

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



دانشکده مهندسی عمران

پایان نامه کارشناسی ارشد مهندسی و مدیریت منابع آب

پیش بینی سرعت و جهت باد با استفاده از خروجی مدل های عددی هواشناسی

نگارنده: سیده فروزان خاکزاد

استاد راهنما:

دکتر سعید گلیان

استاد مشاور:

مهندس محمد علمی

بهمین ۹۶

شماره: ۹۶۲۲/۴  
تاریخ: ۴۶/۱۱/۹

باسمه تعالی



مدیریت تحصیلات تکمیلی

فرم شماره (۳) صورتجلسه نهایی دفاع از پایان نامه دوره کارشناسی ارشد

با نام و یاد خداوند متعال، ارزیابی جلسه دفاع از پایان نامه کارشناسی ارشد خانم / آقای سیده فروزان خاکزاد با شماره دانشجویی ۹۴۰۶۵۲۴ رشته مهندسی عمران گرایش مدیریت منابع آب تحت عنوان پیش‌بینی سرعت و جهت باد با استفاده از خروجی مدل‌های عددی هواشناسی که در تاریخ ۹۶/۱۱/۹ با حضور هیأت محترم داوران در دانشگاه صنعتی شاهرود برگزار گردید به شرح ذیل اعلام می‌گردد:

<input type="checkbox"/> مردود <input checked="" type="checkbox"/> قبول (با درجه: .....)			
نوع تحقیق: <input type="checkbox"/> نظری <input type="checkbox"/> عملی			
عضو هیأت داوران	نام و نام خانوادگی	مرتبه علمی	امضاء
۱- استاداراهنمای اول	دکتر سعید گلین	استادیار	
۲- استاداراهنمای دوم			
۳- استاد مشاور	محمد علمی		
۴- نماینده تحصیلات تکمیلی	دکتر مهدی گلی	استادیار	
۵- استاد ممتحن اول	دکتر احمد احمدی	دانشیار	
۶- استاد ممتحن دوم	دکتر رامین امینی	دانشیار	

وزارت علوم، تحقیقات و فناوری  
دانشگاه مهندسی عمران  
رئیس دانشکده: دکتر احمد احمدی  
امضاء و مهر دانشکده:

تیسره: در صورتی که کسی مردود شود حداکثر یکبار دیگر (در مدت مجاز تحصیل) می‌تواند از پایان نامه خود دفاع نماید (دفاع مجدد نباید زودتر از ۴ ماه برگزار شود).

تقدیم به آنان که:

با هستی خویش، راه را برایم گشودند...

پدرم، به پاس دست‌هایش که فریادرس است و نومی‌دی در پناهِش به امید می‌گراید

مادرم، به پاس مهرش که عشق را در وجودم پروراند و دامانش سجده‌گاه مهربانی است

خواهرم که خورشید محبتش را غروبی نیست

و با سپاس خالصانه از همسرم که حضورش شمع راه من بود، قلبم را آرام، ذهنم را پرجوش

و انگیزه‌ام را متعالی کرد...

## تقدیم سپاس

سپاس خدایی را که به قلم جان داد تا نوشتن بیاموزم، سپاس پدری را که سایه بلندش را استوار داشت، سپاس مادری را که آغوش پر مهرش را دریغ نداشت و سپاس استادی را که مرا بنده خویش ساخت.

امروز که بر شانه گذشتگانمان ایستاده‌ام و به افق‌های دانش می‌نگرم، بر خود واجب می‌دانم تا از زحمات تمامی عزیزانی که مرا در عرصه علم آموزشی یاری نمودند تقدیر کنم. ارادت خالصانه من تقدیم به استاد گران‌قدم جناب آقایان دکتر سعید گلیان و مهندس محمد علمی که دلسوزانه رهنمودهایشان چراغ روشنی در مسیر این پژوهش بود و تمامی دوستان عزیز به‌ویژه آقایان مهندس کاظم سعیدی که با مشورت‌های ارزنده و حمایت‌های بی‌دریغشان، همواره در کنار بنده بودند و دوستانه و مسئولانه بنده را مساعدت فرمودند؛ با تشکر از سازمان هواشناسی ایران که در تهیه اطلاعات این پژوهش مرا یاری رساندند؛ همچنین از اساتید فرزانه و دلسوز؛ آقایان دکتر احمد احمدی و دکتر رامین امینی که زحمت داوری این پایان‌نامه را متقبل شدند؛ با تقدیر از نماینده محترم تحصیلات تکمیلی، جناب آقای دکتر مهدی گلی که با شکیبایی این مسئولیت را پذیرفتند؛ کمال تشکر و قدردانی را دارم و در نهایت برای تمامی این عزیزان آرزوی تندرستی و توفیق الهی را از درگاه باری تعالی مستدعی هستم.

سیده فروزان خاکزاد

۱۳۹۶/۱۱/۹

## تعهدنامه

اینجانب سیده فروزان خاکزاد دانشجوی دوره کارشناسی ارشد رشته مهندسی و مدیریت منابع آب دانشکده مهندسی عمران دانشگاه صنعتی شاهرود نویسنده پایان نامه با موضوع پیش‌بینی سرعت و جهت باد با استفاده از خروجی مدل‌های عددی هواشناسی تحت راهنمایی دکتر سعید گلیان متعهد می‌شوم:

- تحقیقات در این پایان نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است.
- در استفاده از نتایج پژوهش‌های محققان دیگر به مرجع مورد استفاده استناد شده است.
- مطالب مندرج در پایان نامه تاکنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است.
- کلیه حقوق معنوی این اثر متعلق به دانشگاه صنعتی شاهرود می‌باشد و مقالات مستخرج با نام دانشگاه صنعتی شاهرود و یا **Shahrood University of Technology** به چاپ خواهد رسید.
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان نامه تأثیرگذار بوده اند در مقالات مستخرج از پایان نامه رعایت می‌گردد.
- در کلیه مراحل انجام این پایان نامه، در مواردی که از موجود زنده (یا بافت‌های آن‌ها) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است.
- در کلیه مراحل انجام این پایان نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است اصل رازداری، ضوابط و اصول اخلاق انسانی رعایت شده است.

تاریخ:

امضاء دانشجو

### مالکیت نتایج و حق نشر

- کلیه حقوق معنوی این اثر و محصولات آن (مقالات، مستخرج، کتاب، برنامه‌های رایانه ای، نرم‌افزارها و تجهیزات ساخته شده) متعلق به دانشگاه صنعتی شاهرود می‌باشد. این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود.
- استفاده از اطلاعات نتایج موجود در پایان نامه بدون ذکر مرجع مجاز نمی‌باشد.

## چکیده:

باد یکی از عناصر اصلی در اقلیم هر منطقه است که تغییرات آن می‌تواند بر پدیده‌هایی مانند طوفان-های گرد و غباری و شدت تبخیر و تعرق تاثیرگذار باشد. پیش‌بینی رفتار باد به علت ماهیت تصادفی آن، بسیار چالش برانگیز است و به شرایط آب و هوایی و عوامل منطقه بستگی دارد. علاوه بر روش-های فیزیکی و آماری سنتی، در سال‌های اخیر جهت دستیابی به پیش‌بینی‌های با قطعیت بالا برخی روش‌های پیشرفته بر اساس هوش مصنوعی مورد بررسی قرار گرفته‌اند.

در این تحقیق، به‌منظور پیش‌بینی سرعت و جهت باد روزانه در یک ساعت مشخص، چندین مدل توسعه داده شد. سه نوع شبکه عصبی مصنوعی که عبارتند از شبکه عصبی مصنوعی NARX، شبکه عصبی مصنوعی پرسپترون چند لایه (MLP) و شبکه عصبی مصنوعی پرسپترون چند لایه با نمونه-گیری بگینگ جهت پیش‌بینی یک گام بعد با استفاده از داده‌های پیشین ساخته شد. تمامی مدل‌ها توسط داده‌های سرعت باد مدل سیستم پیش‌بینی جهانی (GFS) و برخی پارامترهای هواشناسی واقعی (جهت باد، فشار هوا، دمای هوا، رطوبت نسبی و میزان بارش) گردآوری شده در یک دوره آماری حدوداً دو ساله (اکتبر ۲۰۱۴ - جولای ۲۰۱۶) در بندر ماهشهر آموزش داده شدند. بر اساس نتایج، شبکه عصبی مصنوعی پرسپترون چند لایه با نمونه‌گیری بگینگ نسبت به دو شبکه عصبی دیگر پاسخ بهینه‌تری ارائه کرد. در این تحقیق همچنین به بررسی تاثیر پارامترهای مختلف بر مدل-های پیش‌بینی نیز پرداخته شد. در ساختارهای ورودی مختلف پارامترهای فشار هوا و دمای هوا بیشترین تاثیر را در مدل‌های شبکه عصبی مصنوعی در منطقه بندر ماهشهر داشتند.

**کلیدواژه‌ها:** پیش‌بینی، سرعت باد، جهت باد، روزانه، شبکه عصبی مصنوعی، بگینگ، GFS

## لیست مقالات:

- خاکزاد، ف. و گلیان، س.، " پارامترهای موثر بر پیش‌بینی سرعت باد با استفاده شبکه عصبی مصنوعی (مطالعه موردی: بندر ماهشهر)"، پنجمین کنفرانس ملی پژوهش‌های کاربردی در مهندسی عمران، معماری و مدیریت شهری، ۱۳ و ۱۴ دی ماه ۱۳۹۶، تهران.



## فهرست مطالب

فصل اول) مقدمه و کلیات..... ۱

۱-۱- مقدمه..... ۲

۱-۲- ضرورت تحقیق..... ۴

۱-۳- فرضیات تحقیق..... ۶

۱-۴- اهداف تحقیق..... ۷

۱-۵- نوآوری‌های تحقیق..... ۸

۱-۶- مروری بر فصل‌های پایان‌نامه..... ۹

فصل دوم) بررسی منابع..... ۱۱

۱-۲- مقدمه..... ۱۲

۲-۲- پیش‌بینی باد..... ۱۳

۲-۳- پیش‌بینی باد با استفاده از شبکه عصبی مصنوعی..... ۱۸

۲-۴- پارامترهای موثر بر پیش‌بینی باد..... ۲۵

۲-۵- جمع‌بندی..... ۲۷

فصل سوم) مواد و روش‌ها..... ۲۹

۱-۳- مقدمه..... ۳۰

- ۳-۲- منطقه مورد مطالعه..... ۳۰
- ۳-۲-۱- خصوصیات آب و هوایی منطقه..... ۳۲
- ۳-۲-۱-۱- انواع باد منطقه..... ۳۲
- ۳-۲-۱-۲- دیگر خصوصیات آب و هوایی منطقه..... ۳۲
- ۳-۳- اطلاعات ورودی و آماده‌سازی آن‌ها..... ۳۳
- ۳-۳-۱- داده های منطقه..... ۳۳
- ۳-۲-۱-۱- سیستم پیش‌بینی جهانی (GFS)..... ۳۴
- ۳-۳-۲- آماده‌سازی داده‌ها..... ۳۵
- ۳-۴- روش‌های پیش‌بینی باد..... ۳۷
- ۳-۴-۱- سیستم‌های پیش‌بینی آب و هوای عددی..... ۳۷
- ۳-۴-۲- سیستم‌های فیزیکی..... ۳۸
- ۳-۴-۳- رویکرد سیستم‌های آماری..... ۳۹
- ۳-۵- شبکه‌های عصبی مصنوعی..... ۴۰
- ۳-۵-۱- اصول پایه شبکه عصبی مصنوعی..... ۴۰
- ۳-۵-۲- شبکه عصبی مورد استفاده در این مطالعه..... ۴۲
- ۳-۵-۳- الگوریتم‌های بهینه‌سازی..... ۴۵
- ۳-۵-۴- اندازه لایه مخفی..... ۴۵
- ۳-۵-۵- مقداردهی اولیه وزن شبکه..... ۴۶
- ۳-۵-۶- نرخ یادگیری..... ۴۷
- ۳-۵-۷- ضریب مومنتم..... ۴۷
- ۳-۵-۸- تعداد سیکل‌های آموزش (تکرارها)..... ۴۷

- ۴۸.....۳-۵-۹- ارزیابی عملکرد سیستم.....
- ۴۹.....۳-۶- طراحی شبکه عصبی مصنوعی.....
- ۴۹.....۳-۶-۱- انتخاب ورودی و آماده‌سازی.....
- ۵۰.....۳-۶-۲- نرمال‌سازی.....
- ۵۰.....۳-۶-۳- نمونه‌گیری داده‌ها.....
- ۵۱.....۳-۶-۴- آموزش، اعتبارسنجی و آزمون مجموعه داده‌ها.....
- ۵۲.....۳-۶-۵- انتخاب خصوصیات سیستم.....

## ۵۵..... فصل چهارم) نتایج.....

- ۵۶.....۴-۱- مقدمه.....
- ۵۶.....۴-۲- انتخاب دوره آماری در اجرای شبکه.....
- ۵۷.....۴-۳- تحلیل همبستگی جهت اجرای شبکه عصبی.....
- ۵۹.....۴-۴- بررسی اطلاعات هواشناسی منطقه.....
- ۶۴.....۴-۵- پیش‌پردازش داده‌ها.....
- ۶۷.....۴-۶- پیش‌بینی سرعت باد شبکه عصبی NARX.....
- ۶۸.....۴-۶-۱- ارزیابی نتایج.....
- ۶۹.....۴-۷- پیش‌بینی سرعت باد با استفاده از شبکه عصبی پرسپترون چندلایه.....
- ۷۲.....۴-۷-۱- ارزیابی نتایج.....
- ۷۳.....۴-۸- پیش‌بینی سرعت باد با استفاده از شبکه عصبی پرسپترون چندلایه با نمونه‌گیری بگینگ.....
- ۷۷.....۴-۸-۱- ارزیابی نتایج.....

۷۹-۴-۹- پیش‌بینی جهت باد.....۷۹

۷۹-۴-۹-۱- پیش‌بینی جهت باد افقی.....۷۹

۸۱-۴-۹-۲- پیش‌بینی جهت باد عمودی.....۸۱

۸۳-۴-۱۰- جمع‌بندی.....۸۳

## ۸۵- فصل پنجم) نتیجه‌گیری و پیشنهادات.....۸۵

۸۶-۵-۱- مقدمه.....۸۶

۸۶-۵-۲- نتیجه‌گیری.....۸۶

۸۷-۵-۲-۱- ارزیابی بهترین نوع شبکه عصبی مصنوعی.....۸۷

۸۷-۵-۲-۲- ارزیابی ترکیب‌های مختلف پارامترهای ورودی در شبکه عصبی مصنوعی بهینه.....۸۷

۸۸-۵-۲-۳- ارزیابی تعداد نرون‌های لایه مخفی در لایه مخفی در شبکه عصبی بهینه.....۸۸

۸۸-۵-۲-۴- ارزیابی پیش‌بینی جهت‌های باد عمودی و افقی.....۸۸

۸۹-۵-۲-۵- مقایسه عملکرد شبکه بهینه در پیش‌بینی‌های سرعت و جهت باد.....۸۹

۸۹-۵-۳- پیشنهادات.....۸۹

## ۹۱- فهرست منابع.....۹۱

۹۹- پیوست.....۹۹

۱۰۰- پیوست الف- نتایج کامل پیش‌بینی‌های سرعت و جهت باد.....۱۰۰

۱۰۰- الف-۱- پیش‌بینی‌های سرعت و جهت باد در ساعت ۰۶:۰۰.....۱۰۰

الف-۲- پیش‌بینی‌های سرعت و جهت باد در ساعت ۱۲:۰۰..... ۱۰۲

الف-۳- پیش‌بینی‌های سرعت و جهت باد در ساعت ۱۸:۰۰..... ۱۰۴

## فهرست اشکال

- شکل (۱-۱) اطلس باد ایران در ارتفاع ۸۰ متری از سطح زمین..... ۶
- شکل (۱-۳) نقشه توپوگرافی بندر ماهشهر..... ۳۱
- شکل (۲-۳) موقعیت ایستگاه سینوپتیک بندر ماهشهر..... ۳۴
- شکل (۳-۳) نمونه‌ای از مولفه افقی سرعت باد داده‌های مدل GFS و شبکه‌بندی ناحیه مورد نظر..... ۳۶
- شکل (۴-۳) خلاصه‌ای از سیستم‌های پیش‌بینی باد..... ۴۰
- شکل (۵-۳) طرح کلی شبکه عصبی مصنوعی با یک لایه مخفی..... ۴۲
- شکل (۶-۳) روش استاندارد پیش‌بینی سری‌های زمانی با شبکه‌های عصبی مصنوعی..... ۴۴
- شکل (۱-۴) میانگین ۱۰ ساله (۲۰۱۳-۲۰۰۴) سرعت باد ماهانه در ایستگاه هواشناسی مورد مطالعه..... ۵۹
- شکل (۲-۴) سرعت باد مشاهداتی روزانه در ساعت صفر در ایستگاه هواشناسی مورد مطالعه..... ۶۰
- شکل (۳-۴) سرعت باد مدل GFS، در همبسته‌ترین سلول، روزانه در ساعت صفر در منطقه مورد مطالعه..... ۶۱
- شکل (۴-۴) فشار هوای روزانه در ساعت صفر در ایستگاه هواشناسی مورد مطالعه..... ۶۲
- شکل (۵-۴) دمای هوا روزانه در ساعت صفر در ایستگاه هواشناسی مورد مطالعه..... ۶۲
- شکل (۶-۴) میزان بارش روزانه در ساعت صفر در ایستگاه هواشناسی مورد مطالعه..... ۶۳
- شکل (۷-۴) رطوبت نسبی روزانه در ساعت صفر در ایستگاه هواشناسی مورد مطالعه..... ۶۳
- شکل (۸-۴) سرعت باد مشاهداتی استاندارد شده روزانه در ساعت صفر در منطقه مورد نظر..... ۶۵
- شکل (۹-۴) سرعت باد مدل GFS استاندارد شده روزانه در ساعت صفر در منطقه مورد نظر..... ۶۶
- شکل (۱۰-۴) ساختار شبکه NARX در پیش‌بینی ساعت صفر..... ۶۷
- شکل (۱۱-۴) شاخص ارزیابی MSE شبکه NARX در ساعت صفر..... ۶۷
- شکل (۱۲-۴) نمودارهای رگرسیون پیش‌بینی شبکه NARX در ساعت صفر..... ۶۸
- شکل (۱۳-۴) ساختار مدل M4 در شبکه MLP جهت پیش‌بینی باد یک گام بعد روزانه در ساعت صفر..... ۷۰
- شکل (۱۴-۴) شاخص MSE در مدل M4 شبکه MLP جهت پیش‌بینی سرعت باد یک گام بعد روزانه در ساعت صفر..... ۷۱
- شکل (۱۵-۴) نمودارهای رگرسیون در مدل M4 شبکه MLP جهت پیش‌بینی باد یک گام بعد روزانه در ساعت صفر..... ۷۱
- شکل (۱۶-۴) نمودار سرعت باد مشاهداتی و پیش‌بینی شده توسط مدل M4 شبکه MLP در ساعت صفر..... ۷۲

- شکل (۴-۱۷) ساختار مدل M4 شبکه MLP با بگینگ جهت پیش‌بینی سرعت باد یک گام بعد در ساعت صفر.....۷۴
- شکل (۴-۱۸) شاخص MSE در مدل M4 شبکه MLP با بگینگ جهت پیش‌بینی باد یک گام بعد در ساعت صفر.۷۴
- شکل (۴-۱۹) نمودارهای رگرسیون مدل M4 شبکه MLP با بگینگ در پیش‌بینی سرعت باد یک گام بعد ساعت صفر.....۷۵
- شکل (۴-۲۰) ساختار شبکه MLP با بگینگ و یک نرون در لایه مخفی در ساعت صفر.....۷۶
- شکل (۴-۲۱) نمودارهای رگرسیون مدل M4 شبکه MLP با بگینگ و یک نرون لایه مخفی در پیش‌بینی سرعت باد یک گام بعد ساعت صفر.....۷۶
- شکل (۴-۲۲) سرعت باد مشاهداتی و پیش‌بینی شده توسط مدل M4 شبکه MLP با بگینگ در ساعت صفر.....۷۸
- شکل (۴-۲۳) پراکندگی داده‌های سرعت باد در ساعت صفر با شبکه MLP با بگینگ.....۷۸
- شکل (الف-۱) نمودارهای رگرسیون مدل M3 پیش‌بینی سرعت باد ساعت ۰۶:۰۰ در شبکه MLP با بگینگ.۱۰۱
- شکل (الف-۲) نمودارهای رگرسیون مدل M3 پیش‌بینی، سرعت باد ساعت ۱۲:۰۰ در شبکه MLP با بگینگ.....۱۰۳
- شکل (الف-۳) نمودارهای رگرسیون مدل M3 پیش‌بینی سرعت باد ساعت ۱۸:۰۰ در شبکه MLP با بگینگ.....۱۰۵

## فهرست جداول

جدول (۱-۳) خصوصیات آب و هوایی سالانه بندر ماهشهر.....	۳۲
جدول (۲-۳) ویژگی‌های طراحی شبکه عصبی مصنوعی بهینه.....	۵۲
جدول (۱-۴) مقادیر همبستگی در سلول‌های سرعت باد مدل GFS با سرعت باد مشاهداتی در ساعت صفر.....	۵۸
جدول (۲-۴) معیارهای ارزیابی پیش‌بینی سرعت باد در ساعت صفر با شبکه MLP.....	۷۰
جدول (۳-۴) معیارهای ارزیابی پیش‌بینی سرعت باد در ساعت صفر توسط شبکه MLP با بگینگ.....	۷۳
جدول (۴-۴) معیارهای ارزیابی پیش‌بینی سرعت باد در ساعت صفر توسط شبکه MLP با بگینگ و یک نرون مخفی.....	۷۷
جدول (۵-۴) معیارهای ارزیابی پیش‌بینی جهت باد افقی با شبکه NARX در ساعت صفر.....	۸۰
جدول (۶-۴) معیارهای ارزیابی پیش‌بینی جهت باد افقی با شبکه MLP در ساعت صفر.....	۸۰
جدول (۷-۴) معیارهای ارزیابی پیش‌بینی جهت باد افقی توسط شبکه MLP با بگینگ در ساعت صفر.....	۸۰
جدول (۸-۴) معیارهای ارزیابی پیش‌بینی جهت باد عمودی توسط NARX در ساعت صفر.....	۸۱
جدول (۹-۴) معیارهای ارزیابی پیش‌بینی جهت باد عمودی توسط MLP در ساعت صفر.....	۸۲
جدول (۱۰-۴) معیارهای ارزیابی پیش‌بینی جهت باد عمودی توسط شبکه MLP با بگینگ در ساعت صفر.....	۸۲
جدول (الف-۱) معیارهای ارزیابی پیش‌بینی سرعت باد در ساعت ۰۶:۰۰ توسط شبکه MLP با بگینگ.....	۱۰۰
جدول (الف-۲) معیارهای ارزیابی پیش‌بینی جهت باد افقی در ساعت ۰۶:۰۰ توسط شبکه MLP با بگینگ.....	۱۰۲
جدول (الف-۳) معیارهای ارزیابی پیش‌بینی جهت باد عمودی در ساعت ۰۶:۰۰ توسط شبکه MLP با بگینگ.....	۱۰۲
جدول (الف-۴) معیارهای ارزیابی پیش‌بینی سرعت باد در ساعت ۱۲:۰۰ توسط شبکه MLP با بگینگ.....	۱۰۳
جدول (الف-۵) معیارهای ارزیابی پیش‌بینی جهت باد افقی در ساعت ۱۲:۰۰ توسط شبکه MLP با بگینگ.....	۱۰۴
جدول (الف-۶) معیارهای ارزیابی پیش‌بینی جهت باد عمودی در ساعت ۱۲:۰۰ توسط شبکه MLP با بگینگ.....	۱۰۴
جدول (الف-۷) معیارهای ارزیابی پیش‌بینی سرعت باد در ساعت ۱۸:۰۰ توسط شبکه MLP با بگینگ.....	۱۰۵
جدول (الف-۸) معیارهای ارزیابی پیش‌بینی جهت باد افقی در ساعت ۱۸:۰۰ توسط شبکه MLP با بگینگ.....	۱۰۶
جدول (الف-۹) معیارهای ارزیابی پیش‌بینی جهت باد عمودی در ساعت ۱۸:۰۰ توسط شبکه MLP با بگینگ.....	۱۰۶



# فصل اول:

## مقدمه و کلیات

سرعت و جهت باد در بین متغیرهای هواشناسی به منظور کشف تغییرات آب و هوایی، کمتر مورد مطالعه قرار گرفته‌اند. عنصر باد از جمله متغیرهای پیچیده اقلیمی است و تغییرات آن در بازه‌های زمانی کوتاه‌مدت و بلندمدت بر خصوصیات اقلیم جهانی و منطقه‌ای اثر می‌گذارد و از جمله عوامل موثر بر نوسانات اقلیم محسوب می‌شود (فاضل‌پور و همکاران<sup>۱</sup>، ۲۰۱۶). اطلاع از تغییرات سرعت و جهت باد، اهمیتی بنیادی در پژوهش‌های مربوط به انرژی باد، احداث ساختمان‌ها و محاسبه نیاز آبی گیاهان دارد. بررسی تغییرات باد از جنبه‌های مختلفی دارای اهمیت است، از جمله اینکه با کاهش سرعت باد، انرژی آن کاهش یافته و در نتیجه آلودگی شهری افزایش می‌یابد. این کاهش سبب کم شدن انتقال گرما و رطوبت بین سطح زمین و اتمسفر و در نهایت افزایش دما می‌شود. همچنین کاهش سرعت باد در شب‌ها، به خصوص در شب‌های زمستان باعث ایجاد وارونگی تابشی سطح زمین می‌شود. افزایش ناگهانی سرعت باد نیز، سبب وقوع تندبادها، گردبادها و خسارت در منطقه خواهد شد (الکساندرسن و همکاران<sup>۲</sup>، ۲۰۰۰).

با افزایش شدت و سرعت باد، روش‌های مناسب و خلاقانه‌ای نیاز است تا خطاهای حاصل از پیش‌بینی باد را کاهش و مدل تخمین سرعت و جهت باد خروجی را بهبود بخشد. روش‌های پیش‌بینی متعددی در چند سال اخیر مورد بحث بوده و مطالعات مختلفی انجام شده است تا دقت پیش‌بینی سرعت باد را بهبود بخشند. الگوهای سرعت باد دینامیک و غیرخطی هستند، از این رو با استفاده از مدل‌های رگرسیون خطی متعارف، به دقت قابل پیش‌بینی نیستند. هرچند برای برخی از بازه‌های پیش‌بینی، از تکنیک‌های مدل‌سازی غیرخطی ریاضی پیچیده‌ای استفاده شده است که با ابزارهای محاسباتی موجود در صنعت مدرن این روزها، ممکن می‌باشد. روش‌های پیش‌بینی، نیاز به داده واقعی گذشته به منظور ساخت و فراگیری دارند. اندازه‌گیری‌های داده در بازه‌های طولانی از زمان غیراقتصادی است، به

---

<sup>1</sup> Fazelpour et al

<sup>2</sup> Alexanderson et al

ویژه زمانی که نیاز به دقیق بودن توسعه پروژه‌های باد می‌باشد. از این رو، یکی از بهترین روش‌ها در صنعت، اندازه‌گیری دقیق در یک زمان کوتاه‌تر و تعمیم آن به دوره زمانی مورد نظر است. برای مثال اندازه‌گیری‌های روزانه برای پیش‌بینی داده هفتگی، اندازه‌گیری‌های هفتگی برای پیش‌بینی داده ماهانه و اندازه‌گیری‌های ماهانه برای پیش‌بینی داده باد سالانه قابل استفاده می‌باشد (مور و دئو<sup>۱</sup>، ۲۰۰۳). پیش‌بینی سرعت باد برای بازه‌های زمانی مختلف، از سی دقیقه تا یک هفته، یک ماه یا یک سال در آینده قابل اجرا می‌باشد. در این تحقیق، تمرکز بر پیش‌بینی کوتاه‌مدت سرعت باد در ساعاتی مشخص از شبانه روز می‌باشد.

پیش‌بینی سرعت باد کوتاه‌مدت، به منظور جلوگیری از اثرات خرابی‌های بادهای سنگین ضروری است. انرژی باد به عنوان یک منبع انرژی جایگزین، به طور عمده به تولید انرژی الکتریسیته می‌پردازد. پیش‌بینی سرعت و جهت باد در صنایع زیادی در حال حاضر مورد توجه است. پیش‌بینی سرعت باد کوتاه-مدت در زمینه‌های نظامی و غیرنظامی برای کنترل ترافیک هوا، پرتاب موشک، ناوبری کشتی و غیره به کار می‌رود. مهندسان دریایی نیز با استفاده از این امر به بسیاری از فعالیت‌های عملیاتی و ساخت و ساز جهت‌دار که ضرورتاً نیاز به پیش‌بینی و برنامه‌ریزی دارند، می‌پردازند. همچنین، در صنعت هوانوردی سرعت‌های باد بر حوزه امنیتی هواپیما در طی فرود و پرواز موثر است.

مطالعات گسترده‌ای در زمینه پیش‌بینی باد انجام شده است. مدل‌های پیش‌بینی گوناگونی برای بازه‌های زمانی مختلف در کشورهای متفاوت بررسی شده‌اند. در این مطالعات پارامترهای ورودی مناسبی را بر اساس موقعیت منطقه مورد نظر در نظر گرفته شده است تا نتیجه مدل پیش‌بینی را تحت تاثیر قرار دهد.

در این مطالعه، روشی بر پایه شبکه عصبی مصنوعی جهت پیش‌بینی سرعت و جهت باد انجام خواهد گرفت. داده‌های مورد استفاده اطلاعات ثبت شده در ایستگاه سینوپتیک بندرماهشهر در استان

---

<sup>1</sup> More & Deo

خوزستان می‌باشند. سرعت باد کوتاه‌مدت به متغیرهای هواشناسی مختلف، از جمله جهت باد، فشار هوا، رطوبت نسبی، دمای هوا و میزان بارش وابسته است. مقادیر این پارامترها از نزدیکترین ایستگاه هواشناسی در منطقه مورد مطالعه بدست آمد و برای آموزش ساختارهای مختلف شبکه عصبی مصنوعی استفاده شده است. شبکه عصبی مصنوعی با توجه به سری‌های زمانی سرعت باد به منظور پیش‌بینی سرعت باد روز بعد در ساعات مشخص از شبانه روز صورت خواهد گرفت که ساختار آن با استفاده از داده‌های سرعت باد استخراج شده از مدل سیستم پیش‌بینی جهانی (GFS)<sup>1</sup> و برخی متغیرهای هواشناسی مشاهداتی منطقه از جمله دمای هوا، فشار هوا، رطوبت نسبی، بارش و جهت باد در ایستگاه مورد نظر جهت آموزش ترکیب‌های مختلف شبکه عصبی مصنوعی طراحی شده است.

## ۱-۲- ضرورت تحقیق

سوخت‌های فسیلی علاوه بر تأثیرات مخربی که بر محیط زیست دارند، منابع آن‌ها نیز رو به اتمام است. همین امر باعث شده تا اکثر کشورها به استفاده از انرژی‌های تجدیدپذیر روی بیاورند. انرژی بادی نیز به علت تجدیدپذیری، پاک بودن و البته فراوانی گسترده، به عنوان یک منبع جایگزین مورد استفاده قرار می‌گیرد.

از طرف دیگر استفاده از انرژی باد در سال‌های اخیر، با افزایش مشکلات زیست‌محیطی در حال گسترش است.<sup>۲</sup> IPCC (هیئت بین دولتی تغییرات آب و هوا) در سال ۲۰۱۳ اظهار داشته است که سطح جوی اثر گازهای گلخانه‌ای، به عنوان مثال، دی‌اکسیدکربن، متان، کلروفلئوروکربن و مونوکسیدکربن اتمسفر قطعا در اثر فعالیت‌های بشر در حال افزایش است و همبستگی زیادی بین گازهای گلخانه‌ای و مسائل زیست‌محیطی وجود دارد که باعث گرم شدن کره زمین می‌شود. دی-

<sup>1</sup> Global Forecast System

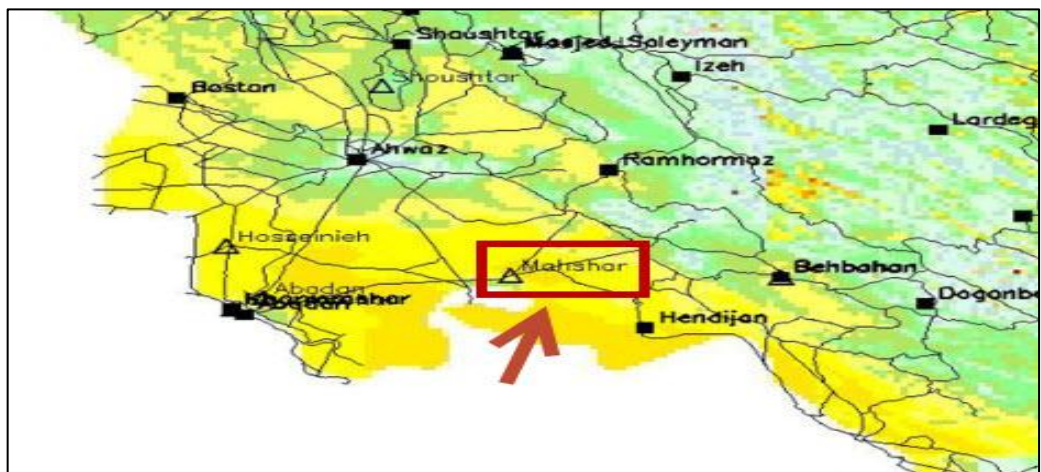
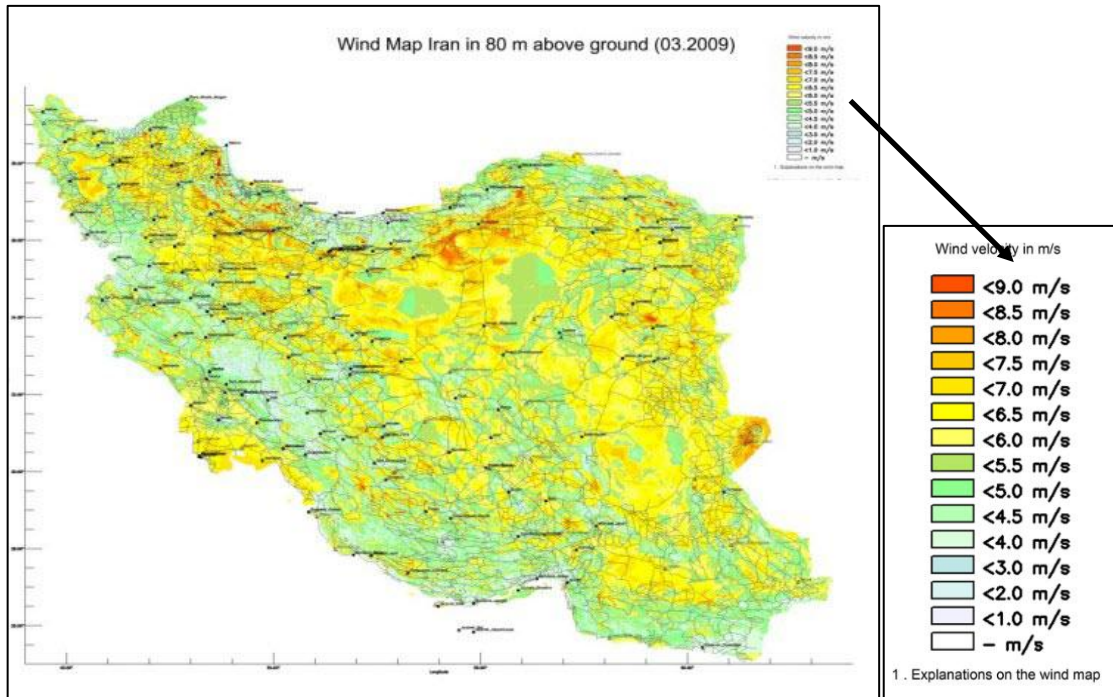
<sup>2</sup> Intergovernmental Panel on Climate Change

اکسیدکربن بیشترین سهم گاز گلخانه‌ای را دارا است. منبع اصلی تولید دی‌اکسیدکربن مصرف سوخت فسیلی است. بنابراین، توجه به انرژی‌های تجدیدپذیر جایگزین با نفت، در کاهش مصرف سوخت‌های فسیلی در سال‌های اخیر تاثیرگذار بوده است. انرژی باد نیز راه حلی برای جلوگیری از گرم شدن کره زمین است. اما تولید انرژی باد برخی مشکلات مدیریتی را داراست که از ویژگی‌های باد بوجود می‌آید. باد، به دلیل عدم تعادل گرما بر روی زمین ایجاد می‌شود. بر اساس بررسی‌های صورت گرفته، سرعت باد دارای تغییرات بسیاری (متناوب و بی‌نظم) در کوتاه مدت است. از این رو، آگاهی از سرعت باد در چند ساعت یا چند روز آینده کمک بسیاری به اپراتورها و تصمیم‌گیرندگان می‌کند تا بتوانند برنامه‌ریزی مناسبی برای قطع و وصل توربین‌های بادی، مدیریت بار و نگهداری تجهیزات داشته باشند. نیروهای باد در طول سال و حتی در طول روز تا حد زیادی تغییر می‌کنند. در ضمن، علاوه بر سرعت باد، دانستن چگونگی تغییرات جهت باد در منطقه نیز امری ضروری است (اسکیدمور<sup>۱</sup>، ۱۹۸۷). از این رو در این پژوهش به منظور پیش‌بینی سرعت و جهت باد به بررسی و مقایسه چند مدل متفاوت از شبکه عصبی مصنوعی جهت دستیابی به شبکه‌ای بهینه پرداخته شده است.

طبق اطلس بادی تهیه شده توسط سازمان انرژی‌های نو ایران و پژوهشکده هواشناسی، ایران در دسته کشورهای بادخیز است (سازمان انرژی‌های تجدیدپذیر و بهره‌وری انرژی برق، ۲۰۱۶) و منطقه مورد مطالعه، بندر ماهشهر، طبق شکل (۱-۱) از سرعت‌های باد نسبتاً خوبی برخوردار می‌باشد، از این رو می‌توان در این منطقه، انرژی و نیروگاه‌های بادی را مورد بررسی قرار داد. به همین منظور، در این پایان‌نامه به پیش‌بینی سرعت و جهت باد بندرماهشهر پرداخته شده است.

---

<sup>1</sup> Skidmore



شکل (۱-۱) اطلس باد ایران در ارتفاع ۸۰ متری از سطح زمین

۳-۱- فرضیات تحقیق

۱- از داده‌های سرعت باد استخراج شده از مدل سیستم پیش‌بینی جهانی (GFS)، استفاده شده است.

۲- متغیرهای هواشناسی مشاهداتی، باعث بهبود شاخص‌های عملکردی مدل می‌شوند.

۳- پارامترهای متفاوت هواشناسی و ترکیب‌های مختلف آن‌ها، اثرات متفاوتی بر شبکه عصبی مصنوعی می‌گذارند.

۴- علاوه بر سرعت باد، جهت باد را نیز می‌توان با استفاده از شبکه عصبی مصنوعی پرسپترون چند-لایه پیشخور با نمونه‌گیری بگینگ مشابه پیش‌بینی کرد.

#### ۴-۱- اهداف تحقیق

سوخت‌های فسیلی با سرعت بسیار بالایی رو به اتمام هستند، که این امر منجر به تولید انرژی از منابع تجدیدپذیر مانند باد، خورشید، جزر و مدی و سلول‌های سوختی جایگزین، شده است. در میان سیستم‌های تجدیدپذیر گوناگون تولید انرژی، انرژی باد بر دیگر منابع انرژی تجدیدپذیر غالب است. باد یک منبع انرژی آزاد و در دسترس است و به نظر می‌رسد که از سریع‌ترین منابع تولید انرژی تجدیدپذیر حال حاضر باشد. بررسی‌ها نشان می‌دهد که در سال ۲۰۲۰، حدود ۱۲٪ از برق جهان از تولید باد خواهد بود (فان و همکاران<sup>۱</sup>، ۲۰۰۹). همچنین اطلاعات ماهواره‌ای نشان می‌دهند، طی چند دهه اخیر شدت وزش باد و نیز طول موج‌ها در اقیانوس‌های جهان در حال افزایش است. براساس این تحقیق، طی ۲۰ سال گذشته شدت باد ۱۰ درصد و طول امواج ۷ درصد افزایش یافته است. افزایش سرعت باد و ارتفاع امواج سبب انتقال گرما بین دریا و اتمسفر و نیز تغییرات آب و هوایی می‌شود. پیش‌بینی سرعت باد و ارتفاع امواج، به شرکت‌های ساحلی و کشتی‌های اقیانوس‌پیما کمک می‌کند تا خود را برای مقابله با باد و امواج آماده کنند (یانگ و همکاران<sup>۲</sup>، ۲۰۱۱).

در این مطالعه، به پیش‌بینی سرعت و جهت باد با استفاده از داده تجربی جمع‌آوری شده و به حداقل رساندن خطای پیش‌بینی زمانی در دوره آماری حدود دو سال پرداخته شده است. روش‌های پیش-

---

<sup>1</sup> Fan et al

<sup>2</sup> Young et al

بینی کوتاهمدت با استفاده از پیش‌بینی روزانه در ساعاتی مشخص از شبانه روز در این تحقیق صورت گرفته است. شبکه عصبی مصنوعی به طور استاندارد بردار ورودی تصادفی را به بردار خروجی متناظر تصویر می‌کند. داده‌های باد استخراج شده از مدل پیش‌بینی هواشناسی عددی (GFS) و داده‌های باد مشاهداتی هواشناسی از ایستگاه سینوپتیک بندرماهشهر، برای بدست آوردن پیش‌بینی‌های یک گام بعد سرعت‌ها و جهت‌های باد استفاده شده‌اند. ابزارهای استفاده شده برای پیش‌بینی شبکه‌های عصبی مصنوعی (ANN<sup>1</sup>)، مدل‌های غیرخطی ساخته شده با نرم‌افزار کامپیوتری متلب می‌باشد (آلاداغ و همکاران<sup>2</sup>، ۲۰۰۹، پانتری و پاپاتاناسیو، ۲۰۰۸، ژانگ و همکاران<sup>3</sup>، ۱۹۹۸). از دیگر اهداف این مطالعه، مقایسه سه شبکه عصبی به کار رفته و بررسی عملکرد مدل‌های شبکه‌های عصبی مصنوعی جهت دستیابی به موثرترین پارامترها و تخمین سرعت و جهت باد می‌باشد. آزمایش‌ها با داده‌های سرعت باد استخراج شده از مدل GFS و مشاهدات هواشناسی به عنوان پیش‌بینی‌کننده، که ورودی‌های شبکه عصبی مصنوعی هستند، انجام می‌شود. بهترین مدل با دقیق‌ترین پیش‌بینی برای هر دوره بدست می‌آید. قبل از فراگیری مدل، داده‌ها دسته‌بندی، ساخته، آموزش، اعتبارسنجی می‌شوند و مورد آزمون قرار می‌گیرند.

## ۱-۵- نوآوری‌های تحقیق

- ۱- افزایش دقت پیش‌بینی روزانه با استفاده از پیش‌بینی در ساعت‌هایی مشخص در شبانه روز، با توجه به داده‌های پیشین موردنظر در همان ساعت جهت آموزش و اعتبارسنجی.
- ۲- استفاده از داده‌های سرعت باد مدل سیستم پیش‌بینی جهانی (GFS) جهت دستیابی به نتایجی با عملکرد بهینه‌تر نسبت به مطالعات پیشین.

---

<sup>1</sup> Artificial Neural Network

<sup>2</sup> Aladag et al

<sup>3</sup> Zhang et al



۳- توسعه روش‌های مرسوم پیش‌بینی پرسپترون چندلایه با استفاده از روش بگینگ در نمونه‌گیری داده‌ها.

۴- پیش‌بینی جهت‌های افقی و عمودی باد با استفاده از شبکه عصبی مصنوعی.

## ۱-۶- مروری بر فصل‌های پایان‌نامه

در روند نگارش این پایان‌نامه، سعی بر آن است تا ضمن پیوستگی مطالب ارائه شده در هر فصل ارتباط موضوعی با سایر فصل‌ها نیز حفظ شود. بدین منظور، در فصل اول مقدمه‌ای در مورد اهمیت موضوع و ضرورت مطالعه پیرامون آن بیان شده و سپس به اهمیت موضوع در منطقه مورد مطالعه پرداخته شده است. در ادامه فرضیات تحقیق مطرح و در نهایت اهداف تحقیق و نوآوری‌های آن آورده شده است.

در فصل دوم، به مرور منابع به عنوان یکی از بخش‌های مهم در هر تحقیق، پرداخته خواهد شد. در این فصل به پژوهش‌هایی که در آن‌ها به پیش‌بینی سرعت باد، با استفاده از شبکه‌های عصبی مصنوعی و دیگر روش‌های مرسوم در ایران و جهان در راستای تحقیق حاضر اشاره شده است. در آخر نیز به بررسی منابع مربوط به پیش‌بینی سرعت باد با استفاده از پارامترهای مهم هواشناسی پرداخته شده است.

در فصل سوم به بررسی منطقه مورد مطالعه به لحاظ موقعیت جغرافیایی، اقلیمی و آب و هوایی و اطلاعات ثبت شده از ایستگاه مورد نظر و روش‌های مختلف مرسوم پیش‌بینی باد مورد بررسی قرار گرفته است. همچنین ساختار شبکه عصبی مصنوعی و جعبه ابزار مورد استفاده برای این مدل‌سازی در نرم‌افزار متلب و همچنین مسیر انجام تحقیق جهت اخذ نتایج موردنظر بررسی شده است. این مراحل شامل استخراج داده‌ها از مدل پیش‌بینی آب و هوا، پالایش و آماده‌سازی داده‌ها و بررسی ساختار شبکه عصبی مصنوعی مورد نظر می‌باشد.

ارائه نتایج حاصل در فصل چهارم، به صورت جداول و نمودارهای حاصل از مراحل کار بیان می‌گردد. ارزیابی معیارهای عملکردی در نتیجه پیش‌بینی سرعت و جهت باد و تاثیر ترکیب‌های متفاوتی از شبکه‌های عصبی مصنوعی و در نهایت ارائه نتایج مدل‌سازی صورت گرفته برای هر یک از ساختارها و گام زمانی مورد مطالعه مواردی است که در این فصل بدان پرداخته شده است.

پس از اخذ نتایج در فصل چهارم، در فصل پنجم، نتایج بدست آمده با توجه به اهداف و فرضیه‌های در نظر گرفته شده بررسی و با نتایج تحقیقات مشابه مقایسه شده است. در نهایت جمع‌بندی کلی از نتایج بدست آمده صورت می‌گیرد. در پایان با توجه به نتایج تحقیق، پیشنهادهایی در جهت کمک به پژوهش‌های آینده ذکر می‌شود. در پیوست نیز نتایج کامل پیش‌بینی سرعت و جهت باد در منطقه آورده شده است.

# فصل دوم:

## بررسی منابع

بشر از دیرباز از انرژی‌های تجدیدپذیر نظیر خورشید و باد استفاده نموده است و با کشف منابع سوخت‌های فسیلی نظیر ذغال‌سنگ و نفت، استفاده از انرژی‌های تجدیدپذیر به تدریج به فراموشی سپرده شد تا اینکه بحران نفت در دهه ۲۰ میلادی باعث شد کشورهای صنعتی به منابع دیگر انرژی، نظیر انرژی‌های تجدیدپذیر و هسته‌ای روی بیاورند. در آغاز، استفاده از انرژی‌های نو با موانعی همچون هزینه سرمایه‌گذاری بالا و به‌صرفه نبودن اقتصادی روبرو بود. به مرور زمان، پیشرفت تکنولوژی و مزایایی همچون کاهش آلودگی زیستی سبب گردید تا انرژی‌های تجدیدپذیر و به‌طور خاص، انرژی باد به مرحله اقتصادی بودن برسد (برتون<sup>۱</sup>، ۲۰۰۳).

در دهه‌های اخیر، کاهش جهانی ذخایر انرژی متعارف و رشد سریع تقاضای انرژی یک نگرانی عمومی جدی بوده است. علاوه بر این، استفاده از منابع انرژی مانند سوخت‌های فسیلی منجر به مشکلات زیست‌محیطی، مانند آلودگی هوا، گرمایش جهانی و کاهش ازون شده است (مانزانو و همکاران، ۲۰۱۳). برای کنترل این مسائل، تلاش‌هایی اساسی جهت یافتن راهی به منظور تامین تقاضای انرژی در حال رشد، منجر به توجه جامعه جهانی به منابع انرژی تجدیدپذیر صورت پذیرفته است (جنینگز<sup>۲</sup>، ۲۰۰۹). منابع انرژی تجدیدپذیر نسبت به سوخت‌های هیدروکربنی کمتر مخل محیط‌زیست می‌باشند.

با توجه به نقش باد در زندگی انسان، پیش‌بینی این عنصر مهم می‌تواند در برنامه‌ریزی‌های آینده منطقه‌ای و جهانی موثر باشد. پیش‌بینی افزایش یا کاهش آلودگی در یک منطقه، پیش‌بینی افزایش یا کاهش تولید انرژی بادی از کاربردهای مهم پیش‌بینی سرعت باد برای آینده می‌باشند. در ارتباط با بررسی تغییرات و پیش‌بینی سرعت باد، مطالعات گسترده‌ای در دنیا و نیز ایران انجام شده است. در گزارش هیأت بین‌دولتی تغییر اقلیم (۲۰۱۳) به تغییرات سرعت باد در آینده در نقاط مختلف دنیا با

---

<sup>1</sup> Burton

<sup>2</sup> Jenings

شدت و ضعف‌های متفاوت اشاره شده و تأثیر آن بر چرخندها و بادهای غربی در عرض‌های میانی و نوسان‌های سرعت باد مورد توجه قرار گرفته است.

به طور کلی، می‌توان گفت که همه جنبه‌های زندگی انسان به نحوی از فرآیندهای آب و هوایی متأثر است و این تأثیرگذاری در زمینه‌های مختلفی چون کشاورزی، آبیاری، اقتصاد، مخابرات، حمل و نقل و صنایع نظامی دیده می‌شود. سرعت باد، از جمله پارامترهای هواشناسی است که پدیده‌ای بسیار پیچیده، غیرخطی و نسبت به زمان و مکان متغیر می‌باشد.

امروزه محققین با ابداع و پیشرفت علمی چون روش‌های هوش مصنوعی، که ابزاری توانمند، انعطاف‌پذیر و مستقل از مدل‌های دینامیکی سیستم هستند، در جستجوی راه‌هایی جهت پیشرفت در شناخت و پیش‌بینی پارامترهای مهم هواشناسی می‌باشند. یکی از مولفه‌های هوش مصنوعی، شبکه عصبی است که توانایی محاسبه و تقریب هر تابع حسابی و منطقی را دارد. توانایی این شبکه‌ها قابل ملاحظه می‌باشد و در مقایسه با مدل‌های مرسوم، این مدل‌ها به ورودی‌ها و محاسبات کمتری نیاز دارند (منه‌اج<sup>۱</sup>، ۱۳۷۹).

در این فصل، مروری اجمالی بر تحقیقاتی که در چند سال اخیر در داخل و خارج از کشور در حیطه روش‌های پیش‌بینی باد، پیش‌بینی با استفاده از شبکه‌های عصبی مصنوعی و پارامترهای موثر بر پیش‌بینی باد صورت گرفته است.

## ۲-۲- پیش‌بینی باد

اندازه‌گیری سرعت و جهت باد در مناطق مختلف بسیار حائز اهمیت است. از موارد اهمیت پیش‌بینی باد، برآورد مقدار انرژی باد به عنوان یک منبع تجدیدپذیر است که بیشترین رشد را میان بخش‌های

---

<sup>۱</sup> Menhaj

مختلف تولید انرژی در جهان طی سال‌های ۲۰۰۰ تا ۲۰۰۴ میلادی به خود اختصاص داده است (پاتر<sup>۱</sup> و همکاران، ۲۰۰۶). غیرقابل پیش‌بینی بودن پارامترهای باد، بزرگترین ضعف تخمین انرژی باد در بسیاری از موارد گزارش شده است. در بیشتر زمینه‌ها مهم‌ترین مولفه‌های موثر پارامتر باد، سرعت و جهت وزش باد می‌باشد. بنابراین، با توجه به اهمیت برآورد مولفه‌های باد، توانایی پیش‌بینی سرعت و جهت وزش باد الزامی به نظر می‌رسد (داموسی و دوکوپولوس<sup>۲</sup>، ۲۰۰۱). بدین منظور، پژوهشگران به مطالعات متعددی در این زمینه پرداختند که در ادامه به گوشه‌ای از آن‌ها اشاره شده است:

افخمی و همکاران (۱۳۹۴)، با استفاده از دو مدل هیبریدی عصبی موجکی و فازی-عصبی موجکی به پیش‌بینی سرعت باد ماهانه در ایستگاه سینوپتیک یزد پرداختند. در این راستا مقادیر خروجی موجک به‌عنوان مقادیر ورودی شبکه‌های عصبی و عصبی-فازی به‌کار گرفته شد. بر اساس نتایج تلفیق موجک با دو مدل نامبرده منجر به افزایش چشمگیری در کارایی آن‌ها شده است، به طوری که ضریب همبستگی شبکه‌های فازی-عصبی در شرایط بدون تلفیق با موجک ۰.۷۴ و  $MAPE^3$ ،  $MAE^4$  و  $RMSE^5$  به ترتیب ۰.۰۱، ۰.۷۵ و ۱.۹۷ برآورد گردیده است در حالی که در شرایط تلفیق با موجک ضریب همبستگی به ۰.۹۶ و  $MAPE$ ،  $MAE$  و  $RMSE$  به ترتیب ۰.۰۲، ۰.۲۴ و ۱.۳۱ ارتقا پیدا کرد. همچنین نتایج بهترین کارایی شبکه عصبی پرسپترون نیز در شرایط بدون تلفیق با موجک از ضریب همبستگی ۰.۷۳ و  $MAPE$ ،  $MAE$  و  $RMSE$  به ترتیب ۰.۰۴، ۰.۸۱ و ۲.۰۱ به ضریب همبستگی ۰.۹۴ و  $MAPE$ ،  $MAE$  و  $RMSE$  به ترتیب ۰.۰۲، ۰.۳۳ و ۱.۴۰ در شرایط تلفیق با موجک بهبود یافت. نتایج عملکرد شبکه‌های فازی-عصبی موجکی نسبت به شبکه‌های عصبی موجکی با خطای کمتری همراه بوده و در مجموع عملکرد برتر این مدل در میان چهار مدل مورد استفاده، به اثبات رسید.

---

<sup>1</sup> Potter et al

<sup>2</sup> Damosis and Dokopoulos

<sup>3</sup> Mean Absolute Percentage Error

<sup>4</sup> Mean Absolute Error

<sup>5</sup> Root Mean Squared Error

قاسمی و سیدی (۱۳۹۴)، به پیش‌بینی تغییرات سرعت باد ایران تا سال ۲۰۲۰ و با استفاد از یک دوره ۵۰ ساله از سال ۱۹۶۱ تا ۲۰۱۰ پرداختند. نتایج حاصل از مدل حالت-وینترز نشان داد که، این مدل به خوبی توانسته تغییرات سرعت باد و حتی مقادیر حدی آن را در ایران برآورد نماید. علاوه بر این، مدل استفاده شده تغییرات ناگهانی اتفاق افتاده در ایستگاه را نیز به خوبی تشخیص داده و برآورد کرده است. مقدار ضریب همبستگی برای مدل نیز بین ۰.۳۹ در آبادان تا ۰.۸ در ایستگاه بابلسر متغیر بود. همچنین مقدار شاخص میانگین قدر مطلق خطا (MAE) نیز بین ۱.۳۴ برای ایستگاه آبادان و ۰.۴ برای ایستگاه بابلسر بدست آمد. با توجه به اینکه نتایج ارزیابی و صحت سنجی مدل حاکی از این بود که مدل در بیشتر ایستگاه‌ها به خوبی توانسته مقدار سرعت باد را برآورد نماید، بنابراین از آن برای پیش‌بینی سرعت باد تا سال ۲۰۲۰ استفاده شد.

گوئو و همکاران<sup>۱</sup> (۲۰۱۱)، روش پیش‌بینی سرعت باد بر اساس روش هیبریدی شبکه عصبی پس انتشار و ایده حذف تاثیرات فصلی مجموعه داده‌های سرعت باد واقعی، با استفاده از تنظیمات نمایی فصلی ارائه کردند. این روش میانگین سرعت باد روزانه در یک سال بعد را با مقدار میانگین مطلق خطای پایینی در مقایسه با حالت بدون تنظیمات نمایی فصلی منطقه‌ای در چین از سال ۲۰۰۱ تا ۲۰۰۶ پیش‌بینی کرد. در مقایسه با مقادیر سرعت باد اندازه‌گیری شده، نتایج شبیه‌سازی با استفاده از روش ارائه شده و شبکه عصبی پس انتشار نشان داد که روش پیشنهاد شده عملکرد بهتری نسبت به شبکه عصبی پس انتشار تنها دارد.

شیلا و دیپا (۲۰۱۳)، یک مدل محاسباتی هیبریدی، ترکیبی از نقشه‌های خود سازمانده<sup>۲</sup> ویژگی و شبکه پرسپترون چندلایه جهت افزایش دقت پیش‌بینی سرعت باد ارائه کردند. روش ارائه شده، بر داده‌های واقعی باد آزمایش شد. نتایج نشان داد که در مقایسه با مدل‌های شبکه عصبی معمول روش هیبریدی ارائه شده عملکرد برتری (RMSE پایین‌تری) دارد.

---

<sup>۱</sup> Guo et al

<sup>۲</sup> Self Organizing Map

لیو و همکاران<sup>۱</sup> (۲۰۱۳)، یک الگوریتم هوشمند هیبریدی برای پیش‌بینی سرعت باد کوتاه‌مدت توسعه دادند. در ابتدا برای پیش‌پردازش سیگنال سرعت باد، از انتقال موجک اصلی استفاده کردند و نوسان تصادفی سرعت باد را از بین بردند. سپس مدل SVM<sup>۲</sup> برای پیش‌بینی تقریبی سیگنال سرعت باد حاصل از انتقال موجک، اجرا شد. الگوریتم ژنتیک به منظور جستجوی پارامترهای بهینه، جهت جلوگیری از احتمال ایجاد ناپایداری توسط پارامترهای انتخاب شده نامناسب، ارائه شد. هنگامی که متغیرهای ورودی SVM انتخاب شدند، از آزمون علیت گرنگر برای انتخاب تاخیرهای مناسب متغیر محیطی دما و از خود همبستگی<sup>۳</sup> و همبستگی جزئی برای انتخاب تاخیرهای مناسب سرعت‌های پیشین استفاده شد. روش توسعه داده شده از مدل ماندگاری<sup>۴</sup> و مدل SVM با الگوریتم ژنتیک بدون انتقال موجک موثرتر واقع شد.

شوکور و لی<sup>۵</sup> (۲۰۱۴)، دو روش هیبریدی KF-ANN<sup>۶</sup> و KF-ARIMA برای بهبود دقت پیش‌بینی سرعت باد ارائه کردند. دو مجموعه داده سرعت باد ثبت شده در دو منطقه متفاوت استفاده شد. نتایج نشان داد که مدل‌های ARIMA<sup>۷</sup>، ANN، هیبریدی KF-ANN و هیبریدی KF-ARIMA کارآمد بودند. هرچند، نتایج MAPE بیان می‌کند که مدل هیبریدی KF-ANN موثرترین ابزار برای بهبود دقت پیش‌بینی‌های سرعت باد است. در مدل KF-ANN نسبت به مدل‌های مجزای آن‌ها نتیجه بهتری در دقت پیش‌بینی سرعت باد حاصل شد، در حالیکه KF و ANN به صورت مجزا پیش‌بینی‌های قابل قبول‌تری در مقایسه با مدل ARIMA که پیش‌بینی‌های سرعت باد بی نتیجه‌ای ارائه داده، نشان دادند.

---

<sup>1</sup> Liu et al

<sup>2</sup> Support Vector Machine

<sup>3</sup> Autocorrelation

<sup>4</sup> Persistence

<sup>5</sup> Shukur and Lee

<sup>6</sup> Kalman Filter Artificial Neural Network

<sup>7</sup> Autoregressive Integrated Moving Average



آکچای و فیلیک<sup>۱</sup> (۲۰۱۷)، چارچوب پیش‌بینی سرعت باد نوینی ارائه کردند. عملکرد چارچوب ارائه شده در مقادیر ثبت شده سرعت باد از ۵ ایستگاه هواشناسی منطقه مارمارا در ترکیه ارزیابی شد. نتایج تجربی نشان داد که آماده کردن الگوهای روزانه، هفتگی، ماهانه و سالانه در اندازه‌گیری‌ها به‌طور قابل‌توجهی باعث افزایش قطعیت تخمین شد. چارچوب مورد نظر بر اساس پاک کردن داده‌ها و فاکتورگیری کوواریانس<sup>۲</sup> توسط روش زیرفضای توسعه داده شده نوین و ایده‌های پیش‌بینی فیلتر کالمن یک گام بعد و چند گام بعد ساخته شد. آزمایشات عددی اعمال شده بر مجموعه داده‌های واقعی نشان داد که، پیش‌بینی‌های سرعت باد به خصوص پیش‌بینی‌های چند گام بعد، عملکرد برتری در مقادیر معیارهای محاسبه شده با مدل‌های پیش‌بینی ماندگاری دارند.

کاپلان و تمیز<sup>۳</sup> (۲۰۱۷)، روشی نوین بر اساس توابع توزیع احتمالی ویبول و گوسی به منظور پیش‌بینی سرعت باد کوتاه‌مدت ارائه کردند. روش ارائه شده بر اساس الگوریتم مقایسه ویژگی‌های استاتیکی سرعت باد مشاهداتی و تولید شده، به منظور دستیابی به برآوردی دقیق‌تر آزمایش شد. این روش بر داده‌های سرعت باد مشاهداتی و ثبت شده در آنکارا در سال‌های ۲۰۱۳ و ۲۰۱۴ اعمال شد. نتایج نشان داد که روش به کار رفته تناوبات ناگهانی در پیش‌بینی سرعت باد را حذف و پیش‌بینی بهتری از سرعت باد ارائه کرد.

ما و همکاران<sup>۴</sup> (۲۰۱۷)، مدلی هیبریدی بر اساس ترکیب روش حذف اختلال با یک شبکه عصبی فازی دینامیکی ارائه کردند. آنالیز طیف تکین<sup>۵</sup> به منظور پیش‌پردازش داده‌های سرعت باد اصلی، جهت بدست آوردن یک توالی آرام‌تر به کار رفت، و شبکه عصبی فازی دینامیکی تعمیم‌یافته‌ای جهت اجرای پیش‌بینی، مورد استفاده قرار گرفت. با ساختار کوچک‌تر و ساده‌تر شبکه عصبی، مدل می‌تواند به طور کارا به نرخ آموزش سریع و پیش‌بینی صحیح دست یابد. سه آزمایش تجربی، که شامل داده-

---

<sup>1</sup> Akcay and Filik

<sup>2</sup> Covariance

<sup>3</sup> Kaplan and Temiz

<sup>4</sup> Ma et al

<sup>5</sup> Single Spectrum Analysis

های سری‌های زمانی سرعت باد، با بازه‌های ۱۰ دقیقه، ۳۰ دقیقه و ۶۰ دقیقه است، مدل را در برنامه-ریزی شبکه‌های هوشمند کارآمد نشان داد.

## ۲-۳- پیش‌بینی باد با استفاده از شبکه عصبی مصنوعی

در دهه‌های اخیر تلاش‌های فراوانی جهت پیش‌بینی پارامترهای باد در بازه‌های زمانی کوتاه‌مدت و تا حدودی میان‌مدت، انجام گرفته است که گروهی از این تلاش‌ها مبتنی بر روش‌های هوش مصنوعی می‌باشد. امروزه روش‌های متعددی با استفاده از شبکه‌های عصبی مصنوعی و منطق فازی برای مدل کردن سرعت باد، به عنوان یک پدیده فیزیکی کاملاً غیرخطی، مورد استفاده قرار گرفته‌اند، تا مقدار سرعت باد در چند گام زمانی بعدی را پیش‌بینی کنند که برخی به نتایج مناسب‌تری نسبت به روش-های قبلی دست یافته‌اند (گوانگدیان و ژیجی، ۱۹۹۴، نگنویتسکی و پاتر، ۲۰۰۶، واتسون و همکاران، ۱۹۹۴). در ادامه به برخی مطالعات در زمینه شبکه عصبی مصنوعی پرداخته شده است:

بختیاری و همکاران (۱۳۹۱)، به پیش‌بینی سری زمانی سرعت باد با استفاده از شبکه عصبی مصنوعی در بازه زمانی ساعتی در شش ماه (آوریل تا سپتامبر) از سال ۲۰۱۰، که سرعت باد نسبت به سایر ماه‌های سال بیشتر بود، پرداختند. آن‌ها از سه مدل با چهار لایه و نورون‌های متفاوت استفاده کردند. نتایج نشان داد که مرحله آزمون مدل با ۲۰ نرون در هر لایه، به طور متوسط ۱۳۴ ثانیه به طول انجامید. لذا این مدل در مقایسه با دیگر مدل‌ها، در مدت زمانی کوتاه‌تر مقادیر خروجی را بدست آورد و سرعت اجرای بالاتری داشت. با توجه به مقایسه پارامترهای آماری در مرحله آزمون، متوسط RMSE و MSE و  $EF^1$  (ضریب کارایی مدل)، به ترتیب، ۱.۱۸۲ و ۰.۶۹۴ و ۰.۹۲۴ به دست آمدند. مدل با ۲۰ نرون، نسبت به دو مدل دیگر، دقت بیشتر و کارایی بهتری در پیش‌بینی سرعت باد نشان داد.

---

<sup>1</sup> Efficiency Coefficient

آکینسی<sup>۱</sup> (۲۰۱۱)، از روش شبکه عصبی مصنوعی برای تخمین کوتاه‌مدت سرعت باد در منطقه بتمن در ترکیه استفاده کرد. مدل‌های شبکه عصبی مصنوعی مختلف برای پیش‌بینی سرعت باد کوتاه‌مدت در بتمن ترکیه، با استفاده از داده‌های بدست آمده از اندازه‌گیری‌های ۱۰ ساله در سازمان هواشناسی دولت ترکیه توسعه داده شد. ابتدا یک مدل با ۱۰ نورون در لایه مخفی انتخاب شد و نتایج به اندازه کافی رضایت‌بخش نبودند. سه مدل دیگر توسعه داده شد، که شامل ۲۰ نورون، ۳۰ نورون و ۴۰ نورون بودند. مدل با ۴۰ نورون برای پیش‌بینی سرعت باد کوتاه‌مدت، مقادیر میانگین مربعات خطا و رگرسیون به ترتیب ۰.۳۱۱ و ۰.۹۴۸ را برای بهترین آموزش نشان داد. مدل توسعه‌داده شده برای پیش‌بینی سرعت باد کوتاه‌مدت قطعیت بسیار خوبی برای ذخیره انرژی نشان داد.

نوگی و همکاران<sup>۲</sup> (۲۰۱۲)، مدل‌هایی از شبکه عصبی مصنوعی جهت پیش‌بینی سرعت باد کوتاه‌مدت در ناحیه ماردین واقع در ترکیه استفاده کردند. با داده‌های ثبت شده سازمان هواشناسی منطقه در دوره ۱۰ ساله به پیش‌بینی سرعت باد کوتاه‌مدت ناحیه ماردین پرداختند. تعدادی مدل‌های شبکه عصبی مصنوعی متفاوت در این مطالعه توسعه داده شد. مدل با ۶۰ نورون موفق‌ترین مدل برای پیش‌بینی سرعت باد کوتاه مدت شناخته شد. میانگین مربعات خطا و مقادیر تقریبی برای آموزش این مدل به ترتیب ۰.۳۷۸ و ۰.۹۶۰ شدند. مدل‌های شبکه عصبی مصنوعی توسعه داده شده در این مطالعه نتایج رضایت‌بخشی ارائه دادند.

ساواله و گوپتا<sup>۳</sup> (۲۰۱۳)، به مطالعه داده‌های آب و هوا با استفاده از داده‌کاوی مانند روش خوشه‌بندی پرداختند. با استفاده از این روش، داده‌های آب و هوا و الگوهای مخفی درون مجموعه داده‌های بزرگ بدست آمدند تا اطلاعات بازیابی شده را به اطلاعات قابل استفاده‌ای برای دسته‌بندی و پیش‌بینی شرایط اقلیمی تبدیل کنند. الگوریتمی بر اساس شبکه عصبی جهت پیش‌بینی اتمسفر در آینده و

---

<sup>1</sup> Akinci

<sup>2</sup> Nogay et al

<sup>3</sup> Savalle and Gupta

موقعیت مورد نظر ارائه شد. آن‌ها از شبکه عصبی پس انتشار ( $BPNN^1$ ) برای مدل‌سازی اولیه استفاده کردند. نتایج بدست آمده توسط مدل BPNN به یک شبکه هاپفیلد توسعه داده شد. عملکرد روش ارائه شده بر اساس شبکه عصبی (روش ترکیب‌شده از شبکه هاپفیلد و BPNN) بر مجموعه داده‌های آب و هوای ۳ سال، شامل ۱۵۰۰۰ گزارش، دارای مشخصه‌هایی مانند دما، رطوبت و سرعت باد آزمایش شد. خطای پیش‌بینی و همگرایی آموزش دارای دقت بالایی بود.

آزاد و همکاران (۲۰۱۴)، دو روش متفاوت اساسی، روش‌های بر پایه آماری و شبکه عصبی، را جهت پیش‌بینی ساعتی داده‌های سرعت باد سال بعد توسعه دادند. نوآوری این مطالعه پیش‌بینی روند کلی سال آینده با طراحی الگوریتم ادغام داده‌ها در شبکه‌های عصبی مختلف است. مجموعه‌ای از نمونه‌های ثبت شده سرعت باد از دو ایستگاه هواشناسی در مالزی، برای آموزش و آزمون مجموعه داده استفاده شد. نتایج بدست آمده توسط روش ارائه شده نتایج با قطعیت بیشتری را یعنی میانگین خطای مطلق (MAE) بسیار کوچک ارائه داد.

چن و همکاران<sup>۲</sup> (۲۰۱۴)، ترکیبی از مدل‌های عددی و احتمالی را بررسی کردند. آن‌ها پردازش گوسی ( $GP^3$ ) ترکیب‌شده با مدل پیش‌بینی آب و هوای عددی ( $NWP^4$ ) به منظور پیش‌بینی انرژی باد روز بعد را به کار بردند. ابتدا، داده‌های سرعت باد استخراج شده از مدل NWP، با یک پردازش گوسی و سپس، پیش‌بینی‌های انرژی باد توسط مدل‌سازی با روابط بین سرعت باد تصحیح شد و خروجی انرژی، با استفاده از یک پردازش گوسی اصلاح شده مورد بررسی قرار گرفت. برای اعتبارسنجی روش ارائه شده، سه مجموعه داده واقعی برای آموزش و آزمایش مدل استفاده شد. نتایج تجربی با مدل‌های کلاسیک مختلف پیش‌بینی باد مقایسه شدند و بر اساس میانگین خطای مطلق (MAE)، مدل ارائه

---

<sup>1</sup> Back Propagation neural Network

<sup>2</sup> Chen et al

<sup>3</sup> Gaussian Process

<sup>4</sup> Numerical Weather Prediction

شده حدود ۹٪ تا ۱۴٪ برتر از مدل شبکه عصبی مصنوعی (ANN) در جهت بهبود قطعیت پیش‌بینی عمل کرد.

اولاوف<sup>۱</sup> (۲۰۱۴)، خروجی سرعت و انرژی باد بلندمدت توربین بادی ۴۰ کیلو وات را بر اساس شبکه عصبی بازگشتی<sup>۲</sup> لایه‌ای، به عنوان پیش‌بینی کننده ارائه کرد. وی مدل پیش‌بینی با الگوریتم لونبرگ مارکوارت پس انتشار (BP) دارای یک تاخیر اصلی را جهت پیش‌بینی سرعت و انرژی باد تولید شده در گام ۵ دقیقه ای تا ۵ روز بعد را در ایستگاه A استفاده کرد. به علاوه، الگوریتم پس انتشار برای پیش‌بینی پتانسیل باد در ایستگاه B را با استفاده از نمونه‌های ۱۰ دقیقه‌ای در ارتفاع مشابه در نظر گرفت. نمونه داده هواشناسی از یک ایستگاه با فاصله بیشتر و در ارتفاع ۲۰ متری جهت بررسی دقت مدل پیش‌بینی مورد استفاده قرار گرفت. خطاهای برآورد شده به‌منظور تعیین نزدیکی پیش‌بینی‌های باد با مقدار واقعی در هر دو ایستگاه بدست آمد و نتیجه مطلوبی حاصل شد.

رن و همکاران<sup>۳</sup> (۲۰۱۴)، به بررسی چگونگی انتخاب داده‌های ورودی جهت دستیابی به دقت پیش‌بینی بهتر پرداختند. آن‌ها از بهینه‌سازی ازدحام ذرات با الگوریتم پس انتشار (PSO-BP<sup>۴</sup>) و پس انتشار تنها، جهت پیش‌بینی داده‌های سرعت باد با استفاده پارامترهای تولید شده تصادفی استفاده کردند و دو روش انتخاب داده‌های جانبی و انتخاب داده‌های طولی را جهت انتخاب داده ورودی به‌منظور استفاده از داده‌های پیشین در آموزش و آزمایش برگزیدند. مقایسه دقت پیش‌بینی این مدل‌ها نشان داد که، پارامترهای مختلف به‌طور مستقیم بر دقت پیش‌بینی اثر گذارند. این امر موجب شد که مدل PSO-BP را با روش انتخاب پارامتری به نام انتخاب پارامتر ورودی (IS<sup>۵</sup>) ترکیب کنند تا به عملکرد بهتری دست یابند. روش انتخاب پارامتر IS شامل انتخاب مجموعه داده ورودی، تعیین ابعاد داده‌های ورودی و تایید پارامترهای PSO است. در مدل‌سازی از مجموعه داده سرعت باد روزانه و

---

<sup>1</sup> Olaufe

<sup>2</sup> Recurrent Neural Network

<sup>3</sup> Ren et al

<sup>4</sup> Particle Swarm Optimization- Back Propagation

<sup>5</sup> Input parameter Selection

مجموعه داده سرعت باد ساعتی استفاده شد تا عملکرد پیش‌بینی مدل BP و مدل IS-PSO-BP مقایسه شود و در نهایت نتایج، برتری قابل توجه مدل IS-PSO-BP را نشان داد.

دالتو و همکاران<sup>۱</sup> (۲۰۱۵)، به ارائه الگوریتم انتخاب متغیرهای ورودی و کاربرد شبکه‌های عصبی عمیق (DNN<sup>۲</sup>) جهت پیش‌بینی سرعت باد بسیار کوتاه‌مدت پرداختند. شبکه‌های عصبی عمیق و سطحی همراه با الگوریتم انتخاب متغیر ورودی جهت پیش‌بینی باد بسیار کوتاه مدت در مجموعه‌ای از موقعیت‌ها مقایسه شدند. نتایج نشان داد شبکه‌های عصبی عمیق عملکرد برتری نسبت به شبکه‌های عصبی سطحی دارند. استفاده از الگوریتم انتخاب متغیر ورودی، پیچیدگی شبکه عصبی را کاهش داده و آموزش شبکه عصبی عمیق را ساده کرد. روش پیش‌بینی شبکه‌های عصبی کلاسیک با تمام متغیرهای موجود، عملکرد پیش‌بینی محدودی به علت متغیرهای ورودی مازاد و نامرتبط و ساختار ناکارآمد دارد. در این مقاله در سه منطقه مختلف مقایسه صورت گرفت و در هر سه مورد شبکه‌های عصبی عمیق عملکرد بهتری نشان دادند.

تگلیافری و همکاران<sup>۳</sup> (۲۰۱۵)، دو روش جهت پیش‌بینی باد کوتاه مدت بر اساس شبکه عصبی مصنوعی و رگرسیون بردار پشتیبان (SVR<sup>۴</sup>) ارائه کردند. در هر دو روش از دانش مورد نیاز جهت‌های باد ثبت شده قبلی برای پیش‌بینی مقادیر آینده نزدیک استفاده شد. پیش‌بینی بر اساس محاسبه میانگین خطای مطلق و میانگین شاخص کارایی پیش‌بینی ارزیابی شد. شبکه عصبی مصنوعی بهینه، خطای مطلق میانگین ۱.۷ درجه و ۳.۰ درجه، و شاخص کارایی میانگین ۰.۸۱ و ۰.۷۸ را به ترتیب برای یک و دو دقیقه بعد بدست آورد. به منظور افزایش دقت پیش‌بینی توسط آموزش شبکه عصبی مصنوعی، پیش‌بینی از میانگین ده گروه شبکه عصبی مصنوعی تحت آموزش‌های مختلف ساخته شد. میانگین شاخص کارایی به‌طور قابل توجهی با افزایش اندازه گروه افزایش یافت. بنابراین، استفاده از

---

<sup>1</sup> Dalto et al

<sup>2</sup> Deep Neural Network

<sup>3</sup> Tagliaferri et al

<sup>4</sup> Support Vector Regression

گروه‌های بیشتر برای پیش‌بینی‌های شبکه عصبی مصنوعی منجر به عملکرد بهتری شد. از جهت و سرعت باد اندازه‌گیری شده دقایق قبلی، به عنوان ورودی و جهت و سرعت باد دو دقیقه بعد به عنوان خروجی استفاده شد.

کادناس و همکاران<sup>۱</sup> (۲۰۱۶a)، با استفاده از تکنیک NARX به پیش‌بینی سرعت باد گام بعد پرداختند. به منظور بررسی بخش‌های مجزای نمونه چند متغیره، داده‌ها را با استفاده از فاصله ماهالوبیس و سپس در آزمون گرنگر آنالیز کردند. در نهایت، مدل تولید شده NAR<sup>۲</sup> تک متغیره و مدل ماندگاری به‌منظور بررسی عملکرد پیش‌بینی متغیرهای مدل NARX مقایسه شدند. مقایسه بین مدل‌های NARX، NAR و ماندگاری برای هر تکنیک با استفاده از داده‌های آزمایش و خطای اندازه‌گیری‌های پیش‌بینی MSE، MAE و MAPE انجام شد. نتایج نشان دادند که NARX ۴٪ عملکرد بهتری از NAR و ۱۱٪ بهتر از مدل ماندگاری دارد.

کاور و همکاران<sup>۳</sup> (۲۰۱۶)، به پیش‌بینی کوتاه‌مدت سرعت باد بر اساس سری‌های زمانی پیشین داده‌های هواشناسی پرداختند. داده‌های غیرخطی مدل بدست آمده در پیش‌بینی سرعت باد استفاده شد. پنج مدل شبکه عصبی مصنوعی مختلف توسعه داده و حداقل میانگین مربعات خطا (MSE) برای این مدل‌ها بر اساس عملکرد شبکه یافته شد. مدل توسعه داده شده با حداقل خطا جهت پیش‌بینی سرعت باد و انرژی تولید شده از توربین‌های بادی، با خطای ۳۰٪، بدست آمد.

موستریس و همکاران<sup>۴</sup> (۲۰۱۷)، به پیش‌بینی سرعت باد ۲۴ ساعت بعد با استفاده از شبکه‌های عصبی مصنوعی جهت عملکرد بهینه ایستگاه‌های انرژی هیبریدی (HPS<sup>۵</sup>) پرداختند. به این منظور، داده‌های ساعتی سرعت باد در یک موقعیت خاص (جزیره تیلوس، یونان) استفاده شد. شبکه عصبی مصنوعی با داده‌های سابق باد و فشار هوا به منظور پیش‌بینی سرعت باد در ارتفاع هاب بر مبنای ساعتی و در

<sup>۱</sup> Cadenas et al

<sup>۲</sup> Nonlinear Autoregressive

<sup>۳</sup> Kaur et al

<sup>۴</sup> Moustris et al

<sup>۵</sup> Hybrid Power Station

۲۴ ساعت بعد توسعه داده شد. روش پیشنهاد شده، پیش‌بینی مناسبی از سرعت باد را بدست آورد. طبق نتایج روش ارائه شده، توانایی پیش‌بینی برای چنین کاربردهایی تنها برای سه ساعت متوالی بعد مناسب است. به جز این محدودیت، روش ارائه شده عملکرد کاملاً رضایت‌بخشی ارائه داد.

یاداو و ساهو<sup>۱</sup> (۲۰۱۷)، به پیش‌بینی سرعت باد و متعاقباً انرژی باد با استفاده از شبکه‌های عصبی مصنوعی پرداختند و ساختارهای مختلفی از ANN و ویژگی‌های آن‌ها را ارائه کردند. در نهایت پارامترهای ارزیابی مورد بحث قرار گرفت و عملکرد هر سیستم ارائه شده ارزیابی شد. آن‌ها دریافتند که شبکه عصبی مصنوعی برای پیش‌بینی سرعت باد، حتی اگر سرعت باد رفتار سری‌های زمانی پیچیده‌ای را نشان دهد، قابل استفاده و موثر است.

## ۲-۴- پارامترهای موثر بر پیش‌بینی باد

بررسی‌های انجام شده نشان داده است که با افزایش اطلاعات ورودی مورد استفاده در بخش آموزش شبکه‌های عصبی مصنوعی، عملکرد آن بهبود می‌یابد. اما باید توجه داشت که آموزش بیش از حد به شبکه خود یک ایراد است. در چنین صورتی نتیجه پیش‌بینی مقادیر آینده سری زمانی برای ورودی-های جدید در بیشتر موارد پاسخ عکس خواهد داشت (شبکه از حالت تعمیم خارج می‌شود) (چوان<sup>۲</sup>، ۱۹۹۷). در ادامه این فصل مطالعاتی بررسی خواهند شد که از ورودی‌های متفاوت و موثر به منظور آموزش شبکه عصبی استفاده کرده‌اند:

قربانی و همکاران (۲۰۱۳)، به توسعه شبکه عصبی پرسپترون چند لایه (MLP<sup>۳</sup>) با استفاده از سرعت باد ماهانه و داده‌های هواشناسی (فشار هوا، دمای هوا، رطوبت نسبی، و بارش) در بازه زمانی سال‌های

---

<sup>1</sup> Yadav and Sahu

<sup>2</sup> Chuan

<sup>3</sup> Multi Layer Perceptron



۲۰۰۰ تا ۲۰۰۵ و برآورد اهمیت نسبی این متغیرها توسط معادله گارسون<sup>۱</sup> پرداختند. همچنین مدل پیش‌بینی توسعه داده شده، در پیش‌بینی مقادیر آینده با زمان تقدم یک سال عملکرد خوبی نشان داد. مدل MLP هیچگونه دیدگاهی در مورد پیشینه فیزیکی داده‌های ثبت شده ارائه نمی‌کند. با توجه به نتایج معادله گارسون فشار هوا و میزان بارش بیشترین و کمترین تاثیر با مقدار تقریبی ۴۰ و ۱۰ درصد را اعمال کردند.

رامازمی و همکاران<sup>۲</sup> (۲۰۱۵)، یک مدل شبکه عصبی مصنوعی با ابزار برازش مناسب (nftool<sup>۳</sup>) جهت پیش‌بینی سرعت‌های باد ۱۱ منطقه در هند توسعه دادند. یک مدل شبکه عصبی مصنوعی استفاده شد تا، سرعت‌های باد را با استفاده از داده‌های اندازه‌گیری شده منطقه برای آموزش و تست پیش‌بینی کند. دما، فشار هوا، تابش خورشیدی و ارتفاع به عنوان ورودی برای مدل شبکه عصبی مصنوعی در نظر گرفته و سرعت‌های باد میانگین روزانه پیش‌بینی شد. میانگین مطلق درصد خطا (MAPE) و ضریب همبستگی (R) که در پیش‌بینی سرعت باد میانگین روزانه به ترتیب، ۴.۵۵٪ و ۹۴٪ بدست آمدند و مدل با سرعت‌های باد ایستگاه دیگری که داده‌های اندازه‌گیری شده آن موجود بود اعتبار سنجی شد. میانگین مطلق درصد خطا ۶.۴۸۹٪ و ضریب همبستگی ۰.۹۵ بدست آمد که نشان دهنده دقت بالای پیش‌بینی مدل شبکه عصبی مصنوعی است.

کادناس و همکاران (۲۰۱۶b)، دو مدل پیش‌بینی سرعت باد گام بعد را مقایسه کردند. آن‌ها از مدل تک متغیره با استفاده از میانگین متحرک جامع خودبرگشتی (ARIMA) خطی و مدل چند متغیره شبکه عصبی مصنوعی NARX و متغیرهای فشار هوا، دمای هوا، جهت باد، تابش خورشیدی و رطوبت نسبی، به علاوه سرعت باد تاخیر داده شده استفاده کردند. هر دو مدل با استفاده از دو پایگاه داده در دو منطقه متفاوت، یکی پایگاه داده اندازه‌گیری‌های ساعتی میانگین در لاماتا مکزیک و دیگری پایگاه داده اندازه‌گیری‌های ۱۰ دقیقه‌ای میانگین در متپک مکزیک، توسعه داده شدند. هدف

<sup>1</sup> Garson

<sup>2</sup> Ramasemy et al

<sup>3</sup> Neural Network Fitting Tool

اصلی، مقایسه اثر متغیرهای هواشناسی مختلف بر عملکرد مدل چند متغیره پیش‌بینی سرعت باد و مقایسه آن با مدل تک متغیره خطی بوده است. مدل NARX نتایج بهتری در مقایسه با مدل ARIMA به ترتیب برای میانگین خطای مطلق و میانگین مربعات خطا بین ۵.۵٪ و ۱۰.۶٪ برای پایگاه داده ساعتی و بین ۲.۳٪ و ۱۲.۸٪ برای پایگاه داده ده دقیقه‌ای ارائه کرد.

فیلیک و همکاران<sup>۱</sup> (۲۰۱۷)، به بررسی مدل‌های شبکه‌های عصبی مصنوعی، با استفاده از اندازه‌گیری‌های هواشناسی محلی متعددی مانند مقادیر سرعت باد، دما و فشار هوا پرداختند و بیان کردند که مدل‌های چند متغیره پیش‌بینی سرعت باد بر اساس شبکه عصبی مصنوعی برای موارد گوناگونی قادر به بهبود هستند. عملکردهای جذر میانگین مربعات خطا (RMSE) و میانگین خطای مطلق (MAE) مدل چند متغیره شبکه عصبی مصنوعی نتایج مطلوبی ارائه کرد.

فینامور و همکاران<sup>۲</sup> (۲۰۱۷)، روشی برای پیش‌بینی سرعت باد بلند مدت بر اساس ارزیابی مکانی زمانی جبهه‌های هوا و مدل داده‌کاوی شبکه عصبی مصنوعی پرسپترون چندلایه (MLPNN) ارائه کردند. در این مدل، پیش‌بینی سرعت باد با استفاده از داده‌های هواشناسی موجود و پیشین مانند فشار، دما و شدت باد توسعه داده شد تا سیر تکاملی جبهه‌های هوا را در ناحیه گسترده در اطراف نقطه مورد نظر توصیف کند. این مدل، با استفاده از داده‌های هواشناسی واقعی آموزش داده شد و سپس جهت پیش‌بینی سرعت باد ۲۴ ساعت بعد مورد استفاده قرار گرفت. کارایی مدل پیش‌بینی با داده واقعی ثبت شده در محل مقایسه شد. مدل شبکه عصبی پیشنهاد شده مقادیر میانگین جذر خطا (۵.۲۷) برای اولین مجموعه شبیه سازی و ۷.۰۵ برای دومین مجموعه) و مقدار درصد خطای مطلوبی ارائه کرد.

---

<sup>1</sup> Filik et al

<sup>2</sup> Finamore et al

## ۲-۵- جمع‌بندی

با توجه به بررسی‌های صورت گرفته، ملاحظه می‌شود که در مطالعات انجام شده در ایران در ارتباط با تغییرات سرعت باد، بیشتر به روندیابی سرعت باد پرداخته شده است، درحالی‌که پیش‌بینی آن به صورت روزانه به ندرت مورد توجه بوده و همچنین جهت باد نه تنها در ایران بلکه به صورت جهانی کمتر مورد توجه قرار گرفته است. بنابراین در پژوهش حاضر سعی گردید با استفاده از چند مدل شبکه عصبی مصنوعی و بررسی تاثیر پارامترهای مختلف هواشناسی از جمله فشار هوا، دمای هوا، رطوبت نسبی و میزان بارش به مدل‌سازی و پیش‌بینی تغییرات سرعت و جهت باد در کشور پرداخته شود.



# فصل سوم:

## مواد و روش‌ها


در این فصل، ابتدا به معرفی منطقه مورد مطالعه و داده های مورد استفاده پرداخته خواهد شد. سپس، در رابطه با روش انجام تحقیق شامل نحوه استخراج اطلاعات مورد نیاز از داده ها و همچنین مدل های شبکه عصبی مصنوعی مطالبی آورده خواهد شد.

### ۳-۲- منطقه مورد مطالعه

بندر ماهشهر، شهری در جنوب استان خوزستان با طول جغرافیایی  $30.5458^{\circ}$  شمالی و عرض جغرافیایی  $49.1803^{\circ}$  شرقی است. ارتفاع این شهر از سطح دریا در حدود ۳ متر و مساحت آن ۲۷۱۳ هکتار می باشد، که بعد از اهواز وسیع ترین شهرستان در استان خوزستان است. اطراف آن، از شمال به اهواز، از غرب به شادگان، از شرق به رامشیر و امیدیه و از جنوب به خلیج فارس و از جنوب شرق به هندیجان ختم می شود. بندر ماهشهر همچون شادگان، از معدود شهرهای ایران است که دارای خور (شاخه هایی از دریا که به خشکی منشعب می شوند) می باشد و مهمترین آنها خور موسی نام دارد، که از نظر استراتژیک و اقتصادی بسیار حائز اهمیت است. در شکل (۳-۱) نقشه توپوگرافی بندر ماهشهر نشان داده شده است. بندر ماهشهر دارای آب و هوای گرم و مرطوب می باشد و در منطقه خشک و بسیار خشک جغرافیایی قرار دارد. شهرستان بندر ماهشهر در بخش جلگه ای دشت خوزستان واقع شده، و ناهمواری و پستی و بلندی زیادی نداشته و بیشتر به صورت مسطح می باشد. بندر ماهشهر دارای شرجیت شدید در نیمه دوم تابستان، یعنی نیمه دوم مرداد تا اواخر شهریور می باشد، به طوریکه رطوبت نسبی آن تا ۱۰۰ درصد می رسد. از اواخر خرداد و اوایل تیر ماه تا معمولا نیمه مرداد ماه، باد گرمی می وزد. میانگین بارش سالیانه ماهشهر حدود ۱۹۵ میلیمتر است.

بندر ماهشهر، به عنوان یکی از سه منطقه بادخیز استان خوزستان شناسایی شده و با نصب اولین توربین، نخستین شهر استان در تولید انرژی پاک برق بادی می‌باشد. بندر ماهشهر با توجه به وجود جلگه مسطح و مجاورت با خلیج فارس در جنوب غربی خود پتانسیل عظیمی جهت بهره‌گیری از انرژی باد نسبت به دیگر مناطق استان دارا می‌باشد. از دلایل انتخاب این منطقه می‌توان به موارد زیر اشاره کرد:

- وجود زمین‌های گسترده و مسطح
- وجود شرایط آب و هوایی گرم و نیاز به انرژی برق به‌طور مستمر (در طول ۸ ماه فصل گرم)
- وجود بادهای مستمر و با سرعت مناسب
- اهمیت پیش‌بینی سرعت و جهت باد در دریانوردی منطقه



شکل (۳-۱) نقشه توپوگرافی بندر ماهشهر

### ۳-۲-۱- خصوصیات آب و هوایی منطقه

#### ۳-۲-۱-۱- انواع باد منطقه

باد شمال: که با سرعت ۱۲ تا ۱۴ متر بر ثانیه از سمت شمال و شمال غرب می‌وزد و به ندرت در برخی سال‌ها سرعت آن بالغ بر ۱۷ تا ۲۱ متر بر ثانیه نیز افزایش می‌یابد.

باد لئیمر: که در فاصله زمانی ۱۵ مهر تا ۳ آبان می‌وزد و به واسطه قدرت زیاد برای دریانوردان و مراکز صنعتی مخاطره‌آمیز بوده و زیان‌هایی را به بار می‌آورد.

باد غالب: در این منطقه، از جهات غرب-شمال غرب (<sup>۱</sup>WNW) و شمال-شمال غرب (<sup>۲</sup>NNW) بوده و با سرعت متوسط ۶.۳ متر بر ثانیه با زاویه ۳.۵ درجه به بندر می‌وزد. میزان حداکثر و حداقل سرعت باد در محدوده بندر به ترتیب ۳.۶ تا ۹ متر بر ثانیه می‌رسد.

#### ۳-۲-۱-۲- دیگر خصوصیات آب و هوایی منطقه

در زمستان حداقل دما در دی ماه با میانگین ۱۲ درجه سانتیگراد می‌باشد و در بعضی از روزها به ۷ درجه سانتیگراد نیز کاهش پیدا می‌کند. در تابستان حداقل دمای هوا در تیر ماه با میانگین ۳۵ درجه سانتیگراد و در برخی روزها تا ۵۰ درجه سانتیگراد افزایش می‌یابد. حداقل رطوبت هوا در طول سال ۱۵٪ و حداکثر رطوبت ۱۰۰٪ می‌باشد. در جدول (۳-۱) به برخی خصوصیات آب و هوایی سالانه بندر ماهشهر برگرفته از اطلاعات ۱۵ ساله آن طی سال‌های ۱۳۶۶ الی ۱۳۸۲ اشاره شده است.

---

<sup>1</sup> West-NorthWest

<sup>2</sup> North-NorthWest



جدول (۳-۱) خصوصیات آب و هوایی سالانه بندر ماهشهر

مقدار	مشخصات
۳۵ °C	میانگین بیشینه درجه حرارت
۱۲ °C	میانگین کمینه درجه حرارت
۵۰ °C	حداکثر دمای روزانه گرم‌ترین ماه (۱۶- تیر)
۶ °C	حداقل دمای روزانه سردترین ماه (دی)
٪۴۶	متوسط رطوبت نسبی
٪۸۶	متوسط رطوبت نسبی مرطوب‌ترین ماه (آذر- دی)
٪۱۵	متوسط رطوبت نسبی کم‌رطوبت‌ترین ماه (خرداد)
۸۷.۴	متوسط روزهای با گرد و غبار در سال

### ۳-۳- اطلاعات ورودی و آماده‌سازی آن‌ها

#### ۳-۳-۱- داده‌های منطقه

در این تحقیق، از دو گروه داده به عنوان ورودی شبکه عصبی مصنوعی استفاده شده است. داده‌های سرعت باد مدل<sup>۱</sup> GFS دریافت شده از مرکز ملی پیش‌بینی محیطی (NCEP<sup>۲</sup>)، در محدوده ۲۸ تا ۳۱ درجه شمالی و ۴۷ تا ۵۳ درجه شرقی در ارتفاع ۱۰ متری از سطح زمین بر حسب متر بر ثانیه که به صورت شبکه‌ای با سلول‌های ۰.۵ در ۰.۵ درجه و داده‌های مشاهداتی به صورت شش ساعته (در ساعت‌های صفر، ۰۶:۰۰، ۱۲:۰۰ و ۱۸:۰۰) از پارامترهای جهت باد، دمای هوا، فشار هوا، رطوبت نسبی و میزان بارش ثبت شده در ایستگاه سینوپتیک بندر ماهشهر با مختصات جغرافیایی ۳۰ درجه و ۳۳ دقیقه عرض شمالی و ۴۹ درجه و ۹ دقیقه طول شرقی موجود در سازمان هواشناسی ایران (IRIMO<sup>۳</sup>) استفاده شده است. این ایستگاه در فرودگاه ماهشهر با ارتفاع ۶/۲ نسبت به سطح آزاد دریا

<sup>۱</sup> Global Forecast System

<sup>۲</sup> National Centres for Environmental Prediction

<sup>۳</sup> Islamic Republic of Iran Meteorological Organization

واقع شده است. در شکل (۲-۳) موقعیت ایستگاه سینوپتیک بندر ماهشهر نشان داده شده است. همچنین از داده‌های سرعت باد مشاهداتی ثبت شده در ایستگاه مورد نظر به عنوان خروجی شبکه استفاده شده است. تمامی داده‌ها در بازه زمانی ۱ اکتبر ۲۰۱۴ تا ۳۱ جولای ۲۰۱۶ در نظر گرفته شده‌اند.



شکل (۲-۳) موقعیت ایستگاه سینوپتیک بندر ماهشهر

### ۳-۳-۱-۱- سیستم پیش بینی جهانی (GFS)

سیستم پیش‌بینی جهانی (GFS) یک سیستم پیش‌بینی آب و هوای عددی است که جهانی شامل یک مدل کامپیوتری جهانی و آنالیز متغیر می‌باشد که توسط سرویس آب و هوای ملی (NWS) آمریکا اداره می‌شود.

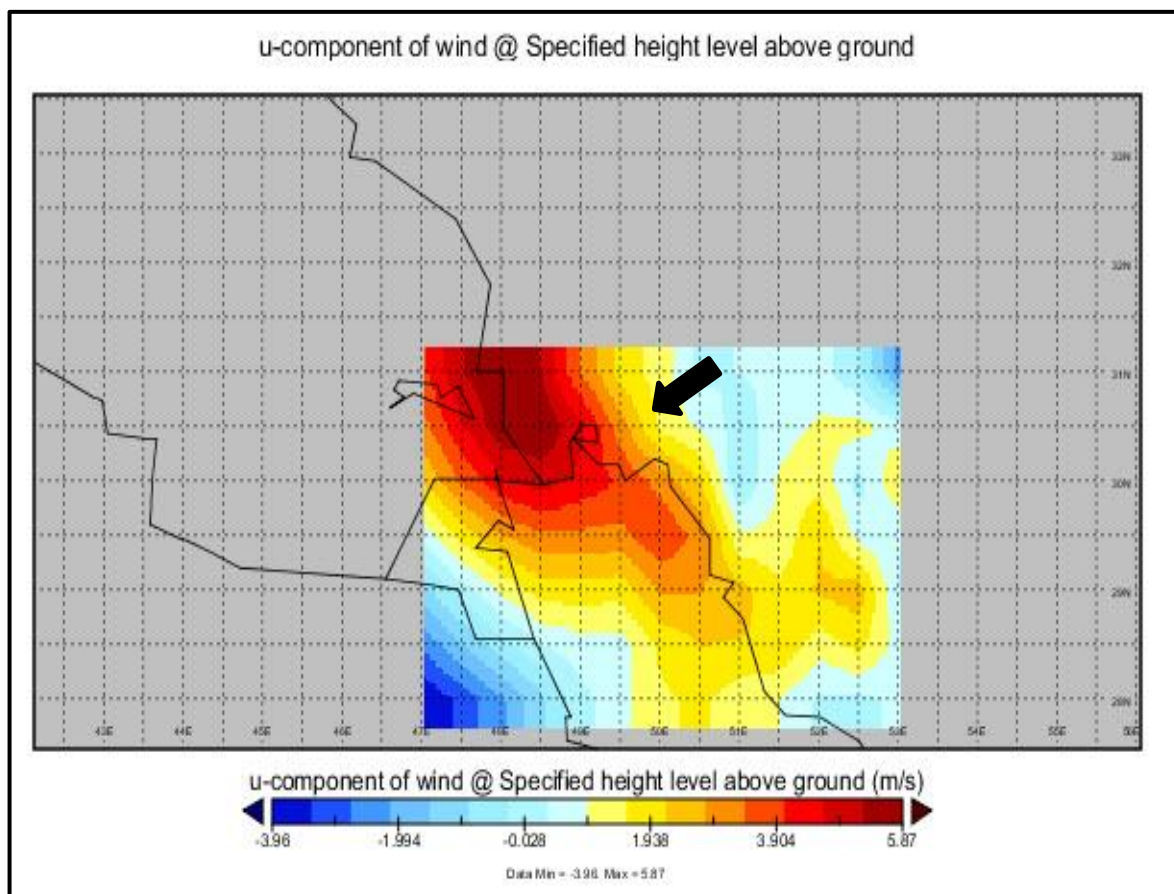
مدل ریاضی در یک روز چهار بار اجرا می‌شود و پیش‌بینی‌هایی برای تا ۱۶ روز بعد اما با کاهش دقت فضایی بعد از ۱۰ روز را تولید می‌کند. توانایی پیش‌بینی به طور کل با زمان و برای پیش‌بینی‌های طولانی مدت تر کاهش می‌یابد (مانند هر مدل پیش‌بینی آب و هوای عددی).

مدل GFS یک مدل طیفی با دقت افقی تقریبی ۱۳ کیلومتر برای ۱۰ روز اول و ۲۷ کیلومتر از ۲۴۰ تا ۳۸۴ ساعت. خروجی مدل GFS نیز برای تولید آمار خروجی مدل استفاده شد.

مدل GFS از چهار مدل مجزا شامل مدل اتمسفر، مدل اقیانوس، مدل زمین یا خاک و مدل دریا تشکیل شده است که با هم عمل می‌کنند و تصویری دقیقی از شرایط آب و هوایی می‌دهند. چندین متغیر اتمسفری و زمین-خاک در این مجموعه داده موجود است از جمله دما، باد و بارش و همچنین رطوبت خاک و غلظت ازون اتمسفری.

### ۳-۳-۲- آماده‌سازی داده‌ها

داده‌های سرعت باد استخراج شده از مدل GFS به‌طور مجزا به‌صورت مولفه‌های افقی و عمودی شبکه‌بندی شده که در بخش پیشین ۳-۳-۱ بیان شد، در محدوده منطقه مورد نظر و بر حسب متر بر ثانیه هستند. در شکل (۳-۳) برای نمونه مولفه افقی سرعت باد در یک زمان مشخص نشان داده شده است. با توجه به اینکه داده‌ها در هر ساعت مشخص سلول‌بندی شده و با فرمت GRIB2 بوده است جهت سهولت کار با استفاده از نرم افزار متلب، خروجی اکسل داده‌ها استخراج شد، به طوری‌که که هر ورق نمایانگر یک سلول می‌باشد. از آنجاییکه سرعت باد مشاهداتی که به عنوان خروجی مدل انتخاب شده به صورت برآیندی از مولفه‌های افقی و عمودی سرعت باد و دارای مقدار مثبت می‌باشد لذا برای همسان‌سازی داده‌های ورودی و خروجی، برآیند داده‌های سرعت باد مدل GFS بدست آمده است.



شکل (۳-۳) نمونه‌ای از مولفه افقی سرعت باد داده‌های مدل GFS و شبکه‌بندی ناحیه مورد نظر

با توجه به اینکه هر ورق در فایل اکسل نمایانگر یک سلول در شبکه‌بندی شکل فوق است، باید بین هر سلول در ساعت مشخص و سرعت باد مشاهداتی متناظر با همان ساعت ضریب همبستگی گرفته شود تا با بهره‌گیری از آن شبکه عصبی مصنوعی به جواب بهینه‌ای دست یابد. پس از بررسی ضرایب همبستگی بدست آمده، سلولی که دارای بهترین ضریب همبستگی است به عنوان ورودی در شبکه عصبی مصنوعی استفاده می‌شود. در این پایان‌نامه، از ضریب همبستگی پیرسون (رابطه ۳-۱) بین داده‌های سرعت باد سلول‌های مختلف با زمان‌های تاخیر متفاوت و سرعت باد مشاهداتی در ایستگاه بند ماهشهر استفاده شد.

$$\rho = r_{xy} = \frac{cov(x,y)}{\sigma_x \sigma_y} \quad (1-3)$$

که  $cov(x, y)$  کوواریانس دو متغیر سرعت باد مدل GFS و سرعت باد مشاهداتی،  $\sigma_x$  انحراف معیار داده‌های سرعت باد مدل GFS و  $\sigma_y$  انحراف معیار داده‌های سرعت باد مشاهداتی است. ورودی‌ها و خروجی مورد نظر جهت اجرا در شبکه عصبی مصنوعی دارای واحدهای مختلفی هستند. از این‌رو به‌منظور همسان‌سازی داده‌ها جهت کسب شبکه عصبی بهینه الزامی است داده‌ها در یک بازه مشخص ۰ تا ۱ و ۱- تا ۱ نرمال‌سازی شوند. پس از آماده‌سازی داده‌های مورد نظر با توجه به بحث-های فوق می‌توان شبکه عصبی مصنوعی را اجرا کرد.

### ۳-۴- روش‌های پیش‌بینی باد

با توجه به ضریب مناسب توزیع سرعت باد در استان خوزستان و نیز وجود خط ساحلی گسترده، پتانسیل احداث مزارع بادی در مناطق مختلف استان از جمله ماهشهر، آبادان، هندیجان، ایذه و شوشتر وجود دارد. با در نظر گرفتن این موضوع که توان تولیدی در نیروگاه‌های بادی با مکعب سرعت باد رابطه مستقیم دارد، ابتدا باید به پیش‌بینی سرعت باد پرداخت. چندین روش پیش‌بینی باد در سال‌های اخیر توسعه داده شده است. هرچند، هر مدل بر اساس طبیعت نوع پیش‌بینی مورد نیاز، برای شرایط مختلفی مناسب است. برخی مدل‌ها به‌منظور پیش‌بینی بلندمدت و برخی به‌منظور پیش‌بینی کوتاه‌مدت مناسب هستند. در این مطالعه، پیش‌بینی سرعت و جهت باد کوتاه‌مدت برای تاکید بر پیش‌بینی یک گام بعد یعنی یک روز بعد استفاده می‌شود. به‌طور کلی، تا سال ۲۰۱۷ سه رویکرد پیش‌بینی باد تا کنون به خوبی مستند شده است: مدل‌های پیش‌بینی آب و هوایی عددی ( $NWP^1$ )، رویکرد سیستم‌های فیزیکی و رویکرد آماری.

### ۳-۴-۱- سیستم‌های پیش‌بینی آب و هوای عددی

سیستم پیش‌بینی آب و هوای عددی ( $NWP$ )، اتمسفر را توسط یکپارچگی عددی معادلات حرکتی، که از حالت‌های جوی رایج شروع شده، شبیه‌سازی می‌کند و این شبیه‌سازی با استفاده از ترسیم

<sup>1</sup> Numerical Weather Prediction

جهان واقعی در یک شبکه‌بندی محاسباتی، که جهان را به الگوی چند ضلعی‌های عظیم با ابعاد واقعی ۶۰ در ۶۰ کیلومتر مربع تقسیم کرده، صورت می‌گیرد. مدل‌های NWP، به علت جمع‌آوری داده‌های فراوان، پیچیده و گران هستند و توسط محققان ملی سرویس‌های آب و هوا اجرا می‌شوند. با استفاده از این مدل‌ها، دقت به یک منطقه کوچک‌تر جهت پاسخ به کشور مورد نظر محدود می‌شود. برای مثال به دقتی محدود به ۷ در ۷ کیلومتر مربع یا کمتر کاهش می‌یابد. متغیرهایی که در هر نقطه از شبکه محاسبه می‌شوند، میانگینی از سلول شبکه هستند. از این رو، پیش‌بینی به طور واضح برای تمام نقاط شبکه در سلول به صورت میانگین زمانی بهینه است (لانژ<sup>۱</sup>، ۲۰۰۳).

### ۳-۴-۲- سیستم‌های فیزیکی

سیستم‌های فیزیکی، دینامیک اتمسفر را توسط مفهوم پارامتریک کردن لایه مرزی سیاره‌ای (PBL<sup>۲</sup>) مدل می‌کنند، که لایه مرزی اتمسفری (ABL<sup>۳</sup>) نیز شناخته می‌شوند. لایه مرزی اتمسفری، پایین‌ترین بخش از اتمسفر است که در امتداد تماس با سطح زمین می‌باشد. در این سیستم‌ها، مقادیر فیزیکی مانند سرعت، دما و رطوبت (باد یا هوا) آشفته هستند. از نظر تئوری، دو نوع پایه از سیستم‌های پیش‌بینی فیزیکی وجود دارد. سیستم‌هایی که بر اساس شبیه‌سازی‌های سیال دینامیکی عملی هستند و مشابه سیستم‌های NWP می‌باشند و مدل‌های تشخیصی که توسط پارامتریک کردن PBL کار می‌کنند. مفهوم ABL توجه بسیاری از محققان را در سال‌های اخیر جلب کرده است. از این رو، سیستم‌های فیزیکی به دو بخش شبیه‌سازی‌های عددی و مدل‌های تشخیصی تقسیم می‌شوند. شبیه‌سازی‌های عددی می‌توانند به طور کلی به توسعه‌ای از سیستم‌های NWP اشاره کنند. همانطور که پیش‌تر بحث شد، NWP نمی‌تواند سرعت باد را به طور واضح در یک نقطه از فضا پیش‌بینی کند و پاسخی کلی برای مقدار یک سلول در شبکه‌بندی می‌دهد. شبیه‌سازی‌های عددی، به وضوح پدیده‌های جوی را که در محدوده مشابه با سیستم NWP تغییر می‌کنند (۱۰-۱۰۰۰۰ کیلومتر) از

<sup>1</sup> Lange

<sup>2</sup> Planetary Boundary Layer

<sup>3</sup> Atmospheric Boundary Layer

سیستم‌های آب و هوایی با مقیاس بزرگ (۱-۱۰ کیلومتر) به ترازهای با مقیاس کوچک (۰.۱-۱۰۰ متر) مدل می‌کنند (لانز، ۲۰۰۳).

برخی از مدل‌های عددی که بر اساس پارامتریک‌کردن لایه مرزی سیاره‌ای توسعه داده شده اند عبارت‌اند از: مدل بزرگ مقیاس نسل پنجم ( $MM5^1$ )، مدل مطالعه و پیش‌بینی آب و هوا ( $WRF^2$ )، مدل طیف‌های منطقه ای ( $RSM^3$ ) و سیستم پیش‌بینی جهانی (GFS) (کیم و همکاران، ۲۰۰۷). مدل‌های تشخیصی نیز مانند مدل‌های عددی، بر اساس پارامتریک‌کردن جریان لایه مرزی سیاره‌ای، اما با شرایط دینامیکی کمتر، می‌باشند. این موضوع توسط پالایش نتایج بدست آمده از سیستم NWP صورت می‌گیرد. خروجی NWP به شرایط محلی برای مثال زبری سطح، کوهنگاری سطح زمین، موانع و گرادیان دمای اتمسفر موجود وابسته است، که اثبات شده نتایج پیش‌بینی بهتری تولید می‌کند، و الزاما به گذشته وابسته نیست. چنین سیستم‌هایی توسط لندبرگ در آزمایشگاه ملی ریسو در دانمارک در سال ۱۹۹۳ توسعه داده شده اند (لانز، ۲۰۰۳).

### ۳-۴-۳- رویکرد سیستم‌های آماری

سیستم‌های آماری، بر اساس آموزش مدل‌هایی با نمونه داده‌های واقعی مشخص در یک منطقه اجرا می‌شوند، که از تعدادی چرخه آماری مجزا استفاده می‌کند. تفاوت بین خروجی پیش‌بینی شده و خروجی مورد نیاز (خطا)، با تنظیم دقیق آن به سطحی که بتواند برای حال حاضر یا پیش‌بینی استفاده شود، حداقل‌سازی می‌شود. رویکردهای آماری به سه زیربخش تقسیم می‌شوند. ابزار پیش‌بینی انرژی باد ( $WPPT^5$ )، ابزاری آماری است که توسط آزمایشگاه‌های ملی دانمارک برای پیش‌بینی آب و هوا توسعه داده و اجرا می‌شود. ابزار پیش‌بینی انرژی باد بر اساس مدلی از نوع NARX است، که سرعت باد را به عنوان یک فرآیند تصادفی غیرخطی، ناپایدار و متغیر زمانی از اتمسفر ارائه می‌کند. رویکرد دوم آماری، مربوط به سرعت‌های باد آینده به صورت مبهم و نامعلوم می‌باشد و از این‌رو در تلاش است

<sup>1</sup> Mesoscale Model 5

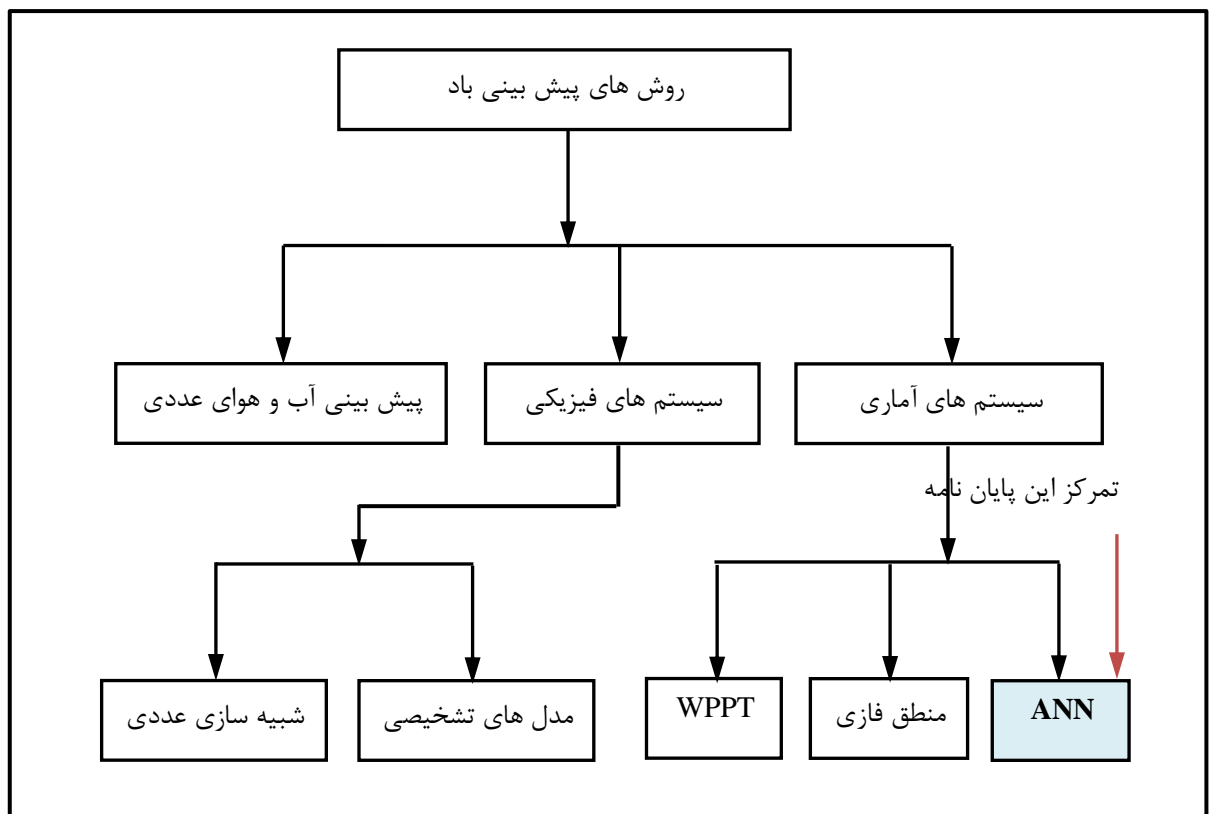
<sup>2</sup> Weather Research and Forecasting

<sup>3</sup> Regional Spectral Model

<sup>4</sup> Kim et al

<sup>5</sup> Wind Power Prediction Tools

تا توسط تقریبی منطقی با مفهوم منطق فازی به پاسخی دست یابد. شبکه‌های عصبی مصنوعی (ANN) سومین رویکرد آماری است که جدیدترین روش توسعه داده شده برای پیش‌بینی صحیح است. شبکه‌های عصبی مصنوعی موضوع پایان‌نامه جاری می‌باشد و در بخش‌های بعد با جزئیات به آن پرداخته می‌شود. شکل (۳-۴) خلاصه‌ای از روش‌های پیش‌بینی سرعت باد که در مطالب فوق بحث شد و تمرکز این پایان‌نامه را نشان می‌دهد.



شکل (۳-۴) خلاصه‌ای از سیستم‌های پیش‌بینی باد

### ۳-۵- شبکه‌های عصبی مصنوعی

#### ۳-۵-۱- اصول پایه شبکه عصبی مصنوعی

شبکه عصبی مصنوعی (ANN)، یک سیستم پردازش اطلاعات است که ساختار عصبی مغز انسان را برای آنالیز داده‌ها، یافتن الگوها، طبقه‌بندی و پیش‌بینی از طریق فرآیند یادگیری و با استفاده از




گروهی از معادلات ریاضی شبیه‌سازی می‌کند (تو<sup>۱</sup>، ۱۹۹۶). تاریخچه شبکه عصبی مصنوعی به سال ۱۹۴۳ باز می‌گردد، زمانیکه وارن مک‌کلاچ روان‌شناس و والتر پیترز ریاضی‌دان یک نرون ساده را معرفی کردند. بر اساس مطالعات، محققان کشف کردند که نرون‌های بیولوژیکی می‌توانند به‌عنوان مولفه‌های جریان مفهومی ارائه شوند که قادرند چندین کار محاسباتی را انجام دهند (کروسه و اسماگت، ۱۹۹۶).

چندین لایه نرون (گره) در یک شبکه عصبی مصنوعی وجود دارد. هر لایه چندین ورودی برای گره-های خود دریافت می‌کند و بعد از اعمال چند معادله ریاضی، اطلاعات به لایه بعدی منتقل می‌شود. بنابراین، هر لایه با اطلاعات لایه بعدی تغذیه می‌شود، این موضوع، مفهوم پایه یک شبکه عصبی مصنوعی است. سه لایه اصلی در یک شبکه عصبی مصنوعی وجود دارد: لایه‌های ورودی، مخفی و خروجی. لایه ورودی هیچگونه محاسباتی انجام نمی‌دهد و از این رو در یک شبکه تنها نرون‌های لایه-های مخفی و خروجی به حساب می‌آیند. قرارگیری نرون‌ها در یک لایه و لایه‌ها در یک شبکه توپولوژی یا یک ساختار، شبکه عصبی نامیده می‌شود. مزیت اصلی شبکه عصبی مصنوعی با چندین لایه نسبت به یک مدل تک لایه، در توانایی حل مسائل غیرخطی است (اسونسون، ۲۰۱۵). شکل (۳-۵) طرح کلی یک مدل شبکه عصبی مصنوعی با یک لایه مخفی را نشان می‌دهد.

---

<sup>1</sup> Tu



شکل (۳-۵) طرح کلی شبکه عصبی مصنوعی با یک لایه مخفی

متغیرهای ورودی،  $x_i$ ، به سمت نرون‌های لایه مخفی،  $h_j$ ، و سپس به سمت متغیرهای خروجی،  $y_k$ ، ترسیم می‌شوند و توسط معادلات زیر محاسبه می‌شوند:

$$h_j = f(\sum_i w_{1ji} + b_{1j}) \quad (۲-۳)$$

$$y_k = g(\sum_j w_{2kj} + b_{2k}) \quad (۳-۳)$$

که  $f$  و  $g$  توابع فعال‌سازی،  $w_{1ji}$  و  $w_{2kj}$  ماتریس‌های وزنی و  $b_{1j}$  و  $b_{2k}$  بایاس‌ها هستند (هسیه)<sup>۱</sup>، (۲۰۰۹).

### ۳-۵-۲- شبکه عصبی مورد استفاده در این مطالعه

در این تحقیق، دو نوع شبکه عصبی مصنوعی، شبکه عصبی مصنوعی پرسپترون چندلایه (MLP) پیشخور و شبکه عصبی مصنوعی NARX جهت پیش‌بینی سرعت و جهت باد مشاهداتی یک روز بعد

<sup>۱</sup> Hsieh

(با استفاده از تاخیر در ورودی‌ها) و در ساعت مشخص مورد استفاده قرار گرفت و همچنین یک شبکه عصبی MLP دیگر با یک روش نمونه‌گیری بگینگ، که در بخش‌های آتی به شرح آن پرداخته خواهد شد، توسعه داده شد.

شبکه‌های عصبی پیشخور با الگوریتم پس‌انتشار، اطلاعات ثبت شده را توسط یادگیری همزمان و مقایسه خروجی با نتایج واقعی پردازش می‌کنند. لایه بعدی به‌طور کامل به لایه پیشین متصل است و از این‌رو خطای بدست آمده در یک پیش‌بینی کارا، به عنوان یک ورودی با هدف حداقل کردن آن در مرحله بعدی (گرادیان نزولی) استفاده می‌شود، از این‌رو الگوریتم پس‌انتشار نامیده می‌شود.

از آنجاییکه شبکه عصبی پیشخور، داده رهنمون (بر اساس داده‌ها) است، اولاً، ورودی‌ها را بدون ایجاد پیش‌فرض در طول فرموله کردن مدل به خروجی‌ها تصویر و آنچنان‌که مدل‌های نادرست همیشه منجر به خطا خواهند شد، مدل را دقیق‌تر می‌کند. ثانیاً، تقریب زنده‌های جامعی از مدل‌های دینامیکی و غیرخطی می‌باشند. شبکه‌های عصبی پیشخور، حاصل چندین اتصال هستند که در آن‌ها اطلاعات (وزن‌ها) از یک گره (نرون) به دیگری منتقل می‌شوند. به علاوه، آن‌ها بسیار آسان اجرا می‌شوند و در صورت نیاز، به انواع دیگر شبکه قابل‌تعمیم هستند. همچنین طبق مطالعات پیشین ثابت شده است که اجراکننده بهتر و سریع‌تری در پیش‌بینی هستند، بنابراین هزینه محاسبات را کاهش می‌دهند (تسای و لی<sup>۱</sup>، ۲۰۰۵).

مدل NARX، یک شبکه عصبی بازگشتی غیرخطی با ورودی خارجی است، که به‌طور معمول در مسائل پیش‌بینی یک یا چند گام بعد با در نظر گرفتن زمان تاخیر و توسط داده‌های پیشین استفاده می‌شود. شبکه‌های بازگشتی، یک یا چند حلقه پسخور دارند. به‌طور کلی، این نوع شبکه‌ها دو کاربرد اساسی دارند: حافظه شرکت‌پذیری و شبکه‌های نگاشت ورودی-خروجی. شبکه‌های نگاشت ورودی-

---

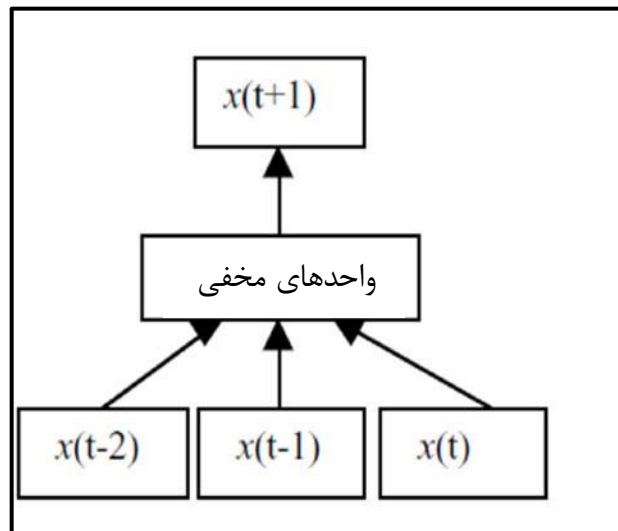
<sup>1</sup> Tsai and Lee

خروجی در مدل سازی و پیش بینی سیگنال به صورت سری های زمانی مورد استفاده قرار می گیرند (کادناس و همکاران، ۲۰۱۶ b). رابطه ریاضی شبکه های NARX به صورت زیر می باشد:

$$y(t) = f(y(t-1), y(t-2), \dots, Y(t-n_y), u(t-1), u(t-2), \dots, u(t-n_u)) \quad (۴-۳)$$

که  $y(t)$  و  $u(t)$  ورودی های مستقل (خارجی) گذشته و حال در یک گام مجزای  $t$  هستند و  $f$  یک تابع نگاشت غیر خطی می باشد. که مقدار بعدی خروجی وابسته  $y(t)$  بر مقادیر قبلی سیگنال خروجی یک متغیر مستقل سیگنال ورودی بازگشت می کند.

روش استاندارد پیش بینی با شبکه های عصبی، استفاده از متغیرهای دارای تاخیر به عنوان ورودی ها و متغیرهای مقدم، به عنوان خروجی مورد انتظار شبکه می باشد. شکل (۶-۳) روش بیان شده را نشان می دهد.



شکل (۶-۳) روش استاندارد پیش بینی سری های زمانی با شبکه های عصبی مصنوعی

که  $x(t-2)$  و  $x(t-1)$  دو اندازه گیری پیشین،  $x(t)$  متغیر ورودی فعلی و  $x(t+1)$  خروجی پیش بینی شده می باشد. اختلاف بین متغیرهای خروجی واقعی و پیش بینی شده باید مورد توجه قرار گیرد.

### ۳-۵-۳- الگوریتم‌های بهینه‌سازی

در طی فرآیند بهینه‌سازی، گرادیان تابع هدف نسبت به پارامترها، به منظور حداقل‌سازی خطا (E)، توسط الگوریتم پس‌انتشار صورت می‌گیرد. روش پس‌انتشار شامل دو گام اصلی است. ابتدا در گام پیشرو، پارامترها به صورت تصادفی مقداردهی اولیه می‌شوند و مقادیر خروجی پیش‌بینی می‌شود. سپس، تابع هدف محاسبه می‌شود. در طی گام پسرو، پارامترها تا جایی به‌روزرسانی می‌شود که تابع هدف به حداقل می‌رسد. برای انجام این کار، استفاده از گرادیان E نسبت به پارامترها، جهت محاسبه پارامترهای جدید از معادله زیر استفاده می‌شوند:

$$p_{new} = p_{old} - \eta * \frac{\partial E}{\partial p_{old}} \quad (۵-۳)$$

$\eta$  نرخ یادگیری نامیده می‌شود و عاملی بهینه است که بر قطعیت و سرعت یادگیری تاثیر می‌گذارد.

الگوریتم لونبرگ-مارکوارت یکی از سریع‌ترین توابع آموزش شبکه‌های عصبی مصنوعی است. این روش قوی‌تر از گرادیان نزولی می‌باشد، بدین معنی که می‌تواند به حداقل نهایی نزدیک شود حتی اگر داده‌ها خیلی پرت باشند. هرچند، در حضور چندین حداقل، حدس اولیه برای پارامترها باید نسبتاً به جواب نهایی نزدیک باشد به طوری که الگوریتم بتواند به حداقل جهانی<sup>۱</sup> نزدیک شود. همچنین این الگوریتم در مسائل رگرسیون غیرخطی نسبت به شناسایی الگو<sup>۲</sup> بسیار مناسب‌تر است.

### ۳-۵-۴- اندازه لایه مخفی<sup>۳</sup>

تعیین اندازه لایه مخفی (H) یکی از سخت‌ترین وظایف در مدل‌سازی شبکه عصبی است. در اینجا، H به تعداد نورون‌های مخفی مرتبط با شبکه عصبی اشاره می‌کند. H کوچکتر، با تعداد کمی ورودی، نمی‌تواند همه اطلاعات اساسی مربوط به داده‌ها را ضبط کند و تنها منجر به تولید برآوردی خطی از

<sup>۱</sup> Global

<sup>۲</sup> Pattern Recognition

<sup>۳</sup> Hidden Layer

خروجی واقعی مورد نیاز می‌شود. از طرف دیگر، H بزرگتر بیش از پیش برای آموزش زمان‌بر است و تمایل به تولید نتایج خوب در طول آموزش و اعتبارسنجی دارد، اما باعث ایجاد خطاهای بزرگ در مرحله آزمون می‌شود. بدین ترتیب منجر به "بیش برآزش"<sup>1</sup> و از دست دادن توانایی تعمیم می‌شود (بشیر و هجمیر، ۲۰۰۰، نگاندرا و خاره<sup>۲</sup>، ۲۰۰۶).

تانگ و فیشویک اشاره کردند که تمایلی بین تعداد واحدهای مخفی و خطای شبکه وجود دارد. تا یک نقطه مشخص، خطا به حداقل خود کاهش می‌یابد و سپس شروع به افزایش می‌کند. آنها نتیجه گرفتند که به این ترتیب تعداد واحدهای مخفی بهینه برای سری‌های مختلف از داده‌ها وجود دارد (تانگ و فیشویک<sup>۳</sup>، ۱۹۹۳).

در اغلب موارد، محققان ممکن است مجبور شوند مدل‌سازی با اندازه‌های مختلف لایه‌های مخفی را امتحان کنند، که لزوماً مطابق با یک قانون خاص نیستند (سعی و خطا). نگاندرا و خاره در مطالعه خود نیز پیشنهاد می‌کنند که قوانین در بدست آوردن اندازه بهینه لایه مخفی به نتیجه نرسیدند، با اشاره به اینکه بهترین راه برای به دست آوردن اندازه لایه مخفی مورد نیاز، تنظیم مکرر اندازه در هنگام اندازه‌گیری خطا در طی آزمون شبکه عصبی می‌باشد (نگاندرا و خاره، ۲۰۰۶).

### ۳-۵-۵- مقداردهی اولیه وزن شبکه

بردار وزن اولیه به صورت تصادفی اختصاص داده می‌شود و سپس توسط جستجوی تکراری حین آموزش ثابت می‌شود. نگوین و ویدرو پیشنهاد کردند که مقداردهی اولیه وزن‌های سازگار بر تعداد زیادی از مسائل آموزش موجب بهبود قابل‌ملاحظه‌ای در کارایی یادگیری می‌شود (نگوین و ویدرو<sup>۴</sup>، ۱۹۹۰). در این پایان‌نامه نیز مقداردهی اولیه وزن به صورت تصادفی و بر اساس پیش‌فرض نرم افزار متلب صورت گرفته است.

<sup>1</sup> Overfitting

<sup>2</sup> Nagendra and Khare

<sup>3</sup> Tang and Fishwick

<sup>4</sup> Nguyen and widrow

### ۳-۵-۶- نرخ یادگیری<sup>۱</sup>

نرخ یادگیری ( $\eta$ )، کمیت سنجش شتاب است که در آن بردار وزن تغییر می‌کند. نرخ یادگیری می‌تواند تماماً ثابت باشد، همانطور که در این پایان‌نامه انجام شده است. این نرخ پارامتر می‌تواند هر چیزی بین ۰ تا ۱۰ باشد. در تمام شبکه‌های ایجاد شده برای این پایان‌نامه، نرخ یادگیری از ۰.۰۱ به نتایج مطلوبی رسید (بشیر و هجمیر، ۲۰۰۰).

### ۳-۵-۷- ضریب مومنتم<sup>۲</sup>

ضریب مومنتم ( $\mu$ ) پس‌انتشار، پارامتری است که در به‌روزرسانی وزن اعمال می‌شود، به معنی سرعتی که در آن بردار وزن تغییر می‌کند. بسیاری از نویسندگان پیشنهادات مختلفی در مورد چگونگی ثابت کردن ضریب مومنتم کردند (بشیر و هجمیر، ۲۰۰۰). برای این پروژه، ضریب مومنتم بین ۰.۰ تا ۰.۱، همانطور که توسط (هسون، ۱۹۹۵) پیشنهاد شد، نتایج رضایت‌بخشی تولید کرد.

### ۳-۵-۸- تعداد سیکل‌های آموزش (تکرارها)<sup>۳</sup>

تکرارها به عنوان یکی از پارامترهای آموزش تنظیم می‌شوند و در سنجش زمان آموزش توسط یک شبکه عصبی، به‌منظور دستیابی به همگرایی و تنظیم هدفی جهت تعیین حد شبکه‌ای آموزش داده شده اهمیت دارند. در این مطالعه، تکرارهای آموزش توسط سعی و خطا، در محدوده ۱۰۰ تا ۱۰۰۰ تنظیم شدند. در بیشتر موارد ۱۰۰۰ دوره برای تمام مدل‌های ساخته شده نتایج رضایت‌بخشی ارائه کرده است.

---

<sup>1</sup> Learning Rate

<sup>2</sup> Momentum Coefficient

<sup>3</sup> Epochs

### ۳-۵-۹- ارزیابی عملکرد سیستم

شبکه‌های عصبی، تماماً در مورد یافتن وزن‌هایی است که خطای بین برخی ورودی‌ها و خروجی مورد انتظار در یک فرآیند مدل‌سازی را به حداقل می‌رساند. به عنوان مثال، اگر هدف این پروژه پیش‌بینی رفتار آینده یک پدیده باشد، نتیجه نهایی می‌تواند نشان دهد که طراح چقدر نزدیک به واقعیت مدل‌سازی کرده است. این مرحله‌ای است که این پایان‌نامه بر آن متمرکز است، زیرا به‌وضوح تغییرپذیری داده‌های اصلی را از داده‌های پیش‌بینی شده متمایز می‌کند. از تکنیک‌های اندازه‌گیری خطا برای ارزیابی رابطه بین دو مجموعه داده، از جمله میانگین مربعات خطا (MSE)، جذر میانگین مربعات خطا (RMSE)، ضریب مربع همبستگی ( $R^2$ ) یا گرفتن ضریب ساده همبستگی (R) بین دو مجموعه داده به کار رود. هر یک از این اندازه‌گیری‌های خطا، بر اساس اهداف مطالعه، مزایا و معایب خاص خود را دارد.

RMSE و MSE در حال حاضر بیش از پنج دهه، به خصوص در مسائل پیش‌بینی به عنوان یک شاخص وضوح (حساسیت) مورد استفاده قرار گرفته است. زیرا اجرای آن‌ها ساده است، حافظه کامپیوتری کمتری نیاز دارند و مفهوم فیزیکی واضحی را فراهم می‌کنند و برای درک بهتر همه استفاده شده‌اند (وانگ و بوویک<sup>۱</sup>، ۲۰۰۹).

استفاده از MSE و RMSE به‌ویژه در شبکه‌های عصبی به تازگی محبوبیت خود را به عنوان ابزار اندازه‌گیری عملکرد به دست آورده و به طور گسترده‌ای مورد استفاده قرار گرفته‌اند (فراری و استنجل<sup>۲</sup>، ۲۰۰۵، آلاداگ و همکاران، ۲۰۰۹، الشیعه، ۲۰۱۱). برای هر مدلی که در این مطالعه طراحی شده است، میانگین مربعات خطا (MSE) و جذر میانگین مربعات خطای (RMSE) در پیش‌بینی سرعت و جهت باد برای مقایسه قطعیت روش‌های مختلف مورد استفاده قرار گرفته‌اند و روابط ریاضی آن به شکل زیر است:

<sup>1</sup> Wang and Bovik

<sup>2</sup> Ferrari and Stengel



$$MSE = \frac{1}{N} \sum_{i=1}^N (y_m - y_t)^2 \quad (6-3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_m - y_t)^2}{N}} \quad (7-3)$$

که  $y_m$  پیش‌بینی مدل و  $y_t$  مشاهدات واقعی برای هر گام زمانی است.

علاوه بر این، MSE و RMSE در ایجاد مقایسه‌های بین چندین مدل با مجموعه داده‌ها و مشاهدات مشابه مفید هستند. در صورت مقایسه بیش از یک مدل، یک شاخص مهم به دست آمده این است که چگونه مدل، در مقایسه با بقیه عملکرد بهتری دارد. همچنین، ضریب همبستگی در مجموعه داده‌های آزمون، آموزش و اعتبار سنجی نیز بررسی شده‌اند.

### ۳-۶- طراحی شبکه عصبی مصنوعی

#### ۳-۶-۱- انتخاب ورودی و آماده‌سازی

مطالعات پیشین پیشنهاد می‌کنند که سرعت و جهت باد، به دمای هوا، میزان بارش، فشار هوا و رطوبت نسبی وابسته است. هدف این مطالعه در نظر گرفتن تمام پیش‌بینی کننده‌های اشاره شده جهت دستیابی به پیش‌بینی دقیق‌تری از سرعت و جهت باد می‌باشد.

بنابراین، شبکه عصبی مصنوعی طراحی شده چندین ترکیب از متغیرها را در نظر می‌گیرد. این متغیرها در پیش‌بینی سرعت باد، سرعت باد استخراج شده از مدل GFS، جهت باد، دمای هوا، رطوبت نسبی، فشار هوا و میزان بارش به عنوان ورودی و سرعت باد مشاهداتی به عنوان خروجی می‌باشند. همچنین در پیش‌بینی جهت باد از سرعت باد مدل GFS و پارامترهای هواشناسی مشاهداتی معرفی شده به عنوان ورودی و جهت‌های باد افقی و عمودی مشاهداتی به عنوان خروجی استفاده می‌شود.

### ۳-۶-۲- نرمال سازی

داده‌های استفاده شده در مدل شبکه عصبی مصنوعی باید ابتدا نرمال سازی شوند. نرمال سازی داده‌ها اثر اندازه متغیرها بر مدل را به حداقل می‌رساند (فرانسیس<sup>۱</sup>، ۱۹۹۹). این امر مقادیر ورودی، متغیر-های مختلف را تنظیم می‌کند تا در محدوده‌ای یکسان باشند، و بایاس شبکه عصبی مصنوعی یک متغیر نسبت به دیگری را به حداقل برساند.

روش‌های گوناگونی برای نرمال کردن یک مجموعه داده وجود دارد. روش اعمال شده در این کار، نرمال سازی حداقل- حداکثر نام دارد. این روش مقادیر عضو A را طبق مقادیر حداقل و حداکثر آن‌ها نرمال و یک مقدار a را در بردار A به  $\hat{a}$  در محدوده [کمتر، بیشتر] طبق رابطه (۳-۸) تبدیل می‌کند (نایاک و همکاران، ۲۰۱۴). تمام مقادیر به جز دما در بازه [۰,۱] نرمال می‌شوند. دما در محدوده [-۱,۱] نرمال می‌شود.

$$\hat{a} = \frac{a - \min A}{\max A - \min A} \quad (۳-۸)$$

داده جهت باد با استفاده از سینوس و کسینوس مقادیر خود نرمال سازی شد.

### ۳-۶-۳- نمونه‌گیری داده‌ها

ممکن است بتوان قطعیت الگوریتم یادگیری ماشین (برای مثال شبکه عصبی مصنوعی) را با اجرای برخی تکنیک‌های نمونه‌گیری بهبود بخشید. یکی از این روش‌ها بگینگ یا متراکم شدن خودکار<sup>۲</sup> نامیده می‌شود، که امکان بیش‌برازش را کاهش می‌دهد. روش پیش‌بینی‌کننده‌های بگینگ می‌تواند چندین مجموعه پیش‌بینی‌کننده از یک مجموعه داده منفرد تولید کند (بریمان<sup>۳</sup>، ۱۹۹۴). از رویکردهای دیگر مقابله با موضوع بیش‌برازش، روش اعتبارسنجی متقابل است، که باید بعد از نمونه-

<sup>۱</sup> Francis

<sup>۲</sup> Bootstrap Aggregating

<sup>۳</sup> Brieman

گیری داده با استفاده از روش بگینگ اعمال شود. هرچند، این روش شدیداً محاسباتی است و با توجه به روش اجرا شده حاضر، برای جلوگیری از بیش‌برازش و نتایج مورد نیاز صحیح منطقی، تنها بهبود اندکی را می‌توان انتظار داشت.

در این مطالعه، روش پیش‌بینی‌کننده‌های بگینگ برای ساخت ۱۰ زیرمجموعه تصادفی از هر مجموعه داده آموزش استفاده شده است. تا زمانیکه در طی هر اجرای شبکه عصبی پارامترهای اولیه به صورت تصادفی انتخاب می‌شوند، پیش‌بینی می‌تواند اندکی متفاوت باشد و به عنوان نتیجه، RMSE در هر اجرا تغییر خواهد کرد. به‌منظور حداقل‌سازی خطای تصادفی، مدل ۱۰ بار اجرا می‌شود و میانگین حسابی ۱۰ اجرا را به عنوان پیش‌بینی آن به صورت خروجی ارائه می‌کند.

چندین مدل شبکه عصبی مصنوعی با ترکیب‌های مختلف از ورودی به عنوان حساسیت مطالعه برای یافتن موثرترین پیش‌بینی‌کننده طراحی می‌شود.

### ۳-۶-۴- آموزش، اعتبارسنجی و آزمون مجموعه داده‌ها

یک گام بحرانی در آماده‌سازی داده‌ها برای یک سیستم پیش‌بینی تقسیم داده‌های موجود به دو گروه کاملاً مجزا یعنی مجموعه داده‌های آموزش و آزمون می‌باشد. مجموعه داده آزمون نباید به هیچ شکلی در فرآیند آموزش مورد استفاده قرار گیرد، تا به سیستم پیش‌بینی اجازه دهد که با یک مجموعه داده مستقل به‌طور کامل ارزیابی شود. برای هر گروه، دو سوم از داده‌ها به صورت تصادفی برای شکل دادن مجموعه داده آموزش و باقی در مجموعه داده آزمون قرار می‌گیرند.

برای مدل‌های شبکه عصبی مصنوعی، مجموعه داده آموزش خود نیز به دو مجموعه مختلف برای آموزش و اعتبارسنجی تقسیم شد. ۷۰ درصد برای آموزش و ۳۰ درصد باقی‌مانده برای هدف اعتبارسنجی به کار رفته است.

رایج‌ترین روش اعتبارسنجی مدل در طی مرحله آموزش روش اعتبارسنجی متقابل<sup>۱</sup> است. در این رویکرد مجموعه داده‌های آموزش به چندین دسته تقسیم می‌شوند، که در ابتدا، یک دسته به مجموعه اعتبارسنجی اختصاص داده شده و بقیه دسته‌ها برای مجموعه داده‌های آموزش در نظر گرفته می‌شوند. سپس این رویکرد برای هر دسته به عنوان مجموعه اعتبارسنجی تکرار می‌شود. عملکرد مدل میانگین، عملکرد دسته‌ها خواهد بود (هرناندز و همکاران<sup>۲</sup>، ۲۰۱۶).

### ۳-۶-۵- انتخاب خصوصیات سیستم

همان‌طور که پیش‌تر بحث شد، یک شبکه عصبی مصنوعی با لایه مخفی منفرد، اگر تعداد گره‌های مخفی به دقت تعریف شود، می‌تواند به‌خوبی عمل پیش‌بینی را انجام دهد. هم‌چنین با توجه به تجربه بدست آمده پیشنهاد می‌شود که اندازه بهینه لایه مخفی معمولاً بین اندازه لایه‌های ورودی و خروجی انتخاب شود. برای این مطالعه، تعداد گره‌های مخفی حداکثر منطقی ۸ می‌باشد.

مدل‌های این تحقیق، پرسپترون چند لایه (MLP) پس‌انتشار خطا و NARX هر دو با یک لایه مخفی می‌باشند. به عنوان حساسیت مطالعه، تعداد گره‌های مخفی از ۱ تا ۸ انتخاب شده است. اضافه کردن گره‌های مخفی بیشتر از ۸ به نظر نمی‌رسد که به‌طرز قابل‌توجهی باعث بهبود شود. هم‌چنین هر دو شبکه دارای ساختاری هیبریدی با تابع فعال‌سازی تانژانت هایپربولیک برای لایه مخفی و یک تابع انتقال خطی در لایه خروجی می‌باشند. تابع هدف، میانگین مربعات خطا (MSE) است و روش بهینه-سازي انتخاب شده، الگوریتم لونیبرگ مارکوارت می‌باشد. این طراحی در جدول (۳-۲) خلاصه شده است.

با توجه به اینکه از پارامترهای هواشناسی مختلفی برای مدل‌سازی استفاده شد، ترکیب‌های گوناگونی از شبکه اجرا شد تا به بررسی تاثیر بهینه هر گروه پارامتر پرداخته شود.

<sup>1</sup> Cross-validation

<sup>2</sup> Hernandez et al

متغیرهای پیش بینی آب و هوای سرعت باد مدل GFS نرمال شده، به شبکه عصبی آموزش داده شده به عنوان پیش‌بینی‌کننده جهت ذخیره ارائه شد، که به شبکه عصبی مصنوعی اجازه پیش‌بینی سرعت باد مشاهداتی را می‌دهد. این فرآیند می‌تواند جهت اجرا به صورت خودکار نوشته شود. زمان محاسبه در صفحه کار کامپیوترهای مدرن و لپ‌تاپ‌ها تنها چند ثانیه است.

جدول (۲-۳) ویژگی‌های طراحی شبکه عصبی مصنوعی بهینه

۱	تعداد لایه های مخفی
۱-۶	تعداد گره های در لایه ورودی
۸	تعداد گره های در لایه مخفی
۱	تعداد گره ها در لایه خروجی
سیگموئیدی لگاریتمی	تابع فعال سازی در لایه مخفی
خطی	تابع فعال سازی در لایه خروجی
میانگین مربعات خطا	تابع هدف
لونبرگ مارکوارت	الگوریتم بهینه سازی
بگینگ	روش نمونه گیری داده ها



# فصل چہارم:

## نتائج

در این فصل به ارائه نتایج پیش‌بینی سرعت و جهت باد با استفاده از سه شبکه عصبی MLP، NARX، با نمونه‌گیری تصادفی و MLP با استفاده از نمونه‌گیری بگینگ و همچنین تشریح و ارزیابی نتایج پرداخته می‌شود. آنچه در ادامه فصل می‌آید عبارتند از: بررسی اطلاعات هواشناسی منطقه، داده‌های آماری مورد استفاده در اجرای شبکه، بررسی همبستگی و انتخاب همبسته‌ترین سلول از مدل GFS، انتخاب ترکیب‌های مختلفی از ورودی‌ها، پیش‌پردازش داده‌های ورودی و خروجی، پیش‌بینی سرعت و جهت باد با استفاده از سه شبکه عصبی بیان شده و ارائه نتایج حاصل از آن‌ها و ارزیابی هر مدل و در نهایت جمع‌بندی فصل جاری.

#### ۴-۲- انتخاب دوره آماری در اجرای شبکه

جهت پیش‌بینی سرعت و جهت باد در منطقه بندر ماهشهر از داده‌های آماری سرعت باد مدل GFS که از سازمان NCEP دریافت شد، جهت باد، دمای هوا، فشار اتمسفر، رطوبت نسبی و میزان بارش در ورودی و سرعت باد مشاهداتی به عنوان خروجی از اکتبر ۲۰۱۴ تا جولای ۲۰۱۶ استفاده شد. تمامی داده‌های مشاهداتی هواشناسی مربوط به ایستگاه سینوپتیک بندر ماهشهر از سازمان هواشناسی ایران، با بازه زمانی ۶ ساعته دریافت شد. شبکه پس از جمع‌آوری اطلاعات اولیه اجرا و ارزیابی شد. در تمامی شبکه‌ها برای نمونه از داده‌های ساعت صفر استفاده شد و نتایج باقی‌ساعت‌ها (۰۶:۰۰، ۱۲:۰۰ و ۱۸:۰۰) در پیوست الف ضمیمه شد.



### ۳-۴- تحلیل همبستگی جهت اجرای شبکه عصبی

با توجه به این موضوع که خروجی مدل‌های GFS در یک محدوده جغرافیایی و به صورت شبکه‌های ۰.۵ درجه در ۰.۵ درجه ارائه شده است، ابتدا باید همبستگی بین خروجی مدل GFS در زمان  $t-1$  و باد مشاهداتی در زمان  $t$ ، که در آن عدد ۱ یعنی یک روز (۲۴ ساعت)، بدست آید تا بتوان شبکه‌های عصبی مورد نظر در این تحقیق را توسعه داد. به همین منظور با استفاده از نرم افزار متلب و یک کد کوتاه همبستگی سلول‌ها در ساعت صفر در جدول (۴-۱) ارائه شد.


با توجه به این موضوع که مختصات جغرافیایی بندر ماهشهر  $30.5458^{\circ}$  شمالی و  $49.1803^{\circ}$  شرقی می‌باشد بیشترین همبستگی در مختصات  $30.5^{\circ}$  شمالی و  $49^{\circ}$  شرقی با مقدار  $0.686$  که نزدیک‌ترین ناحیه به منطقه مورد نظر است، بدست آمد. بنابراین از داده‌های سرعت باد مدل GFS در این سلول برای توسعه شبکه‌های عصبی مورد نظر استفاده شد.

جدول (۴-۱) مقادیر همبستگی در سلول‌های سرعت باد مدل GFS با سرعت باد مشاهداتی در ساعت صفر

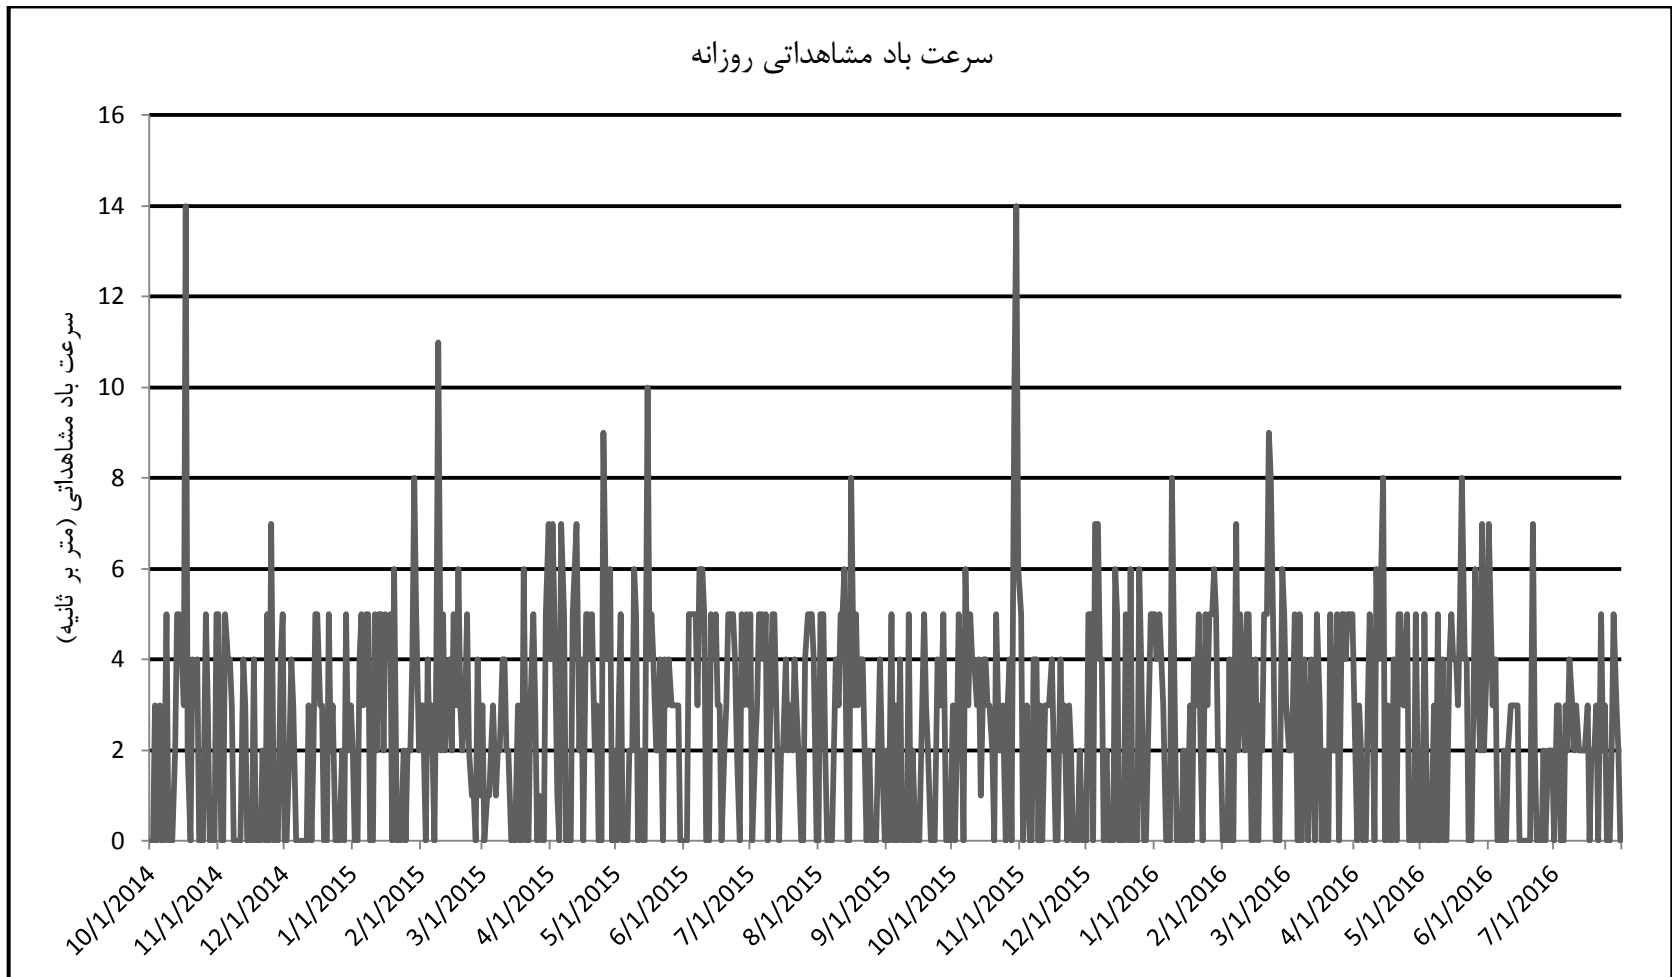
		Lon (°E)												
Lat (°N)	correlation	47.0	47.5	48.0	48.5	49.0	49.5	50.0	50.5	51.0	51.5	52.0	52.5	53.0
	<b>28.0</b>	0.192	0.284	0.350	0.369	0.387	0.374	0.335	0.279	0.213	0.136	0.093	0.049	0.078
	<b>28.5</b>	0.223	0.314	0.368	0.399	0.425	0.389	0.362	0.307	0.193	0.134	0.085	0.056	0.054
	<b>29.0</b>	0.269	0.321	0.383	0.422	0.428	0.390	0.344	0.272	0.244	0.142	0.062	0.042	0.054
	<b>29.5</b>	0.275	0.354	0.399	0.441	0.442	0.399	0.315	0.280	0.227	0.131	0.056	0.104	0.080
	<b>30.0</b>	0.316	0.376	0.413	0.463	0.455	0.432	0.315	0.234	0.104	0.046	0.080	-0.005	0.095
	<b>30.5</b>	0.341	0.380	0.401	0.435	<b>0.686</b>	0.560	0.302	0.130	0.077	0.020	0.150	0.084	0.126
	<b>31.0</b>	0.381	0.396	0.408	0.413	0.446	0.363	0.205	0.071	0.195	0.175	0.154	0.162	0.144

#### ۴-۴- بررسی اطلاعات هواشناسی منطقه


به منظور شناخت بیشتر منطقه مورد مطالعه، پیش از آغاز اجرای مراحل کار باید به یک دید کلی از منطقه دست یافت. بدین منظور ابتدا به بررسی پارامترهای خام هواشناسی مورد استفاده در دوره مورد نظر پرداخته شد. نمودارهای زیر الگوی تغییرات پارامترهای هواشناسی را در منطقه نشان می‌دهد. شکل (۴-۱) میانگین سرعت باد ماهانه در دوره ۱۰ ساله، که از سازمان هواشناسی ایران دریافت شد، در ایستگاه همدیدی بندر ماهشهر و روند تغییرات سرعت باد را در طی افزایش سال، که تغییراتی مداوم، مستمر و دارای تناوب تقریباً منظم است را نشان می‌دهد. در شکل‌های (۴-۲) تا (۴-۷) تغییرات پارامترهای هواشناسی و سرعت باد مدل GFS قابل مشاهده است.




شکل (۴-۱) میانگین ۱۰ ساله (۲۰۰۴-۲۰۱۳) سرعت باد ماهانه در ایستگاه هواشناسی مورد مطالعه




شکل (۴-۲) سرعت باد مشاهداتی روزانه در ساعت صفر در ایستگاه هواشناسی مورد مطالعه




شکل (۳-۴) سرعت باد مدل GFS، در همبسته ترین سلول، روزانه در ساعت صفر در منطقه مورد مطالعه



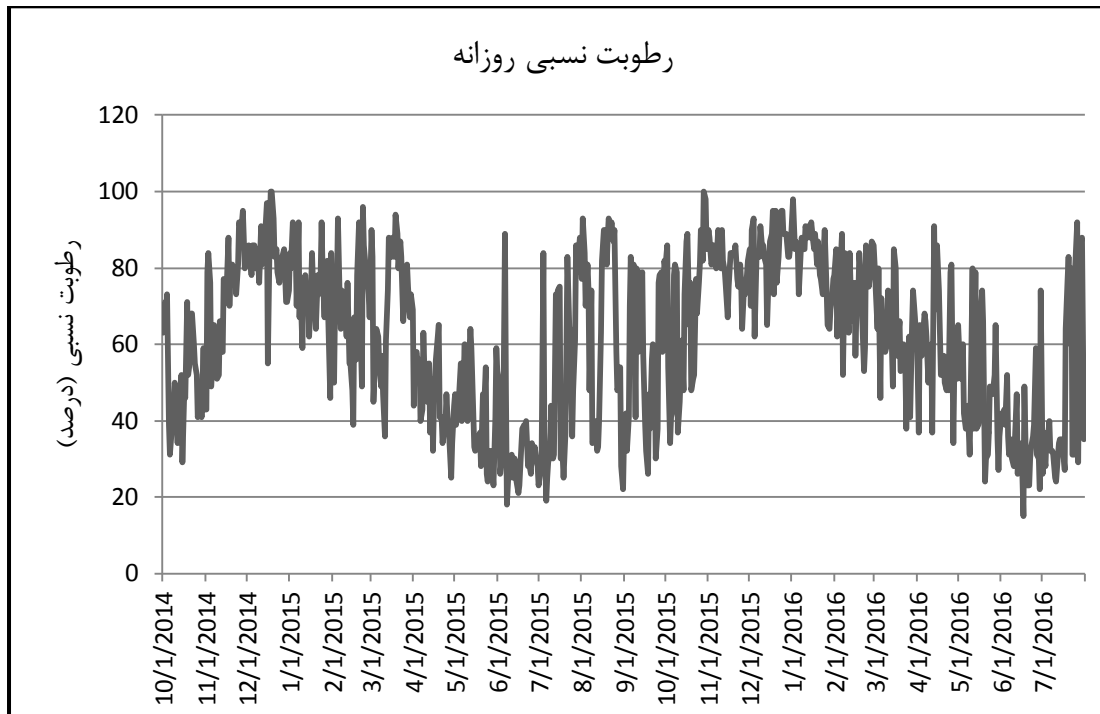
شکل (۴-۴) فشار هوای روزانه در ساعت صفر در ایستگاه هواشناسی مورد مطالعه



شکل (۴-۵) دمای هوا روزانه در ساعت صفر در ایستگاه هواشناسی مورد مطالعه



شکل (۴-۶) میزان بارش روزانه در ساعت صفر در ایستگاه هواشناسی مورد مطالعه




شکل (۴-۷) رطوبت نسبی روزانه در ساعت صفر در ایستگاه هواشناسی مورد مطالعه

شکل (۱-۴) تغییرات سینوسی سالانه سرعت باد را که احتمالاً به علت شرایط اقلیمی و ریخت شناسی زمین در منطقه مورد نظر می‌باشد را نشان می‌دهد. شکل (۲-۴) تغییرات سرعت باد واقعی ثبت شده در ایستگاه سینوپتیک مورد نظر در بازه زمانی تحت آزمایش را نشان می‌دهد و الگوی آن از حالت متناوب و سینوسی خارج شده است. در شکل (۳-۴) به طور تقریبی تناوب سینوسی سرعت باد استخراج شده از مدل GFS قابل مشاهده است. در توسعه شبکه از سرعت باد مدل GFS به عنوان ورودی شبکه استفاده شده است. فشار و دمای هوا که در شکل‌های (۴-۴) و (۵-۴) قابل مشاهده است دارای تناوب منظم در طول دوره مورد آزمایش است اما این تناوب منظم در بارش و رطوبت نسبی با توجه به نمودارهای شکل‌های (۶-۴) و (۷-۴) قابل مشاهده نیست. اقلیم منطقه گرم و مرطوب با الگوهای باد مشخص است. در حال حاضر تاثیر هر پارامتر نامعلوم است. در ادامه در مورد پارامترهای موثر بر سرعت باد بحث خواهد شد.


#### ۴-۵- پیش پردازش داده‌ها

باید در نظر داشته باشیم، که داده‌های ورودی از پارامترهای مختلف و دارای واحدهای اندازه‌گیری متفاوت هستند. الزامی است که داده‌های ورودی و خروجی با استفاده از کد نرمال‌سازی حداقل-حداکثر در متلب استاندارد شوند، تا توابع هدف پاسخ بهتری ارائه دهند. تمامی داده‌ها در محدوده ۰ تا ۱ استاندارد شدند به جز دما که در محدوده ۱- تا ۱ استاندارد شد و در پایان کار جهت بدست آوردن خروجی‌های واقعی پیش‌بینی سرعت باد، داده‌های نرمال شده از حالت استاندارد خارج شدند. سری زمانی داده‌های استاندارد شده سرعت باد مشاهداتی و سرعت باد مدل‌سازی شده به ترتیب در شکل‌های (۸-۴) و (۹-۴) ارائه شده است. با توجه به این نمودارها می‌توان دریافت که با استاندارد کردن سری زمانی، تناوب و تغییرات سرعت باد به‌طور واضح‌تری قابل مشاهده است.






شکل (۴-۸) سرعت باد مشاهداتی استاندارد شده روزانه در ساعت صفر در منطقه مورد نظر




شکل (۴-۹) سرعت باد مدل GFS استاندارد شده روزانه در ساعت صفر در منطقه مورد نظر

#### ۴-۶- پیش‌بینی سرعت باد با شبکه عصبی NARX

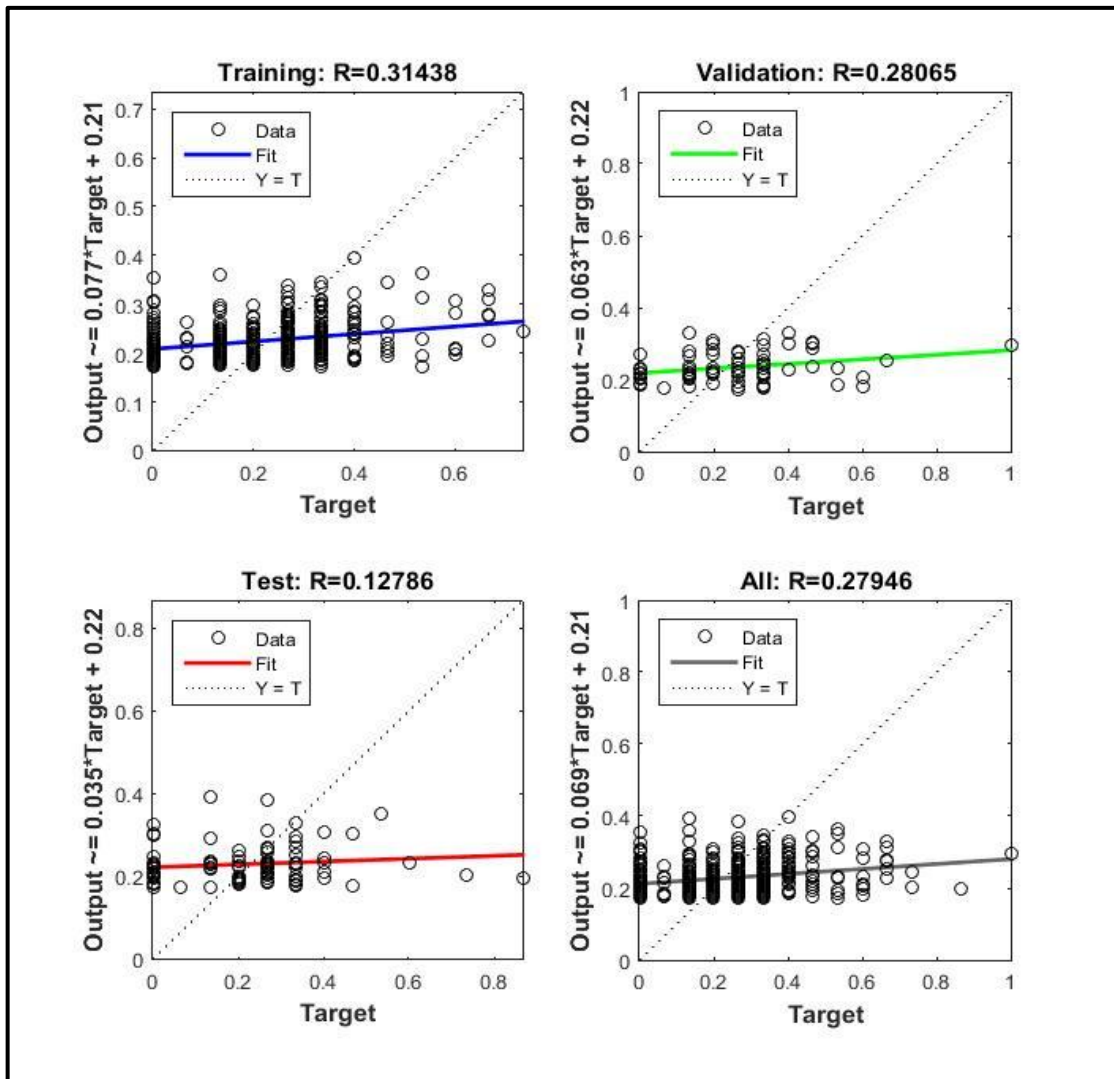
در این شبکه سرعت باد مدل GFS به عنوان ورودی و سرعت باد مشاهداتی از ایستگاه به عنوان خروجی، هر دو سری زمانی در زمان صفر و به صورت استاندارد شده، یک روز تاخیر، تابع فعال‌سازی سیگموئیدی منطقی در لایه مخفی و تابع فعال‌سازی خطی در لایه خروجی و زمان تاخیر یک در نظر گرفته شدند. جهت انتخاب تعداد نرون بهینه در لایه مخفی از ۱ تا ۱۰ نرون مورد آزمایش قرار گرفت و مشاهده شد که در نرون ۸ بهینه‌ترین پاسخ از شبکه حاصل شده است لذا ۸ نرون در لایه مخفی انتخاب شد. ساختار شبکه در شکل (۴-۱۰) و نتایج در شکل‌های (۴-۱۱) و (۴-۱۲) قابل مشاهده است.



شکل (۴-۱۰) ساختار شبکه NARX در پیش‌بینی سرعت باد در ساعت صفر



شکل (۴-۱۱) شاخص ارزیابی MSE شبکه NARX در پیش‌بینی سرعت باد در ساعت صفر



شکل (۴-۱۲) نمودارهای رگرسیون پیش‌بینی سرعت باد با شبکه NARX در ساعت صفر

#### ۴-۶-۱- ارزیابی نتایج

با توجه به نتایجی که در شکل‌های (۴-۱۱) و (۴-۱۲) ارائه شد، مشاهده شد که شبکه عصبی NARX با وجود تابع عملکردی نسبتاً خوب (MSE برابر با ۰.۰۲۶۰) نتایج خوبی در رگرسیون داده‌های آزمون، آموزش و اعتبارسنجی ارائه نکرد.

#### ۷-۴- پیش‌بینی سرعت باد با استفاده از شبکه عصبی پرسپترون چندلایه

در این بخش با استفاده از ترکیب‌های مختلف ورودی به بررسی نتایج پیش‌بینی سرعت باد در ساعت صفر پرداخته خواهد شد. انتخاب انواع مختلف ورودی به علت دستیابی به بهینه‌ترین حالت پیش‌بینی است. در این شبکه از ورودی‌ها و خروجی استاندارد شده، توابع فعال‌سازی سیگموئیدی در لایه مخفی و خطی در لایه خروجی استفاده شد. همان‌طور که در بخش قبل برای شبکه عصبی NARX انجام شد، در این بخش نیز جهت بدست آوردن تعداد نرون بهینه در شبکه عصبی مورد نظر از یک تا ۱۰ نرون به شبکه اعمال شد و شبکه با ۸ نرون بهترین پاسخ را ارائه کرد. پیش‌بینی‌ها با یک گام تاخیر برای روز بعد ارائه شد.

ترکیب‌های مختلف ورودی به صورت زیر انتخاب شد:

**الف- مدل M1:** سرعت باد مدل GFS

**ب- مدل M2:** سرعت باد مدل GFS و جهت باد

**ج- مدل M3:** سرعت باد مدل GFS، جهت باد و دمای هوا

**د- مدل M4:** سرعت باد مدل GFS، جهت باد، دمای باد و فشار هوا

**ه- مدل M5:** سرعت باد مدل GFS، جهت باد، دمای هوا، فشار هوا و رطوبت نسبی


**و- مدل M6:** سرعت باد مدل GFS، جهت باد، دمای هوا، فشار هوا، رطوبت نسبی و میزان بارش

نتایج پیش‌بینی سرعت باد در ساعت صفر با استفاده از شبکه عصبی MLP و ترکیب‌های فوق در جدول (۲-۴) ارائه شد. در جدول زیر به بررسی نتایج عملکردهای MSE، RMSE، و R پرداخته شد. در این شاخص‌ها در صورتی بهینه‌ترین پاسخ را ارائه می‌کنند که MSE و RMSE به صفر و R به یک میل کنند.

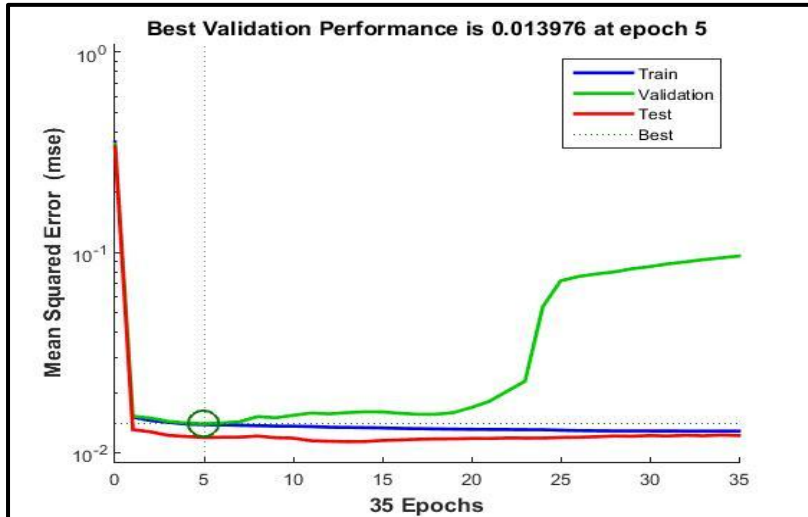
جدول (۲-۴) معیارهای ارزیابی پیش‌بینی سرعت باد در ساعت صفر با شبکه MLP

نام مدل	MSE استاندارد شده	RMSE	R		
			آزمون	آموزش	اعتبارسنجی
M1	۰.۰۹۹	۵.۱۶۴	۰.۳۹۷۰	۰.۳۶۷	۰.۲۹۹۱
M2	۰.۰۷۴	۴.۲۸۰	۰.۴۲۶۱	۰.۱۲۷۵	۰.۳۴۸
M3	۰.۰۳۲	۴.۰۵۹	۰.۴۰۰۴	۰.۳۸۰	۰.۴۳۲
M4	۰.۰۱۳۹	۳.۷۸۳	۰.۵۰۳۶	۰.۳۸۰	۰.۳۹
M5	۰.۴۸	۴.۱۵۰	۰.۴۴۹	۰.۳۰۶	۰.۳۳۳
M6	۰.۰۸۱	۴.۳۹۰	۰.۲۹۸۰	۰.۴۴۶۷	۰.۴۱۳۱

با توجه به نتایج ارائه شده در جدول فوق، مشاهده شد که مدل M4 شامل ورودی‌های سرعت باد مدل GFS، جهت باد، دمای هوا و فشار هوا تماماً به صورت استاندارد شده، بهترین پاسخ را ارائه کرده است. اما با این حال همچنان نتیجه قابل قبولی را به علت پایین بودن ضریب رگرسیون ارائه نکرد. در شکل‌های زیر نمودارهای حاصل از بهترین مدل قابل مشاهده است. شکل (۴-۱۳) ساختار شبکه را نشان می‌دهد و در شکل (۴-۱۴) شاخص عملکردی MSE و در شکل (۴-۱۵) رگرسیون در بخش‌های آموزش، آزمون و اعتبارسنجی ارائه شده است.

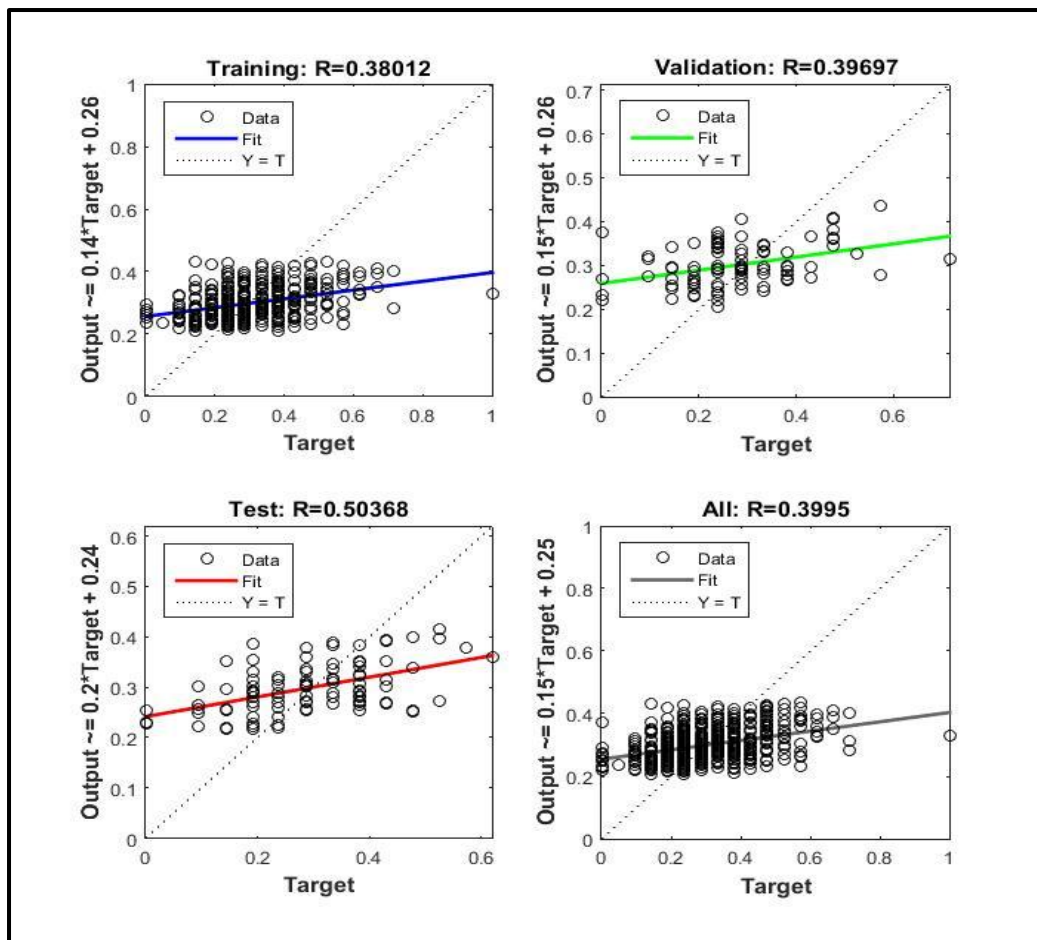


شکل (۴-۱۳) ساختار مدل M4 در شبکه MLP جهت پیش‌بینی سرعت باد یک گام بعد روزانه در ساعت



شکل (۴-۱۴) شاخص MSE در مدل M4 شبکه MLP جهت پیش‌بینی سرعت باد یک گام بعد در ساعت

صفر




شکل (۴-۱۵) نمودارهای رگرسیون مدل M4 شبکه MLP جهت پیش‌بینی سرعت باد یک گام بعد در

ساعت صفر

#### ۴-۷-۱- ارزیابی نتایج

همان‌طور که در شکل‌های فوق قابل مشاهده است، شبکه عصبی MLP مورد نظر، دارای میانگین مربعات خطای (MSE) خوبی است اما شاخص رگرسیون در آزمون، آموزش و اعتبار سنجی نامناسب است. در شکل (۴-۱۶) به مقایسه داده‌های مشاهده‌ای و داده‌های پیش‌بینی شده مدل که از حالت استاندارد خارج و به داده‌های واقعی تبدیل شدند، پرداخته شد.



شکل (۴-۱۶) نمودار سرعت باد مشاهده‌ای و پیش‌بینی شده توسط مدل M4 شبکه MLP در ساعت صفر

در شکل فوق مشاهده شده است که مدل پیش‌بینی شده توسط شبکه MLP برآوردی خوبی از داده‌های سرعت باد مشاهده‌ای واقعی ارائه نکردند. این امر نشان‌دهنده ناکارآمد بودن این شبکه می‌باشد.



#### ۸-۴- پیش‌بینی سرعت باد با استفاده از شبکه عصبی پرسپترون چندلایه با نمونه‌گیری

##### بگینگ


در این بخش نیز همانند بخش ۴-۶ به پیش‌بینی سرعت باد با استفاده از ترکیب‌های مختلف متغیرهای ورودی‌های سرعت باد مدل GFS، جهت باد، دمای هوا، فشار هوا، رطوبت نسبی و میزان بارش پرداخته خواهد شد. در این نوع شبکه از مدل نمونه‌گیری داده بگینگ که پیش‌تر به شرح آن پرداخته شد، استفاده شده است. در جدول (۳-۴) نتایج حاصل اجرای این شبکه در ترکیب‌های مختلف ارائه شده است.

جدول (۳-۴) معیارهای ارزیابی پیش‌بینی سرعت باد در ساعت صفر با شبکه MLP با بگینگ

نام مدل	MSE استاندارد شده	RMSE	R		
			آزمون	آموزش	اعتبارسنجی
M1	۰.۰۲۱۴	۲.۰۰۳۲	۰.۷۶۱۵	۰.۸۰۱۶	۰.۸۶۳۲
M2	۰.۰۱۵۶	۱.۶۹۸۱	۰.۹۰۳۸	۰.۹۰۵۴	۰.۹۰۰۹
M3	۰.۰۱۳۵	۱.۶۷۵۲	۰.۹۰۶۸	۰.۹۳۳۴	۰.۸۳۰۱
<b>M4</b>	<b>۰.۰۰۷۴</b>	<b>۱.۶۶۷۴</b>	<b>۰.۹۲۲۵</b>	<b>۰.۹۳۱۴</b>	<b>۰.۸۲۱۳</b>
M5	۰.۰۱۹۵	۱.۶۷۰۵	۰.۹۰۴۸	۰.۹۲۰۵	۰.۷۵۵۰
M6	۰.۰۲۲۹	۱.۶۸۹۱	۰.۸۹۴۸	۰.۹۵۴۷	۰.۹۳۹۶


با توجه به نتایج ارائه شده در جدول فوق، در این بخش نیز مشاهده شد که مدل M4، شامل ورودی‌های سرعت باد مدل GFS، جهت باد، دمای هوا و فشار هوا تماماً به صورت استاندارد شده بهترین پاسخ را ارائه کرد. نتایج همه شاخص‌های عملکردی بسیار خوب و بهینه بدست آمد که بیانگر این موضوع است که این نمونه‌گیری تاثیر بسیار خوبی در عملکرد شبکه عصبی مصنوعی دارد. در شکل‌های زیر نمودارهای حاصل از بهترین مدل نشان داده شده است. شکل (۴-۱۷) ساختار شبکه که

کاملاً مشابه بهترین شبکه‌ی مدل MLP بدون نمونه‌گیری بگینگ است را نشان می‌دهد. در شکل (۴-۴) -  
 (۱۸) شاخص عملکردی MSE و در شکل (۴-۱۹) رگرسیون در بخش‌های آزمون، آموزش و اعتبار-  
 سنجی ارائه شده است.



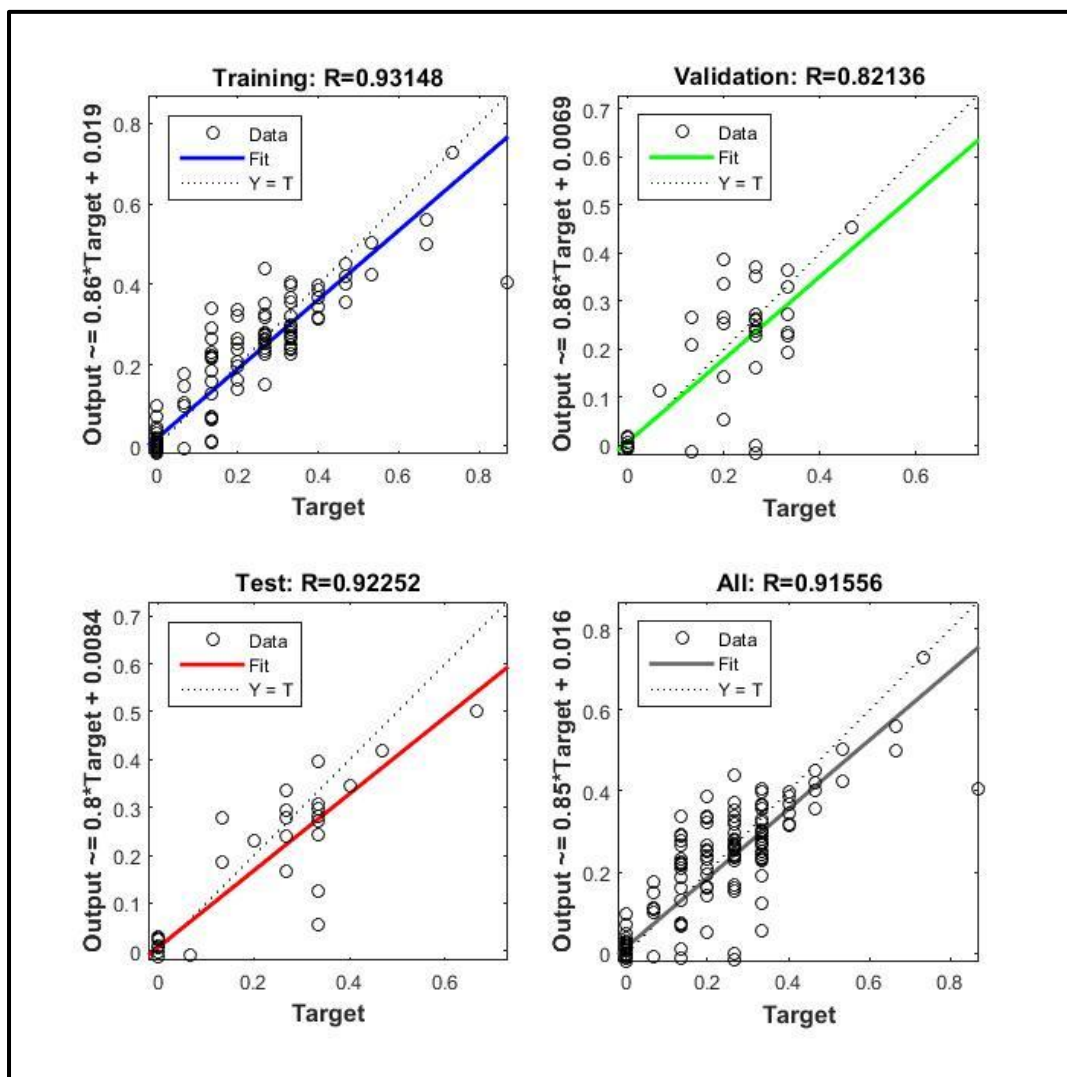
شکل (۴-۱۷) ساختار مدل M4 شبکه MLP با بگینگ جهت پیش‌بینی سرعت باد یک گام بعد در ساعت

صفر




شکل (۴-۱۸) شاخص MSE در مدل M4 شبکه MLP با بگینگ جهت پیش‌بینی سرعت باد یک گام بعد

در ساعت صفر

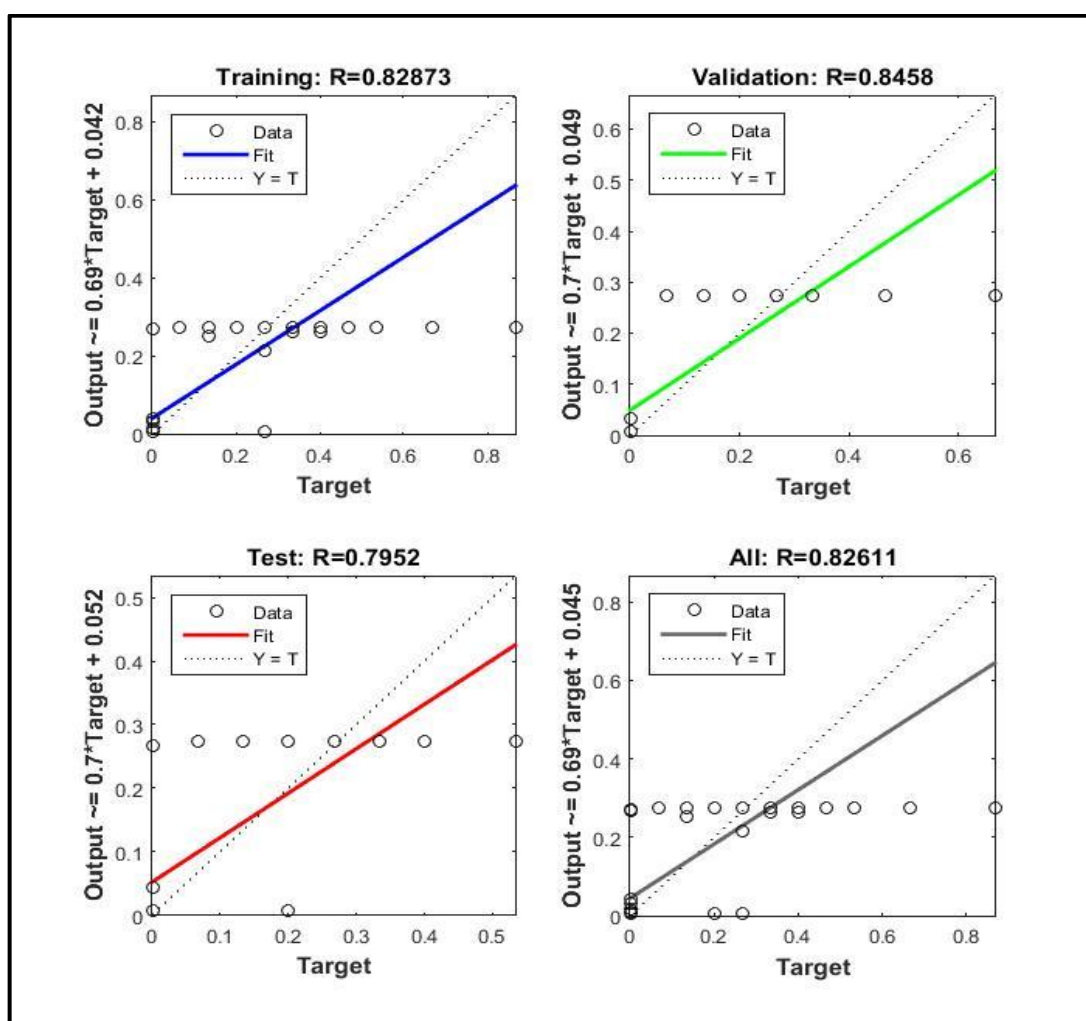


شکل (۴-۱۹) نمودارهای رگرسیون مدل M4 شبکه MLP با بگینگ در پیش‌بینی سرعت باد یک گام بعد ساعت صفر

طبق نتایج مشخص شد که بهترین ترکیب جهت دریافت پیش‌بینی بهینه، مدل M4 است، از این رو، به‌منظور مقایسه تاثیر تعداد نرون‌های لایه مخفی، از لایه مخفی با یک نرون نیز برای اجرای شبکه عصبی مصنوعی مورد نظر استفاده شد. نتایج این شبکه در شکل‌های (۴-۲۰) و (۴-۲۱) و جدول (۴-۴) قابل مشاهده است.



شکل (۴-۲۰) ساختار شبکه MLP با بگینگ و یک نرون در لایه مخفی در ساعت صفر



شکل (۴-۲۱) نمودارهای رگرسیون مدل M4 شبکه MLP با بگینگ و یک نرون لایه مخفی در پیش بینی

باد یک گام بعد ساعت صفر

جدول (۴-۴) معیارهای ارزیابی پیش‌بینی سرعت باد در ساعت صفر توسط شبکه MLP با بگینگ و یک


نرون مخفی

نام مدل	MSE استاندارد شده	RMSE	R		
			آزمون	آموزش	اعتبارسنجی
M4	۰.۰۰۷۴	۱.۸۳۹	۰.۷۹۵۲	۰.۸۲۸۷	۰.۸۴۵۸

همان‌طور که از نتایج دریافت می‌شود، پیش‌بینی با استفاده از چند نرون در لایه مخفی بسیار بهینه‌تر از یک گره با پیش‌بینی‌کننده‌های یکسان است.


۴-۸-۱- ارزیابی نتایج

با توجه به نتایج ارائه‌شده در شکل‌های فوق، شبکه عصبی مورد نظر دارای مقدار میانگین مربعات خطا (MSE) و شاخص رگرسیون در تمامی مجموعه داده‌های آزمون، آموزش و اعتبارسنجی بسیار مطلوب است که نشان می‌دهد مدل توسعه داده‌شده بهینه‌ترین حالت پیش‌بینی سرعت باد را ارائه کرد. در شکل (۴-۲۲) به مقایسه داده‌های مشاهداتی و داده‌های پیش‌بینی شده مدل که از حالت استاندارد خارج و به داده‌های واقعی تبدیل شدند و در شکل (۴-۲۳) به پراکندگی سرعت باد مشاهداتی و پیش‌بینی شده پرداخته شد. شکل (۴-۲۲) نمایانگر تقریب بسیار خوب از سرعت باد یک گام بعد با استفاده از داده‌های روزانه در ساعت صفر است.



شکل (۴-۲۲) سرعت باد مشاهده‌ای و پیش‌بینی شده توسط مدل M4 شبکه MLP با بگینگ در ساعت

صفر



شکل (۴-۲۳) پراکندگی داده‌های سرعت باد در ساعت صفر با شبکه MLP با بگینگ

#### ۹-۴- پیش‌بینی جهت باد

در این بخش، جهت باد با استفاده از سرعت باد مدل GFS و پارامترهای دیگر هواشناسی، توسط سه شبکه عصبی مصنوعی استفاده شده در بخش‌های پیش‌بینی سرعت مورد بررسی قرار گرفت. به‌منظور بررسی دقیق‌تر پیش‌بینی جهت باد، پیش‌بینی در دو بخش جهت باد افقی و عمودی با استفاده از مولفه‌های سرعت باد افقی و عمودی مدل GFS و دیگر پارامترهای هواشناسی به‌عنوان ورودی صورت گرفت.

در پیش‌بینی جهت باد همچون سرعت باد از ترکیب‌های مختلف ورودی‌ها استفاده شد و نتایج در ادامه ارائه شد. در زیر به معرفی ترکیب‌های مختلف ورودی در پیش‌بینی جهت باد پرداخته می‌شود:

الف - M1: سرعت باد مدل GFS

ب - M2: سرعت باد مدل GFS و دمای هوا

ج - M3: سرعت باد مدل GFS، دمای هوا و فشار هوا

د - M4: سرعت باد مدل GFS، دمای هوا، فشار هوا و رطوبت نسبی

ه - M5: سرعت باد مدل GFS، دمای هوا، فشار هوا، رطوبت نسبی و بارش

در تمامی شبکه‌های عصبی توسعه داده شده سرعت باد مدل GFS و پارامترهای دیگر هواشناسی به‌عنوان ورودی و جهت باد به‌عنوان خروجی در نظر گرفته شد. همچنین جهت انتخاب تعداد نرون‌های مخفی بهینه، در تمامی شبکه‌ها بهترین تعداد نرون در لایه مخفی با سعی و خطا، ۸ نرون بدست آمد. از این رو، تعداد نرون‌های مخفی در هر سه شبکه ۸ در نظر گرفته شد.

#### ۹-۴-۱- پیش‌بینی جهت باد افقی

پیش‌بینی جهت باد افقی با استفاده از ترکیب ورودی‌های مختلف مورد آزمایش قرار گرفت و باقی پارامترهای آموزش شبکه کاملاً مشابه پیش‌بینی سرعت باد انتخاب شد. در جداول (۴-۵)، (۴-۶) و (۴-۷) نتایج آموزش در شبکه‌های مختلف ارائه شد.

جدول (۴-۵) معیارهای ارزیابی پیش‌بینی جهت باد افقی با شبکه NARX در ساعت صفر

نام مدل	MSE استاندارد شده	RMSE	R		
			آزمون	آموزش	اعتبارسنجی
M1	۰.۱۴۷۵	۶.۲۳۱۲	۰.۲۳۰۱	۰.۲۴۵۷	۰.۴۴۸۵

با توجه به نتایج بدست آمده در جدول فوق، شبکه عصبی NARX برای پیش‌بینی جهت باد یک گام بعد عملکرد مطلوبی ارائه نکرده است. از این رو، ترکیب‌های دیگر ورودی در آن آموزش داده نشد.

جدول (۴-۶) معیارهای ارزیابی پیش‌بینی جهت باد افقی با شبکه MLP در ساعت صفر

نام مدل	MSE استاندارد شده	RMSE	R		
			آزمون	آموزش	اعتبارسنجی
M1	۰.۱۳۳۰	۴.۰۶۷۵	۰.۴۸۵۰	۰.۴۹۲۳	۰.۴۲۲۳
M2	۰.۱۱۲۲	۳.۴۵۵۶	۰.۵۸۹۱	۰.۴۳۶۵	۰.۵۴۱۵
M3	۰.۰۹۸۷۰	۲.۶۹۴۹	۰.۶۱۹۷	۰.۴۶۹۱	۰.۴۳۰۰
M4	۰.۱۱۴۵	۳.۸۹۵۷	۰.۴۲۰۰	۰.۵۱۴۰	۰.۶۱۰۷
M5	۰.۱۲۰۵	۴.۷۶۸۹	۰.۴۲۸۰	۰.۵۱۲۴	۰.۵۳۴۵

جدول (۴-۷) معیارهای ارزیابی پیش‌بینی جهت باد افقی با شبکه MLP با بگینگ در ساعت صفر

نام مدل	MSE استاندارد شده	RMSE	R		
			آزمون	آموزش	اعتبارسنجی
M1	۰.۲۱۰۰	۳.۱۸۵۶	۰.۶۹۸۵	۰.۶۵۱۱	۰.۶۶۵۵
M2	۰.۱۶۶۴	۲.۲۶۶۹	۰.۵۶۹۳	۰.۶۵۷۷	۰.۷۱۴۹
M3	۰.۱۳۱۵	۱.۷۵۸۸	۰.۸۰۴۹	۰.۷۲۰۹	۰.۷۴۱۵
M4	۰.۱۹۳۴	۲.۳۵۶۵	۰.۶۷۴۴	۰.۷۵۳۴	۰.۶۳۸۰
M5	۰.۱۷۳۶	۳.۴۲۶۱	۰.۶۳۷۲	۰.۶۶۸۴	۰.۶۶۸۷



در جدول (۴-۶) طبق نتایج پیش‌بینی با استفاده از شبکه عصبی مصنوعی MLP مشاهده شد، در پیش‌بینی جهت باد افقی همانند پیش‌بینی سرعت باد، بیشترین تاثیر را سرعت باد افقی مدل GFS، دمای هوا و فشار هوا (مدل M3) داشتند. در این مدل MSE، RMSE و R در مجموعه داده‌های آموزش به ترتیب ۰.۰۹۸۷۰، ۲.۶۹۴۹ و ۰.۶۱۹۷ بدست آمد.

در جدول (۴-۷) نتایج پیش‌بینی جهت باد افقی با استفاده از شبکه عصبی MLP با نمونه‌گیری بگینگ، همانند شبکه پیشین، در مدل M3 یعنی ترکیب ورودی سرعت باد افقی مدل GFS، دمای هوا و فشار هوا بهترین عملکرد خود را ارائه کرد. این شبکه عصبی مصنوعی در مقایسه با شبکه عصبی MLP ساده، بسیار بهینه عمل کرد. در مدل M3 بهینه، MSE، RMSE و R در مجموعه داده‌های آموزش به ترتیب ۰.۱۳۱۵، ۱.۷۵۸۸ و ۰.۸۰۴۹ بدست آمد.

#### ۴-۹-۲- پیش‌بینی جهت باد عمودی

پیش‌بینی جهت باد عمودی کاملاً مشابه پیش‌بینی جهت باد افقی است تنها با این تفاوت که از سرعت باد عمودی مدل GFS به جای سرعت باد افقی مدل GFS در ترکیب‌های ورودی استفاده شد. نتایج آموزش شبکه‌های مختلف در جدول‌های (۴-۸)، (۴-۹) و (۴-۱۰) ارائه شد.

جدول (۴-۸) معیارهای ارزیابی پیش‌بینی جهت باد عمودی با شبکه NARX در ساعت صفر

نام مدل	MSE استاندارد شده	RMSE	R		
			آزمون	آموزش	اعتبارسنجی
M1	۰.۱۳۰۸	۶.۸۷۶۰	۰.۱۷۷۸	۰.۲۷۳۹	۰.۲۶۹۳

جدول (۹-۴) معیارهای ارزیابی پیش‌بینی جهت باد عمودی با شبکه MLP در ساعت صفر

نام مدل	MSE استاندارد شده	RMSE	R		
			آزمون	آموزش	اعتبارسنجی
M1	۰.۱۳۰۶	۵.۰۲۹۴	۰.۳۷۸۸	۰.۴۵۸۵	۰.۴۱۴۴
M2	۰.۱۱۵۵	۴.۶۸۸۱	۰.۴۶۹۷	۰.۴۸۷۳	۰.۵۱۱۶
<b>M3</b>	<b>۰.۱۱۱۶</b>	<b>۳.۹۰۱۹</b>	<b>۰.۵۹۵۱</b>	<b>۰.۵۰۸۶</b>	<b>۰.۴۸۸۵</b>
M4	۰.۱۱۷۷	۴.۴۸۳۱	۰.۴۳۰۰	۰.۵۵۵۵	۰.۶۸۶۶
M5	۰.۱۲۹۸	۵.۵۱۱۹	۰.۳۵۷۷	۰.۵۳۳۶	۰.۵۰۰۵

جدول (۱۰-۴) معیارهای ارزیابی پیش‌بینی جهت باد عمودی توسط شبکه MLP با بگینگ در ساعت صفر

نام مدل	MSE استاندارد شده	RMSE	R		
			آزمون	آموزش	اعتبارسنجی
M1	۰.۱۹۹۵	۴.۰۰۱۷	۰.۴۱۳۷	۰.۵۷۴۵	۰.۵۶۳۹
M2	۰.۱۶۰۸	۳.۷۳۹۸	۰.۵۲۲۵	۰.۶۳۱۲	۰.۶۳۲۵
<b>M3</b>	<b>۰.۰۹۰۱</b>	<b>۲.۷۸۳۲</b>	<b>۰.۷۶۶۱</b>	<b>۰.۶۰۳۹</b>	<b>۰.۶۰۸۴</b>
M4	۰.۱۵۷۰	۳.۵۶۳۶	۰.۵۰۵۸	۰.۴۵۹۲	۰.۵۲۹۹
M5	۰.۱۳۱۶	۴.۵۴۵۶	۰.۴۶۲۷	۰.۵۰۶۴	۰.۵۶۶۴

شبکه عصبی NARX مانند موارد قبلی نتایج نامطلوبی ارائه کرد، از این رو از آموزش آن با ترکیب-های دیگر ورودی صرف نظر شد.

مدل M3 در شبکه‌های عصبی MLP ساده و با نمونه‌گیری بگینگ، مانند پیش‌بینی‌های پیشین بهترین نتایج را ارائه کرد، مقدار MSE، RMSE و R در مجموعه داده‌های آموزش در شبکه‌های عصبی MLP ساده و با نمونه‌گیری بگینگ به ترتیب ۰.۱۱۱۶، ۳.۹۰۱۹، ۰.۵۹۵۱ و ۰.۰۹۰۱، ۲.۷۸۳۲، ۰.۷۶۶۱ بدست آمد.

با توجه به نتایج جدول‌های فوق، شبکه عصبی مصنوعی MLP با نمونه‌گیری بگینگ بهترین عملکرد را در پیش‌بینی جهت باد عمودی در مدل M3 ارائه کرده است.

#### ۴-۱۰- جمع‌بندی

در این فصل به‌طور کلی شبکه‌های عصبی مصنوعی مختلف با ساختارهای متفاوت جهت پیش‌بینی سرعت و جهت باد در ساعت صفر بررسی شد و نتایج آن‌ها به صورت خلاصه در بخش‌های مختلف ارائه شد.

سه شبکه عصبی مصنوعی مورد استفاده قرار گرفت، شبکه عصبی NARX که معمولاً برای پیش‌بینی یک گام بعد سری‌های زمانی استفاده می‌شود، شبکه عصبی MLP ساده که تمامی داده‌ها را به صورت تصادفی و بدون نمونه‌گیری خاصی برآورد می‌کند و شبکه عصبی MLP پیشخور با نمونه‌گیری بگینگ که با توجه به نتایج ارائه شده در بخش‌های فوق بهترین عملکرد را بدست آورد. بنابراین بهتر است جهت پیش‌بینی سرعت و جهت باد یک گام بعد در منطقه بندر ماهشهر از این شبکه استفاده شود. همان‌طور که انتظار می‌رفت، اضافه کردن چندین پیش‌بینی کننده مرتبط و استفاده از ساختارهای پیچیده، عملکرد شبکه‌های عصبی مصنوعی را افزایش می‌دهد. به نظر می‌رسد که رطوبت نسبی و بارش پیش‌بینی‌کننده‌های مناسبی برای سرعت و جهت باد نباشند، زیرا RMSE به‌طور آهسته با اضافه کردن این دو پارامتر به لیست پیش‌بینی‌کننده‌ها کاهش یافت.

علاوه بر سرعت باد مدل GFS و جهت باد، استفاده از فشار و دمای هوا به‌عنوان پیش‌بینی کننده بهترین عملکرد شبکه عصبی مصنوعی را ارائه کردند.

نتایج ارائه شده در این فصل، در فصل آینده مورد بحث و نتیجه‌گیری قرار گرفته و در نهایت نتایج بدست آمده از تحقیق حاضر با فرضیه و اهداف تعیین شده مقایسه شده است.



## فصل پنجم

# نتیجه‌گیری و پیشنهادات

## ۵-۱- مقدمه

در این تحقیق، توانایی مدل‌های شبکه عصبی مصنوعی (ANN) در پیش‌بینی سرعت و جهت باد در منطقه بندر ماهشهر در جنوب غربی ایران مورد مطالعه قرار گرفت. سرعت و جهت باد با استفاده از سه شبکه عصبی مصنوعی مجزا، یعنی شبکه عصبی NARX، شبکه عصبی MLP و شبکه عصبی MLP پیشخور با نمونه‌گیری بگینگ تولید شد و نتایج تمامی آن‌ها مقایسه شد. پس از اخذ نتایج در فصل قبل، در این فصل نتایج حاصل در قسمت‌های مختلف، با توجه به اهداف و فرضیه‌های در نظر گرفته شده، مورد بحث و بررسی قرار گرفته است و در ادامه آن پیشنهادهایی به منظور کمک به پژوهش‌های آینده ذکر شده است.

## ۵-۲- نتیجه‌گیری

شبکه عصبی مصنوعی بهینه یک شبکه سه لایه پیشخور پس انتشار است تا پیش‌بینی یک گام بعد را تولید کند. این تحقیق با استفاده از معرفی پارامترهای هواشناسی مختلف از جمله فشار هوا، دمای هوا، رطوبت نسبی و میزان بارش به‌عنوان عوامل موثر در سرعت باد به پیش‌بینی‌های دقیق‌تری دست یافت.

روش شبکه عصبی مصنوعی MLP پیشخور با نمونه‌گیری بگینگ به طرز قابل توجهی پیش‌بینی یک گام بعد را بهبود بخشید. بررسی نتایج این تحقیق به چند بخش زیر تقسیم می‌شود:

الف: ارزیابی بهترین نوع شبکه عصبی مصنوعی

ب: ارزیابی ترکیب‌های مختلف ورودی‌ها در شبکه عصبی بهینه

ج: ارزیابی تعداد نرون‌های لایه مخفی در لایه مخفی در شبکه عصبی بهینه

د: ارزیابی پیش‌بینی جهت‌های عمودی و افقی باد

ه: مقایسه عملکرد شبکه بهینه در پیش‌بینی‌های سرعت و جهت باد

## ۵-۲-۱- ارزیابی بهترین نوع شبکه عصبی مصنوعی

در فصل قبل، از سه نوع شبکه عصبی در این پایان نامه استفاده شد. شبکه‌های عصبی عبارتند از شبکه عصبی مصنوعی NARX، شبکه عصبی مصنوعی MLP پیشخور ساده و شبکه عصبی مصنوعی MLP پیشخور با نمونه‌گیری بگینگ.

طبق نتایج بدست آمده، مشاهده شد که شبکه عصبی مصنوعی NARX با توجه به این موضوع که طبق مطالعات پیشین شبکه‌ای معمول در پیش‌بینی یک گام بعد سری زمانی است، عملکرد بسیار نامطلوبی ارائه کرده است. این ممکن است به دلیل تناوب بیش از حد باد و ماهیت تصادفی آن باشد. شبکه عصبی مصنوعی MLP پیشخور ساده برای پیش‌بینی یک گام بعد در شاخص عملکردی MSE نتایجی نسبتاً خوب ارائه کرد، ولی با در نظر گرفتن شاخص دیگر، یعنی رگرسیون، این‌طور نتیجه شد که این شبکه نیز عملکرد نسبتاً نامطلوبی دارد. در نهایت به ارزیابی شبکه عصبی مصنوعی MLP پیشخور با نمونه‌گیری بگینگ پرداخته شد. این شبکه عصبی مصنوعی، بهینه‌ترین شبکه برای پیش‌بینی سرعت باد با استفاده از سرعت باد استخراج شده از مدل GFS است. همان‌طور که در فصل قبل مشاهده شد، شاخص‌های عملکردی آن یعنی MSE و RMSE بسیار بهتر از شبکه‌های پیشین و علاوه بر آن رگرسیون آن در تمامی مجموعه داده‌های آزمون، آزمایش و اعتبارسنجی بسیار مطلوب بدست آمدند. بنابراین شبکه عصبی مصنوعی MLP پیشخور با نمونه‌گیری بگینگ بهترین حالت شبکه عصبی مصنوعی جهت پیش‌بینی باد در منطقه بندر ماهشهر می‌باشد.

## ۵-۲-۲- ارزیابی ترکیب‌های مختلف پارامترهای ورودی در شبکه عصبی مصنوعی بهینه

با توجه به این مسئله که شبکه عصبی مصنوعی MLP پیشخور با نمونه‌گیری بگینگ بهینه‌ترین شبکه عصبی مصنوعی شناخته شد، ترکیب‌های مختلف از ورودی در این شبکه مورد آزمایش قرار گرفت. نتایج نشان داد که شبکه عصبی مورد نظر تنها با ورودی سرعت باد مدل GFS جواب نسبتاً خوبی ارائه نکرد. با اضافه کردن پارامترهای مختلف، بهبودی تدریجی در عملکرد شبکه ایجاد شد. با در نظر

گرفتن نتایج مشاهده شد که با استفاده از پارامترهای جهت باد، فشار هوا و دمای هوا بهبود قابل ملاحظه‌ای در شبکه ایجاد شد، که نشان دهنده ارتباط خوب بین این پارامترها با سرعت باد است و استفاده از پارامترهای رطوبت نسبی و میزان بارش به طور تدریجی عملکرد شبکه را کاهش داده است که نشان دهنده این امر است که این عوامل پیشرفت مثبتی در پیش‌بینی سرعت باد بوجود نمی‌آورند. بنابراین بهترین عوامل موثر بر پیش‌بینی سرعت باد طبق مدل M4 یعنی سرعت باد استخراج شده از مدل GFS، جهت باد، فشار هوا و دمای هوا می‌باشند.

### ۵-۲-۳- ارزیابی تعداد نرون‌های لایه مخفی در لایه مخفی در شبکه عصبی بهینه

با توجه به این مسئله که بهترین شبکه، شبکه عصبی مصنوعی MLP پیشخور با نمونه‌گیری بگینگ می‌باشد، به تعداد نرون‌های متفاوت در لایه مخفی جهت بررسی عملکرد شبکه پرداخته شد. در بهترین حالت شبکه عصبی یعنی مدل M4 ابتدا ساده‌ترین شبکه یعنی با یک نرون در لایه مخفی اجرا شد و تعداد نرون‌ها افزایش یافت تا بهترین حالت یعنی ۸ نرون در لایه مخفی بدست آمد و از آن پس هرچه تعداد نرون‌ها در لایه مخفی اضافه شد نتیجه عملکرد مدل به تدریج کاهش یافت. همان‌طور که قابل مشاهده است با افزایش تعداد نرون‌های لایه مخفی شبکه عصبی مصنوعی مورد نظر بهبود یافت. از آنجاییکه در فصل‌های پیشین مورد بحث قرار گرفت افزایش تعداد گره‌های لایه مخفی به فراتر از ۸ باعث ایجاد بهبود قابل توجهی در نتایج شبکه عصبی مصنوعی نشده است و باعث ایجاد خطا در برازش می‌شود.

### ۵-۲-۴- ارزیابی پیش‌بینی جهت‌های باد عمودی و افقی

طبق نتایجی که در بخش‌های ۴-۷ در رابطه با پیش‌بینی جهت‌های باد افقی و عمودی ارائه شد، در هر دو پیش‌بینی مورد نظر بهترین شبکه اعمال شده، شبکه عصبی مصنوعی MLP با نمونه‌گیری بگینگ و موثرترین پارامترها، پارامترهای سرعت باد استخراج شده از مدل GFS، فشار هوا و دمای هوا بوده‌اند. از این رو، این برداشت حاصل شد که شبکه عصبی MLP با نمونه‌گیری بگینگ همانند پیش-



بینی سرعت باد، به منظور پیش‌بینی جهت‌های باد نیز عملکرد مناسبی دارد. فشار هوا و دمای هوا در پیش‌بینی‌های جهت باد نیز بیشترین تاثیر را در بهبود معیارهای ارزیابی شبکه داشتند.

### ۵-۲-۵- مقایسه عملکرد شبکه بهینه در پیش‌بینی‌های سرعت و جهت باد

در نهایت، با در نظر داشتن این موضوع که شبکه عصبی مصنوعی MLP با نمونه‌گیری بگینگ عملکرد برتری نسبت به شبکه‌های عصبی دیگر در پیش‌بینی سرعت و جهت باد دارد و همچنین با توجه به نتایج حاصل در بخش‌های پیشین، این امر به طور واضح نشان داده شد که عملکرد شبکه عصبی بهینه در پیش‌بینی سرعت باد بسیار بهتر از پیش‌بینی جهت‌های باد است. این موضوع نشانگر این مساله است که با وجود دقت بالای شبکه عصبی مورد نظر سرعت باد قابلیت پیش‌بینی بالاتری نسبت به جهت باد دارد.

### ۵-۳- پیشنهادات

با توجه به بررسی‌های صورت گرفته پیشنهادات زیر جهت بهبود پیش‌بینی سرعت و جهت باد با استفاده از شبکه عصبی مصنوعی و استفاد از این مدل ارائه شده است:

۱. پیشنهاد می‌شود از خروجی سایر مدل‌های عددی مانند مدل ECMWF نیز به عنوان ورودی

برای آموزش شبکه عصبی مصنوعی استفاده شود.

۲. روش شبکه عصبی مصنوعی بهینه پیشنهاد شده برای پیش‌بینی سرعت باد ۲ تا ۷ روز بعد

نیز اجرا شود. برای انجام این کار، مدل باید توسط مجموعه داده‌های مناسب دوباره آموزش

داده شود، یعنی پیش‌بینی‌های مدل GFS ۲ تا ۷ روز بعد.

۳. می‌توان این شبکه عصبی بهینه را جهت پیش‌بینی‌های روزانه با استفاده از داده‌های ۶ ساعته

توسعه داد.

۴. پیشنهاد می‌شود از مدل بهینه شبکه عصبی مصنوعی ارائه شده در این تحقیق، جهت پیش-بینی رفتارهای باد در مناطق دیگر نیز با استفاده از داده‌های پیشین و داده‌های مدل GFS صورت گیرد.
۵. در این مدل می‌توان توابع هدف مختلف را جهت دستیابی به نتیجه بهتر آزمایش کرد.
۶. پیشنهاد می‌شود از مدل شبکه عصبی مصنوعی MLP پیشخور با نمونه‌گیری بکینگ جهت پیش‌بینی انرژی باد در مزارع و نیروگاه‌های بادی در یک گام بعد استفاده کرد.

# منابع

۱. افخمی، ح.، طالبی، ع.، محمدی، م. و فتوحی، ف. (۱۳۹۴) "بررسی امکان پیش‌بینی سرعت باد با استفاده از مدل‌های هیبرید شبکه‌های عصبی، شبکه‌های فازی-عصبی و تئوری موجک (مطالعه موردی: ایستگاه سینوپتیک یزد)" نشریه علمی- پژوهشی علوم و مهندسی آبخیزداری ایران، سال نهم، شماره ۳۰.
۲. بختیاری ب.، قهرمان ن. و رحیمی ا. (۱۳۹۱) "استفاده از رویکرد شبکه عصبی مصنوعی جهت پیش‌بینی کوتاه‌مدت سرعت باد (مطالعه موردی: ایستگاه هواشناسی جیرفت)" مجله تحقیقات آب و خاک ایران، شماره ۱، دوره ۴۴، ص ۲۰-۱۱.
۳. سازمان انرژی‌های تجدیدپذیر و بهره‌وری انرژی برق (ساتبا). (۱۳۹۵).
۴. سازمان هواشناسی ایران (IRIMO). (۱۳۹۵).
۵. قاسمی، ا. و سیدی، ف.ا. (۱۳۹۴) "شبیه‌سازی تغییرات و پیش‌بینی سرعت باد در ایران با استفاده از داده‌های آماری پنجاه ساله (۲۰۱۰-۱۹۶۱)" فصلنامه علمی- پژوهشی اطلاعات جغرافیایی، شماره ۹۴، دوره ۲۴.
۶. منہاج، م. (۱۳۷۹) "مبانی شبکه‌های عصبی" نشر دانشگاه صنعتی امیرکبیر، تهران، ۷۱۵ صفحه.

7. Akcay, H. and Filik, T. (2017) "Short-term wind speed forecasting by spectral analysis from long-term observations with missing values" *Applied Energy*, 191, pp 653-662.
8. Akinci, T.C. (2011) "Short Term Wind Speed Forecasting with ANN in Batman, Turkey" *J. of. Electronics and Electrical Engineering*, 107, 1, pp 41-45.
9. Aladag, C.H., Egrioglu, E. and Kadilar, C. (2009) "Forecasting nonlinear time series with a hybrid methodology" *Applied Mathematics Letters*, 22, pp. 1467-1470.
10. Alexandersson, H., Tuomenvirta, H., Schmith, T. and Iden, K. (2000) "Trends of storms in NW Europe derived from an updated pressure data set" *Climate research Clim Res* 14, 1, pp 71-73.

11. Al-Shayea, Q.K. (2011) "Artificial Neural Networks in Medical Diagnosis" *International Journal of Computer Science Issues*, 8, 2, pp 150-154.
12. Azad, H.B., Mekhilef, S. and Ganapathy, V.G. (2014) "Long-Term Wind Speed Forecasting and General Pattern Recognition Using Neural Networks" *IEEE Transactions on Sustainable Energy*, 5, 2, pp 546-553.
13. Basheer, I.A. and Hajmeer, M. (2000) "Artificial neural networks: fundamentals, computing, design, and application" *Journal of Microbiological Methods*, 43, pp 3-31.
14. Breiman, L. (1994) "Bagging predictors", Technical Report No. 421, Department of Statistics, University of California. Berkeley, USA.
15. Burton T. (2003) "Wind Energy Handbook" First Edition, UK, Garrad Hassan and Partners.
16. Cadenas, E., Rivera, W., Campos-Amezcuca, R. and Cadenas, R. (2016 a) "Wind speed forecasting using the NARX model, case: La Mata, Oaxaca, México" *J. of. Neural Computing and Applications*, 27, 8, pp 2417-2428.
17. Cadenas, E., Rivera, W., Campos-Amezcuca, R. and Heard, C. (2016 b) "Wind Speed Prediction Using a Univariate ARIMA Model and a Multivariate NARX Model" *J. of. Energies*, 9, 2, 109.
18. Chen, N., Qian, Z., Nabney, I.T. and Meng, X. (2014) "Wind Power Forecasts Using Gaussian Processes and Numerical Weather Prediction" *IEEE Transactions on Power Systems*, 29, 2, pp 656-665.
19. Chuan, C.S. (1997) "Weather prediction using artificial neural network" *Journal of Hydrology*, 230, pp 101–119.
20. Dalto, M., Matusko, J. and Vasak, M. (2015) "Deep neural networks for ultra-short-term wind forecasting" 2015 IEEE International Conference on Industrial Technology (ICIT).
21. Damousis, I.G. and Dokopoulos, P.A. (2001) "fuzzy expert system for the forecasting of wind speed and power generation in wind farms" In Proceedings of the IE IEEE International Conference on Power Industry Computer Applications PICA 01, pp 63–69.
22. Fan S., Liao J.R., Yokoyama R., Chen L. and Lee W. (2009) "Forecasting the Wind Generation Using a Two-Stage Network Based on Meteorological Information" *IEEE Transactions on Energy Conversion*, 24, 2, pp 474.

23. Fazelpour, F., Tarashkar, N. and Rosen, M.A. (2016) "Short-term wind speed forecasting using artificial neural networks for Tehran, Iran" *Int J Energy Environ Eng.*, 7, 4, pp 377.
24. Ferrari, S. and Stengel, R. (2005) "Smooth Function Approximation Using Neural Networks", *IEEE Transactions on Neural Networks*, 16, pp 24-38.
25. Filik, U.B. and Filik, T. (2017) "Wind Speed Prediction Using Artificial Neural Networks Based on Multiple Local Measurements in Eskisehir" *J. of Energy Procedia*, 107, 264-269.
26. Finamore, A.R., Calderaro, V. and Galdi, V. (2016) "A wind speed forecasting model based on artificial neural network and meteorological data" *2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC)*.
27. Francis, L. (1999) "Neural networks demystified" Salford Systems' Course on Advanced CART, San Diego, USA.
28. Ghorbani, M.A., Khatibi, R., Hosseini, B. and Bilgili, M. (2013) "Relative importance of parameters affecting wind speed prediction using artificial neural networks" *Journal of Theoretical and Applied Climatology*, 114, 1-2, pp 107-114.
29. Guangdian, G.W. and Zhijie, D. (1994) "Wind pattern recognition in neural fuzzy wind turbine control system" *The Industrial Fuzzy and Intelligent Systems Conference and the NASA Joint Technology*, 5, 381.
30. Guo, Z., Wu, J., Lu, H. and Wang, J. (2011) "A case study on a hybrid wind speed forecasting method using BP neural network" *J. of Knowledge-Based Systems*, 24, pp. 1048-1056.
31. Hassoun, M.H. (1995), "Fundamentals of Artificial Neural Networks" Cambridge, The MIT press.
32. Hernandez, M., Zaribafiyani, A., Aramon M. and Naghibi, M. (2016) "A novel graph-based approach for determining molecular similarity" *IQBit. Vancouver, Canada*.
33. Hsieh W. (2009) "Machine learning methods in the environmental sciences neural networks and kernels", Cambridge University Press.

34. IPCC, (2013). Climate Change: The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press, Cambridge, 1-18.
35. Jennings, P. (2009) "New directions in renewable energy education" *Renew. Energy* 34, pp 435–439.
36. Kaplan, O. and Temiz, M. (2017) "A novel method based on Weibull distribution for short-term wind speed prediction" *International Journal of Hydrogen Energy*, 42, 28, pp. 17793-17800.
37. Kaur, T., Kumar, S. and Segal, R. (2016) "Application of artificial neural network for short term wind speed forecasting" 2016 Biennial International Conference on Power and Energy Systems: Towards Sustainable Energy (PESTSE).
38. Kim, Y.K., Seo, J. W. & Jeong, H. E. 2007. Sensitivity experiments for winds prediction with planetary boundary layer parameterization. *Jcomm Scientific and Technical Symposium on Storm Surges*, October 2 - 6, Seoul, Korea.
39. Kröse, B. and Smagt, P. (1993) "An Introduction to Artificial Neural Networks", 8th Ed, Amsterdam, University of Amsterdam.
40. Lange. M., (2003), Phd. thesis, "Analysis of the uncertainty of wind power predictions", University of Oldenburg: Department of Mathematics and Natural Sciences.
41. Liu, D., Niu, D., Wang, H. and Fan L. (2013) "Short-term wind speed forecasting using wavelet transform and support vector machines optimized by genetic algorithm" *J. of. Renewable Energy*, 62, pp 592-597.
42. Ma, X., Jin, Y. and Dong, Q. (2017) "A generalized dynamic fuzzy neural network based on singular spectrum analysis optimized by brain storm optimization for short-term wind speed forecasting" *J. of. Applied Soft Computing*, 54, pp 296-312.
43. Manzano-Agugliaro, F., Alcayde, A., Montoya, F.G., Zapata-Sierra, A. and Gil, C. (2013) "Scientific production of renewable energies worldwide: an overview" *Renew. Sustain. Energy Rev.* 18, 134-143.
44. More, A. and Deo, M.C. (2003) "Forecasting wind with neural networks" *Marine Structures*, 16, pp 35-49.

45. Moustiris, K.P., Zafirakis, D., Alamo, D.H., Nebot Medina, R.J. and Kaldellis, J.K. (2017) "24-h Ahead Wind Speed Prediction for the Optimum Operation of Hybrid Power Stations with the Use of Artificial Neural Networks" *Perspectives on Atmospheric Sciences*, pp 409-414.
46. Nagendra, S.M and Khare, M. (2006) "Artificial neural network approach for modeling nitrogen dioxide dispersion from vehicular exhaust emissions" *Ecological Modelling*, 190, pp 99-115.
47. Nayak, S.C., Misra, B.B. and Behera, H.S. (2014) "Impact of data normalization on stock index forecasting" *International Journal of Computer Information Systems and Industrial Managements Applications*, 6, pp 257-269.
48. Negnevitsky, M. and Potter, C.W. (2006) "Innovative short-term wind generation prediction techniques" *Power Systems Conference and Exposition, PSCE'06, IEEE PES*, pp 60-65.
49. Nguyen, D. and Widrow, B. (1990) "Improving the Learning Speed of 2-layer Neural Networks by Choosing Initial Values of the Adaptive Weights" *Proceedings of International Joint Conference on Neural Networks (IJCNN)*, San Diego, California.
50. Nogay, H.S., Akinci, T.C. and Eidukeviciute, M. (2012) "Application of artificial neural networks for short term wind speed forecasting in Mardin, Turkey" *J. of. Energy in Southern Africa*, 23, 4, pp 2-7.
51. Olaofe, Z.O. (2014) "A 5-day wind speed & power forecasts using a layer recurrent neural network (LRNN)" *J. of. Sustainable Energy Technologies and Assessments*, 6, pp 1-24.
52. Panteri, E. and Papathanassiou, S. (2008) "Evaluation of two simple wind power forecasting models" *European Wind Energy Conference*, Brussels, Belgium.
53. Potter, C.W. and Negnevitsky, M. (2006) "Very short-term wind forecasting for Tasmanian power generation" *IEEE Transaction on power systems*, 21, 2, pp 965-972.
54. Ramasamy, P., Chandel, S.S. and Yadav, A.K. (2015) "Wind speed prediction in the mountainous region of India using an artificial neural network model" *J. of. Renewable Energy*, 80, pp 338-347.



55. Ren, C., An, N., Wang, J., Li, L., Hu, B. and Shang, D. (2014) "Optimal parameters selection for BP neural network based on particle swarm optimization: A case study of wind speed forecasting" J. of. Knowledge-Based Systems, 56, pp 226-239.
56. Sawale, G.J. and Gupta, S.R. (2013) "Use of Artificial Neural Network in Data Mining For Weather Forecasting" International Journal of Computer Science And Application, 6, 2.
57. Sheela, K.G. and Deepa, S.N. (2013) "Neuralnetworkbasedhybridcomputingmodelfor wind speed prediction" J. of. Neurocomputing, 122, pp. 425-429.
58. Shukur, O.B. and Lee, M.H. (2014) "Daily wind speed forecasting through hybrid KF-ANN model based on ARIMA" J. of. Renewable Energy, 76, pp 637-647
59. Skidmore, E.L. (1987) "Wind-erosion Direction Factors as Influenced by Field Shape and Wind Preponderance" J. of. Soil Science Society of America, 51, 1, pp 198-202.
60. Svensson, M. (2015), Master's thesis, "Short-term wind-power forecasting using artificial neural networks", School of Computer Science and Communication, Royal Institute of Technology KTH. Stockholm, Sweden.
61. Tagliaferri, F., Viola, I.M. and Flay, R.G.J. (2015) "Wind direction forecasting with artificial neural networks and support vector machines" J. of. Ocean Engineering, 97, pp 65-73.
62. Tang, Z. and Fishwick, P.A. (1993) "Feed-forward neural nets as models for time series forecasting" ORSA Journal on computing, 5 , 4, pp 374-385.
63. Tsai, T.H. and Lee, C.K. (2005) "Design of Dynamic Neural Networks to Forecast Shortterm Railway Passenger Demand" Journal of the Eastern Asia Society for Transportation Studies, 6, pp 1651-1666.
64. Tu, J.V. (1996) "Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes" J Clin Epidemiol, 49, 11, pp 1225-1231. Boston, USA.
65. Wang, Z. and Bovik, A.C. (2009) "Mean square error: Love it or leave it?" Signal Processing Magazine, pp 99-117.

66. Watson, S.J., Landberg, L. and Halliday, J.A. (1994) "Application of wind speed forecasting to the integration of wind energy in to a large scale power system" IEE Proceedings of Generation, Transmission and Distribution, 141, 4, pp 357-362.
67. Yadav, A. and Sahu, K. (2017) "Wind forecasting using artificial neural networks: A survey and taxonomy" International Journal of Research In Science & Engineering, 3, 2, pp 148-155.
68. Young, I.R., Zieger, S. and Babanin, A.V. (2011) "Global Trends in Wind Speed and Wave Height" J. of. Science, 332, pp 451.
69. Zhang, G., Patuwo, B.E. and Hu, M.Y. (1998) "Forecasting with artificial neural networks: The state of the art" International Journal of Forecasting, 14, pp. 35-62.

پیوست

## پیوست الف

### نتایج کامل پیش‌بینی‌های سرعت و جهت باد

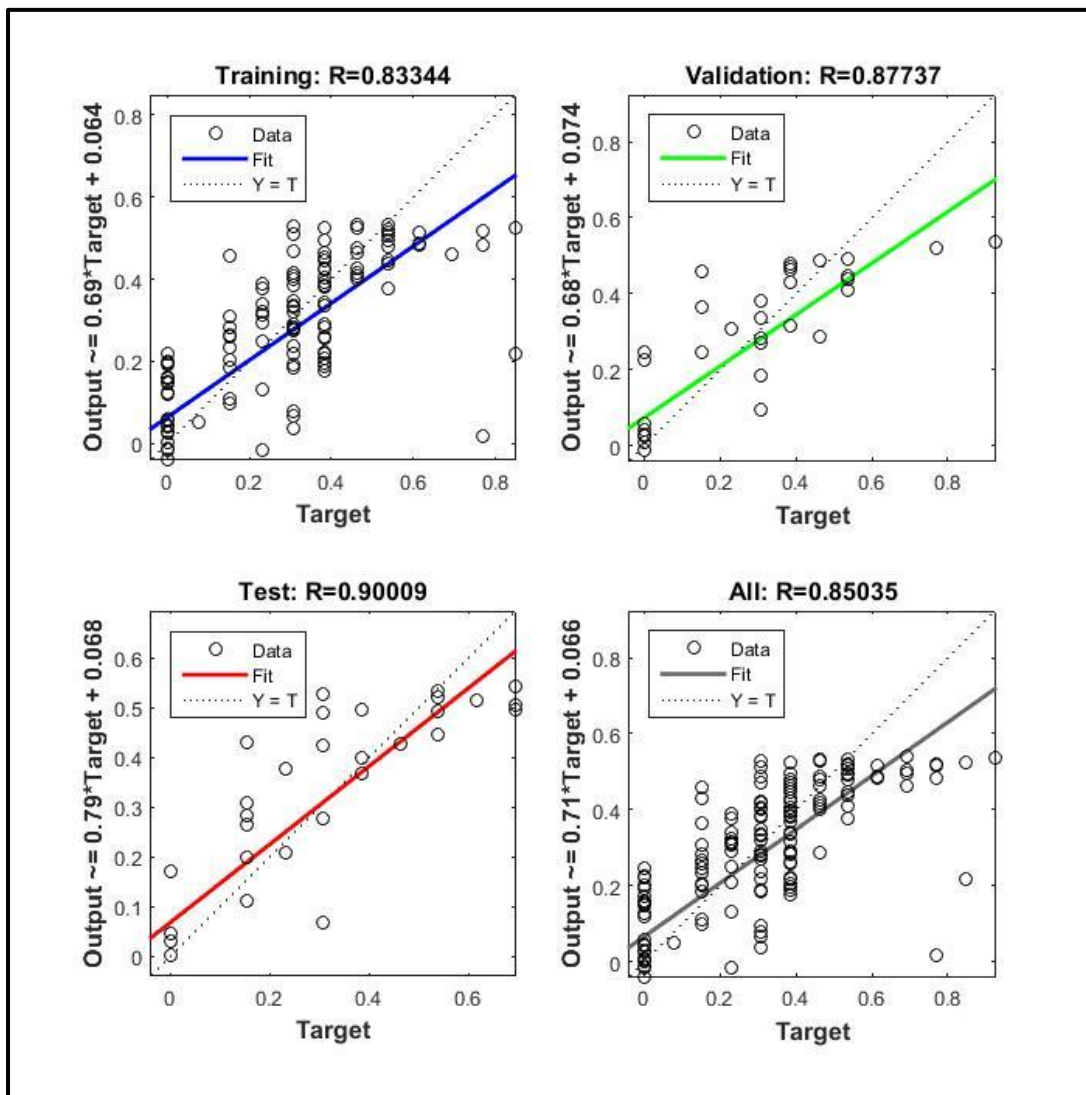
در این پیوست نتایج پیش‌بینی‌های سرعت و جهت‌های باد در ساعت‌های ۰۶:۰۰، ۱۲:۰۰ و ۱۸:۰۰ با استفاده از شبکه عصبی بهینه ارائه شده در این تحقیق که در متن پایان‌نامه به دلیل حجم زیاد مطالب آورده نشده بود آمده است.

### الف-۱- پیش‌بینی‌های سرعت و جهت باد در ساعت ۰۶:۰۰

جدول‌های (الف-۱)، (الف-۲) و (الف-۳) به ترتیب نتایج پیش‌بینی‌های سرعت باد، جهت باد افقی و جهت باد عمودی با استفاده از شبکه عصبی مصنوعی MLP با نمونه‌گیری بگینگ ارائه کردند و شکل (الف-۱) رگرسیون مجموعه داده‌های مختلف آموزش و آزمون شبکه در مدل M3 که بهترین نتایج را با ترکیب ورودی مورد نظر بدست آورد را نشان داد.

جدول (الف-۱) معیارهای ارزیابی پیش‌بینی سرعت باد در ساعت ۰۶:۰۰ توسط شبکه MLP با بگینگ

نام مدل	MSE استاندارد شده	RMSE	R		
			آزمون	آموزش	اعتبارسنجی
M1	۰.۰۱۴۹	۲.۵۷۸۲	۰.۸۵۶۹	۰.۷۹۸۷	۰.۸۳۳۲
M2	۰.۰۱۶۸	۲.۴۸۶۶	۰.۸۹۶۵	۰.۸۰۷۵	۰.۸۲۹۰
M3	۰.۰۱۴۷	۲.۴۷۰۰	۰.۸۵۷۲	۰.۸۶۰۸	۰.۹۱۴۰
M4	۰.۰۱۱۴	۲.۴۰۶۰	۰.۹۰۰۰	۰.۸۳۳۴	۰.۸۷۷۳
M5	۰.۱۳۷	۲.۴۱۰۷	۰.۸۵۸۵	۰.۸۳۸۲	۰.۹۱۲۵
M6	۰.۰۱۶۴	۲.۴۹۹۳	۰.۸۴۵۳	۰.۸۶۸۲	۰.۸۴۰۱



شکل (الف-1) نمودارهای رگرسیون مدل M3 پیش بینی سرعت باد در ساعت ۰۶:۰۰ توسط شبکه

MLP با بگینگ

جدول (الف-۲) معیارهای ارزیابی پیش‌بینی جهت باد افقی در ساعت ۰۶:۰۰ توسط شبکه MLP با بگینگ

نام مدل	MSE استاندارد شده	RMSE	R		
			آزمون	آموزش	اعتبارسنجی
M1	۰.۱۶۹۴	۵.۵۸۰۸	۰.۴۸۹۸	۰.۹۰۸۳	۰.۸۵۳۰
M2	۰.۰۹۰۰	۳.۰۱۹۴	۰.۸۰۵۳	۰.۸۱۳۲	۰.۸۴۱۶
<b>M3</b>	<b>۰.۰۵۴۰</b>	<b>۲.۹۶۲۴</b>	<b>۰.۸۳۷۸</b>	<b>۰.۷۴۰۷</b>	<b>۰.۷۲۶۱</b>
M4	۰.۰۷۴۶	۳.۰۴۶۰	۰.۷۸۲۶	۰.۶۷۳۹	۰.۶۶۹۶
M5	۰.۱۸۸۳	۴.۲۹۸۹	۰.۶۷۶۵	۰.۸۷۷۴	۰.۹۲۰۵

جدول (الف-۳) معیارهای ارزیابی پیش‌بینی جهت باد عمودی در ساعت ۰۶:۰۰ توسط شبکه MLP با

بگینگ

نام مدل	MSE استاندارد شده	RMSE	R		
			آزمون	آموزش	اعتبارسنجی
M1	۰.۱۵۷۵	۲.۸۶۵۰	۰.۶۲۷۶	۰.۸۲۴۶	۰.۷۷۵۰
M2	۰.۰۹۲۹	۱.۸۱۹۶	۰.۸۰۷۸	۰.۷۷۵۷	۰.۷۳۲۶
<b>M3</b>	<b>۰.۰۶۹۹</b>	<b>۱.۸۰۹۵</b>	<b>۰.۸۷۵۲</b>	<b>۰.۸۸۲۸</b>	<b>۰.۸۰۷۶</b>
M4	۰.۰۱۲۹۸	۱.۸۰۰۱	۰.۷۶۰۴	۰.۷۰۲۹	۰.۷۱۲۳
M5	۰.۱۳۴۵	۲.۰۵۹۴	۰.۶۴۹۸	۰.۷۹۰۲	۰.۷۷۵۰

الف-۲- پیش‌بینی‌های سرعت و جهت باد در ساعت ۱۲:۰۰

طبق نتایج ارائه شده در جداول (الف-۴)، (الف-۵) و (الف-۶) که به ترتیب مربوط به پیش‌بینی-

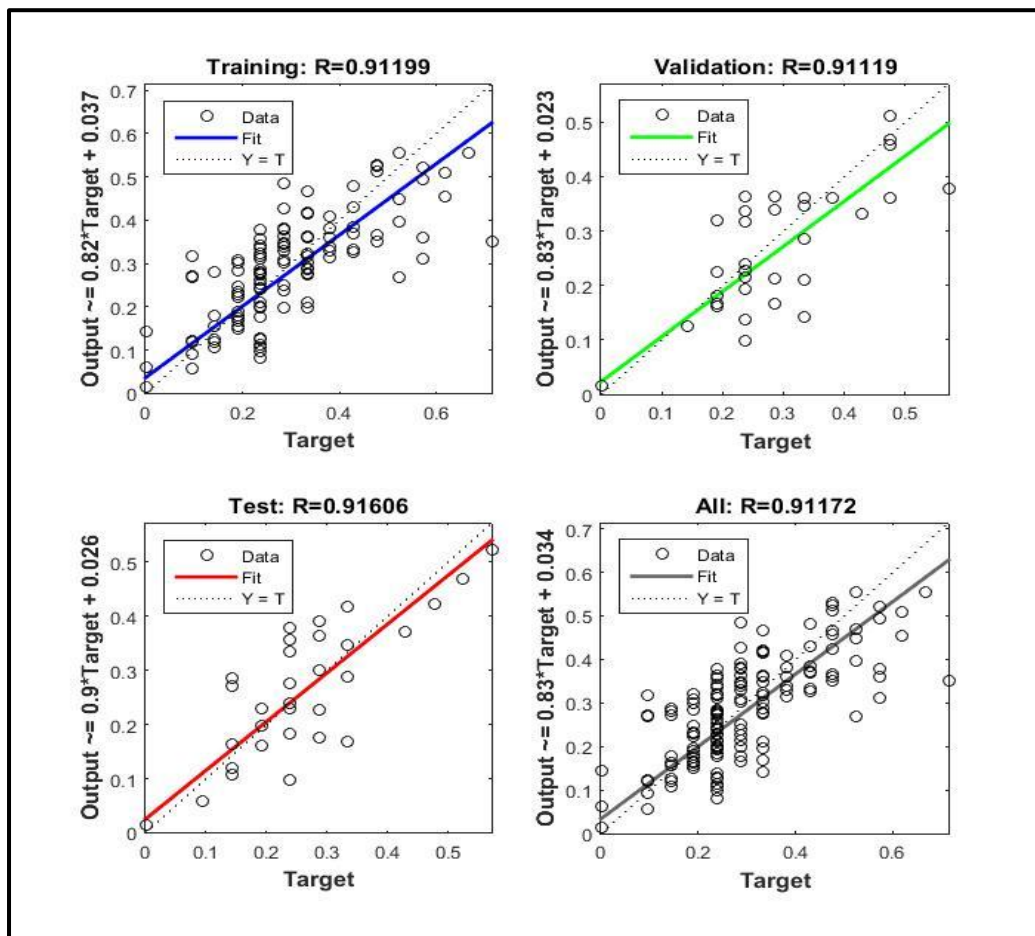
های سرعت باد، جهت باد افقی و جهت باد عمودی است، مدل M3 مطلوب‌ترین عملکرد را در

شاخص‌های ارزیابی تعریف شده ارائه کرد. از این رو در شکل (الف-۲) نتایج رگرسیون مجموعه

داده‌های آموزش، آزمون و اعتبارسنجی نشان داده شد.

جدول (الف-۴) معیارهای ارزیابی پیش‌بینی سرعت باد در ساعت ۱۲:۰۰ توسط شبکه MLP با بگینگ

نام مدل	MSE		R		
	استانداردشده	RMSE	آزمون	آموزش	اعتبارسنجی
M1	۰.۰۰۶۸	۱.۶۵۸۵	۰.۸۱۷۷	۰.۸۷۸۲	۰.۸۷۱۹
M2	۰.۰۰۴۷	۱.۶۷۷۱	۰.۸۷۵۰	۰.۸۹۵۵	۰.۸۵۶۳
M3	۰.۰۰۹۲	۱.۶۷۰۳	۰.۸۸۰۵	۰.۸۶۸۲	۰.۹۰۸۷
M4	۰.۰۰۳۴	۱.۶۲۰۷	۰.۹۱۶۰	۰.۹۱۱۹	۰.۹۱۱۱
M5	۰.۰۰۴۲	۱.۶۳۴۹	۰.۸۷۳۹	۰.۹۰۷۶	۰.۹۱۷۴
M6	۰.۰۰۵۹	۱.۶۵۳۱	۰.۸۷۴۰	۰.۸۹۵۹	۰.۸۹۸۴



شکل (الف-۲) نمودارهای رگرسیون مدل M3 پیش‌بینی سرعت باد در ساعت ۱۲:۰۰ توسط شبکه

MLP با بگینگ

جدول (الف-۵) معیارهای ارزیابی پیش‌بینی جهت باد افقی در ساعت ۱۲:۰۰ توسط شبکه MLP با بگینگ

نام مدل	MSE استاندارد شده	RMSE	R		
			آزمون	آموزش	اعتبارسنجی
M1	۰.۲۷۳۸	۴.۰۴۶۵	۰.۳۳۲۶	۰.۵۳۳۹	۰.۶۶۰۷
M2	۰.۱۶۵۸	۲.۸۳۷۹	۰.۷۳۵۴	۰.۶۴۵۳	۰.۶۹۰۱
<b>M3</b>	<b>۰.۱۶۳۷</b>	<b>۲.۳۸۵</b>	<b>۰.۷۶۴۶</b>	<b>۰.۷۱۱۶</b>	<b>۰.۶۲۲۳</b>
M4	۰.۲۰۹۸	۳.۱۹۷۴	۰.۵۵۳۳	۰.۶۳۴۵	۰.۶۶۹۱
M5	۰.۲۱۴۶	۳.۹۵۶۷	۰.۴۷۲۲	۰.۷۸۶۵	۰.۷۵۸۳

جدول (الف-۶) معیارهای ارزیابی پیش‌بینی جهت باد عمودی در ساعت ۱۲:۰۰ توسط شبکه MLP با

بگینگ

نام مدل	MSE استاندارد شده	RMSE	R		
			آزمون	آموزش	اعتبارسنجی
M1	۰.۱۳۷۴	۳.۹۶۷۲	۰.۵۰۴۱	۰.۶۶۰۱	۰.۶۸۶۸
M2	۰.۱۰۱۷	۲.۶۲۷۴	۰.۶۸۶۷	۰.۷۵۸۲	۰.۷۵۵۰
<b>M3</b>	<b>۰.۰۳۹۶</b>	<b>۲.۰۱۷۳</b>	<b>۰.۷۴۱۶</b>	<b>۰.۷۷۳۸</b>	<b>۰.۸۴۸۸</b>
M4	۰.۱۰۵۴	۲.۴۷۸۵	۰.۶۷۱۰	۰.۶۶۶۴	۰.۶۵۹۳
M5	۰.۱۱۷۵	۳.۰۳۹۲	۰.۵۹۱۰	۰.۷۷۹۲	۰.۷۵۹۸

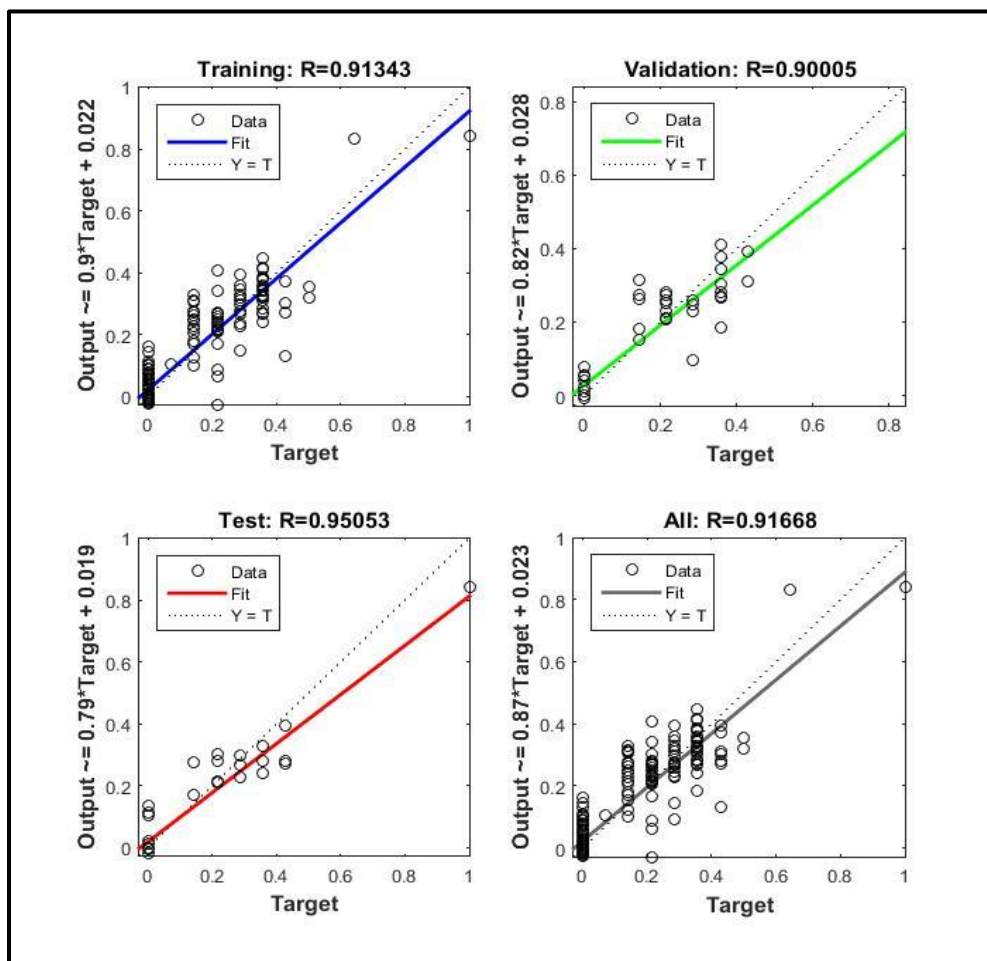
الف-۳ - پیش‌بینی‌های سرعت و جهت باد در ساعت ۱۸:۰۰

در این بخش نتایج معیارهای ارزیابی پیش‌بینی‌های سرعت باد، جهت باد افقی و جهت باد عمودی به ترتیب در جداول (الف-۷)، (الف-۸) و (الف-۹) ارائه شد. در این ساعت نیز همانند تمامی شبکه‌های پیشین مدل M3 برترین مدل بدست آمد و رگرسیون مجموعه داده‌های این مدل در شکل (الف-۳) نشان داده شد.



جدول (الف-۷) معیارهای ارزیابی پیش‌بینی سرعت باد در ساعت ۱۸:۰۰ توسط شبکه MLP با بگینگ

نام مدل	MSE		R		
	استاندارد شده	RMSE	آزمون	آموزش	اعتبارسنجی
M1	۰.۰۱۱۲	۲.۰۲۶۸	۰.۷۳۶۶	۰.۶۸۷۲	۰.۶۴۹۴
M2	۰.۰۰۷۹	۱.۴۵۶۷	۰.۸۶۴۳	۰.۷۹۴۹	۰.۷۷۷۷
M3	۰.۰۰۵۲	۱.۴۴۲۲	۰.۸۹۷۹	۰.۸۰۲۸	۰.۸۷۰۴۸
M4	۰.۰۰۴۳	۱.۳۹۳۳	۰.۹۵۰۵	۰.۹۱۳۴	۰.۹۰۰۰
M5	۰.۰۰۶۴	۱.۴۶۵۷	۰.۸۷۶۶	۰.۹۱۴۲	۰.۸۳۴۳
M6	۰.۰۰۸۰	۱.۴۷۱۴	۰.۸۵۲۸	۰.۸۷۰۲	۰.۷۳۹۷



شکل (الف-۳) نمودارهای رگرسیون مدل M3 پیش‌بینی سرعت باد در ساعت ۱۸:۰۰ در شبکه MLP با

بگینگ

جدول (الف-۸) معیارهای ارزیابی پیش‌بینی جهت باد افقی در ساعت ۱۸:۰۰ توسط شبکه MLP با بگینگ

نام مدل	MSE استاندارد شده	RMSE	R		
			آزمون	آموزش	اعتبارسنجی
M1	۰.۳۸۰۱	۳.۱۳۷۸	۰.۳۳۲۶	۰.۵۳۳۹	۰.۶۶۰۷
M2	۰.۲۶۵۶	۲.۵۴۹۶	۰.۶۵۵۳	۰.۶۷۴۱	۰.۵۳۲۳
M3	۰.۲۳۵۶	۲.۳۸۸۳	۰.۷۵۱۷	۰.۶۷۳۷	۰.۲۸۶۹
M4	۰.۲۸۶۲	۳.۲۱۲۵	۰.۵۸۳۹	۰.۵۰۳۷	۰.۶۷۲۹
M5	۰.۳۰۹۲	۴.۲۷۷۶	۰.۴۰۰۶	۰.۶۶۱۶	۰.۶۷۲۳

جدول (الف-۹) معیارهای ارزیابی پیش‌بینی جهت باد عمودی در ساعت ۱۸:۰۰ توسط شبکه MLP با

بگینگ

نام مدل	MSE استاندارد شده	RMSE	R		
			آزمون	آموزش	اعتبارسنجی
M1	۰.۱۹۴۳	۴.۹۰۴۴	۰.۴۰۹۴	۰.۵۵۶۴	۰.۵۸۰۰
M2	۰.۱۱۳۸	۳.۷۸۷۳	۰.۶۵۳۷	۰.۷۵۹۷	۰.۸۵۷۲
M3	۰.۰۷۹۴	۲.۷۷۵۶	۰.۷۳۵۹	۰.۷۳۶۵	۰.۶۹۵۵
M4	۰.۱۵۳۳	۳.۸۳۴۱	۰.۵۵۳۱	۰.۶۳۶۱	۰.۵۷۶۶
M5	۰.۱۶۱۹	۴.۸۲۱۱	۰.۴۴۱۵	۰.۵۰۳۸	۰.۶۴۹۵

**Abstract:**

Wind is one of the most important components in the climate of each region, and its variations can affect phenomena such as dust storm, and the rate of evapotranspiration. Wind behavior prediction due to its very random nature is very challenging and depends on the weather conditions and the regional hydroclimatic and topography factors. In addition to traditional physical and statistical methods, in recent years, some advanced methods based on artificial intelligence have been investigated to achieve high-certainty and accurate predictions.

In this study, several models have been developed to predict daily wind speed and direction in a special time of the day. Three types of artificial neural networks, namely NARX, multilayer perceptron (MLP), and the multilayer perceptron artificial neural network with Bagging method (bootstrap aggregating) as its data-sampling method were developed to predict one step ahead wind speed. All models were trained by using wind speed data of the Global Forecasting System (GFS) and some observed meteorological parameters (wind speed, air pressure, air temperature, relative humidity and precipitation) collected over a period of approximately two years (October 2014 - July 2016) in Bandar-Mahshahr. Based on the results, the multi-layer perceptron artificial neural network with Bagging sampling showed better performance compared to other two neural networks. In this research, the effect of different parameters on prediction models has also been investigated. In different input combination, air pressure and air temperature have the most effect on prediction of wind speed in Bandar-Mahshahr.

**Keywords:** prediction, wind speed, wind direction, daily, artificial neural network, bagging, GFS



**Shahrood University of Technology**

**Faculty of Civil Engineering**

**M.S.c Thesis in Water Resources Engineering and Management**

**Prediction of wind speed and direction using outputs from  
numerical weather forecasting models**

**By**

***Forouzan Khakzad***

**Supervisor:**

***Dr. Saeed Golian***

**Advisor:**

***Mohammad Elmi***

**January 2018**