on Research and Development, (SCOReD), 27–28.

Kumar, a, & Goyal, P. (2013). Forecasting of air quality index in Delhi using neural network based on principal component analysis. *Pure and Applied Geophysics*, 170, 711–722.

Mahmoudzadeh, S., Othman, Z., Yazdani, A. M., & Bakar, A. A. (2013). Carbon Monoxide prediction using artificial neural network and imperialist competitive algorithm. *Australian Journal of Basic and Applied Sceinces*, 7(4), 735–744.

Martín, M. L., Turias, I. J., González, F. J., Galindo, P. L., Trujillo, F. J., Puntonet, C. G., & Gorriz, J. M. (2008). Prediction of CO maximum ground level concentrations in the Bay of Algeciras, Spain using artificial neural networks. *Chemosphere*, 70(7), 1190–1195.

McIlveen, R., & R, M. (1991). *Fundamentals of weather and climate*. Psychology Press.


Miller, R. (1972). Notes on analysis and severe storm forecasting procedures of the air force global weather central.

Moustris, K. P., Ziomas, I. C., & Paliatsos, A. G. (2010). 3-day-ahead forecasting of regional


- pollution index for the pollutants NO<sub>2</sub>, CO, SO<sub>2</sub>, and O<sub>3</sub> using artificial neural networks in Athens, Greece. *Water, Air, and Soil Pollution*, 209(1-4), 29–43.
- Nayak, P. C., Sudheer, K. P., Rangan, D. M., & Ramasastri, K. S. (2005). Short-term flood forecasting with a neurofuzzy model. *Water Resources Research*, 41(4), 1–16.
- Noori, R., Hoshyaripour, G., Ashrafi, K., & 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.
- Papanastasiou, D. K., Melas, D., & Kioutsioukis, I. (2007). Development and assessment of neural network and multiple regression models in order to predict PM<sub>10</sub> levels in a medium-sized Mediterranean city. *Water, Air, and Soil Pollution*, 182(1-4), 325–334.
- Shakerkhatibi, M., Mohammadi, N., Benis, K. Z., & Sarand, A. B. (2015). Using ANN and EPR models to predict carbon monoxide concentrations in urban area of Tabriz, 2(3), 117–122.
- Sayad, Omid. (1387). *Neural Network*, 30(7), 623–625.
- Tanaka, K., Sano, M., Watanabe, H., & Member, S. (1995). Modeling and Control of Carbon Monoxide Concentration Using a Neuro-Fuzzy Technique, 3(3).
- Ruuskanen, J., Tiitanen, P., Timonen, K. L., Ruskanen, J., Mirme, A., Pekkanen, J., Edward A Keller, Daniel Botkin, E. A. K. (1999). Fine particulate air pollution resuspended road dust and respiratory health among symptomatic children.pdf. *European Respiratory Journal*, 13(2), 266–273.
- Ul-saufie, A. Z., Yahaya, A. S., Ramli, N. A., & Abdul Hamid, H. (2011). Comparison Between Multiple Linear Regression And Feed forward Back propagation Neural Network Models For Predicting PM<sub>10</sub> Concentration Level Based On Gaseous And Meteorological Parameters. *International Journal of Applied Science and Technology*, 1(4), 42–49.
- Upadhyaya, G., & Dashore, N. (2011). Fuzzy logic based model for monitoring air quality index, 4(3), 215–218.
- Wang, P., Liu, Y., Qin, Z., & Zhang, G. (2015). A novel hybrid forecasting model for PM<sub>10</sub> and SO<sub>2</sub> daily concentrations. *Science of the Total Environment*, 505, 1202–1212.
- Wang, W. C., Chau, K. W., Cheng, C. T., & Qiu, L. (2009). A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *Journal of Hydrology*, 374(3-4), 294–306.
- Yi, J., & Prybutok, V. R. (1996). A neural network model forecasting for prediction of daily maximum ozone concentration in an industrialized urban area. *Environmental Pollution*, 92(3), 349–357.
- Zhang, D. Z., & Peng, Z. R. (2014). Near-road fine particulate matter concentration estimation using artificial neural network approach. *International Journal of Environmental Science and*

Zito, P., Chen, H., & Bell, M. C. (2008). Predicting real-time roadside CO and NO2 concentrations using neural networks, 9(3), 514–522.


### پیوست الف




شکل الف- 1: یک نمونه روش بدست آوردن شاخص های پایداری و ناپایداری با داده های رادیوسوند




شکل الف-2: درصد تأثیر پارامترهای اقلیمی و شاخص های پایداری روی CO




شکل الف-3: درصد تأثیر پارامترهای اقلیمی و شاخص های پایداری روی PM<sub>10</sub>



شکل الف-4: درصد تأثیر پارامترهای اقلیمی و شاخص های پایداری روی AQI




شکل الف-5: تغییرات غلظت CO در سال 2012 و 2013




شکل الف-6: تغییرات غلظت PM<sub>10</sub> در سالهای 2012 و 2013







شکل الف- 7: تغییرات AQI در سال‌های 2012 و 2013




شکل الف- 8: تغییرات LCL در سال‌های 2012 و 2013




شکل الف- 9: تغییرات S در سال‌های 2012 و 2013



شکل الف- 10: تغییرات TT در سال‌های 2012 و 2013



شکل الف- 11: تغییرات رطوبت نسبی در سالهای 2012 و 2013



شکل الف- 12: تغییرات دما در سالهای 2012 و 2013



|   |  |                               |
|---|--|-------------------------------|
| <b>Surname : Farhadi</b>  | <b>Name : Razieh</b>                         | <b>Student no: 9323202036</b> |
| <b>Supervisor : Dr. Mojtabzaa Hadavifar</b>   | <b>Advisor's:Dr. Mahmood Amintoosi</b>       |                               |
| <b>Faculty:Geography and Environmental Sciences</b>   | <b>Department: Environmental Science</b>     |                               |
| <b>Program:Master of Science</b>  | <b>Field of study :Environmental Science</b> |                               |
| <b>Title: Temporal Forecasting of Air Quality Using stability and Instability indices and Artificial Neural Network, Case Study: Tehran</b> |  |                               |
| <b>Keywords: Forecasting air quality,Neural Network,Stability and a unstability Indices</b>   |  |                               |

**Abstract**

Advances in technology, increasing population and developing metropolises lead to air pollution. Iran and even all the world are challenging and trying to find a solution for air pollution problems. One of the best solutions to mitigate the negative effects of the concentration of pollutants and air quality prediction is using artificial neural networks (ANN). One of the factors affecting air pollution is meteorological parameters. In previous studies meteorological parameters widely have been used to estimate or predict the concentration of pollutants as the ANN inputs. But the vertical profiles of atmospheric data for prediction of air quality or air pollutant concentration has not been used yet. In the present study, in addition to using usual parameters, the stability and instability parameters data also have been used. The aim of this study is temporal forecasting air quality by stability and instability indices using neural network. For this purpose, MLP neural network with two hidden layers and output, with 10 neurons in the hidden layer with sigmoid transfer function and Levenberg-Marquardt algorithm (LMA) was used in order to evaluate the performance of RMSE and R models. Input data of network were meteorological parameters (WD, WS, TE and HU), the concentration of pollutants (CO, PM<sub>10</sub> and AQI), instability indices (LCL, S and TT) and meteorological parameters. Concentrations of contaminants for three days later predicted for warm and cool season and also for the entire of year. Results showed that tomorrow concentration of PM<sub>10</sub> predicted for warm seasons was better predicted by both meteorological parameters (R=0.55, RMSE=22.24) and the instability parameters and meteorological parameters ((R=0.80, RMSE=23.82) compared to those obtained for CO in terms of meteorological parameters (R=0.73, RMSE=0.72) and instability indices and meteorological parameters with (R=0.73, RMSE=0.72). Data analysis showed that obtained data for PM<sub>10</sub> was also better than those predicted for AQI in terms of meteorological parameters (R=0.61, RMSE=18.55) and instability indices and meteorological parameters (R=0/60, RMSE=14/77). Finally we can conclude that predicted data for PM<sub>10</sub> were resulted better than CO and AQI. About AQI, we concluded that just meteorological parameters were predicted well rather than instability indices. Artificial neural network could not deliver reliable results for AQI compared to PM<sub>10</sub>. This may be due to the improper selection of parameters.



**Hakim Sabzevari University**

Faculty of Geography and Environmental Sciences

Thesis Submitted in Partial Fulfillment of the

Requirements for the Degree of Master of Science (M.Sc.)

in Natural Resources Engineering – environment

# Temporal Forecasting of Air Quality Using stability and Instability indices and Artificial Neural Network, Case Study: Tehran

**Supervisor:**

Dr. Mojtabzaa Hadavifar

Dr. Mazaher Moeinaddini

**Advisor's:**

Dr. Mahmood Amintoosi

**By:**

Razieh Farhadi

September 2016