

اللَّهُ أَكْبَرُ



دانشکده مهندسی عمران

گروه مهندسی آب و محیط زیست

پیش‌بینی بارش و دبی با استفاده از سیگنال‌های هواشناسی

در حوضه بالادست سد گلستان

دانشجو:

حسین رویگر

استاد راهنما:

سعید گلیان

پایان‌نامه ارشد جهت اخذ درجه کارشناسی ارشد

تابستان ۱۳۹۳

دانشگاه صنعتی شاهرود

دانشکده مهندسی عمران

گروه مهندسی آب و محیط زیست

پایان نامه کارشناسی ارشد آقای حسین رویگر

تحت عنوان: پیش بینی بارش و دبی با استفاده از سیگنال های هواشناسی

در حوضه بالادست سد گلستان

در تاریخ ۱۳۹۳/۶/۳۰ توسط کمیته تخصصی زیر جهت اخذ مدرک کارشناسی ارشد
مورد ارزیابی و با درجه مورد پذیرش قرار گرفت.

امضاء	اساتید مشاور	امضاء	اساتید راهنما
	نام و نام خانوادگی:		نام و نام خانوادگی:
	نام و نام خانوادگی:		

امضاء	نماینده تحصیلات تکمیلی	امضاء	اساتید داور
	نام و نام خانوادگی:		نام و نام خانوادگی:
			نام و نام خانوادگی:

تقدیم اثر:

و بعد از مدت‌ها، پس از پیمودن راه‌های فراوان که با حضور شیرین استاد عزیزم،
باراهنمایی‌ها و دغدغه‌های فراوانشان و شیطنت‌های زیبای آن دوران، نگاه‌های پدر مادرم،
با چشم‌های پر از برق شوق و زیبایی حضور خواهرم در کنارم که خستگی‌های این راه را
به امید و روشنی راه تبدیل کرده و امیدوارم بتوانم در آینده‌ی نزدیک جوابگوی این همه
محبت آن‌ها باشم...

اکنون، با احترام فراوان برای این همه تلاش این عزیزان برای موفقیت من....

این پایان‌نامه را به پدر و مادرم، استاد عزیز و خواهر مهربانم تقدیم می‌کنم

امیدوارم قادر به درک زیبایی‌های وجودشان باشم

با تشکر فراوان

تشکر و قدردانی:

سپاس خدای را که سخنوران، در ستودن او بمانند و شمارندگان، شمردن نعمت‌های او ندانند و کوشندگان، حق او را گزاردن نتوانند؛ و سلام و دورد بر محمد و خاندان پاک او، طاهران معصوم، هم آنان که وجودمان وامدار وجودشان است؛ و نفرین پیوسته بر دشمنان ایشان تا روز رستاخیز...

بدون شک جایگاه و منزلت معلم، اجل از آن است که در مقام قدردانی از زحمات بی‌شائبه‌ی او، با زبان قاصر و دست ناتوان، چیزی بنگاریم.

اما از آنجایی که تجلیل از معلم، سپاس از انسانی است که هدف و غایت آفرینش را تأمین می‌کند و سلامت امانت‌هایی را که به دستش سپرده‌اند، تضمین؛ برحسب وظیفه و از باب من لم تشکر المنعم من المخلوقین لم یشکر الله عزّ و جلّ: از پدر و مادر عزیزم... این دو معلم بزرگوارم... که همواره بر کوتاهی و درستی من، قلم عفو کشیده و کریمانه از کنار غفلت‌هایم گذشته‌اند و در تمام عرصه‌های زندگی یار و یآوری بی چشم‌داشت برای من بوده‌اند؛ از استاد با کمالات و شایسته؛ جناب آقای دکتر **گلپان** که در کمال سعه‌صدر، با حسن خلق و فروتنی، از هیچ کمکی در این عرصه بر من دریغ ننمودند و زحمت راهنمایی این پروژه را بر عهده گرفتند؛ و از اساتید فرزانه و دلسوز؛ آقایان دکتر **ساغروانی و دکتر عجمی** که زحمت داوری این پایان‌نامه را متقبل شدند؛ کمال تشکر و قدردانی رادارم.

باشد که این خردترین، بخشی از زحمات آنان را سپاس گوید

تعهدنامه

اینجانب **حسین رویگر** دانشجوی دوره کارشناسی ارشد رشته **مهندسی عمران** - **سازه‌های هیدرولیکی** دانشکده **مهندسی**

عمران دانشگاه صنعتی شاهرود نویسنده پایان‌نامه **پیش‌بینی بارش و دبی با استفاده از سیگنال‌های هواشناسی**

در حوضه بالادست سد گلستان تحت راهنمایی **دکتر سعید گلیان** متعهد می‌شوم.

- تحقیقات در این پایان‌نامه 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 پایان‌نامه 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 بانام «دانشگاه صنعتی شاهرود» و یا «Shahrood University of Technology» به چاپ خواهد رسید.
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان‌نامه تأثیرگذار بوده‌اند در مقالات مستخرج از پایان‌نامه رعایت می‌گردد.
- در کلیه مراحل انجام این پایان‌نامه، در مواردی که از موجود زنده (بافته‌های آن‌ها) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است.
- در کلیه مراحل انجام این پایان‌نامه، 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

امضای دانشجو

مالکیت نتایج و حق نشر

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

* متن این صفحه نیز باید در ابتدای نسخه‌های تکثیر شده پایان‌نامه وجود داشته باشد.

چکیده:

همان‌طور که مطالعات پژوهشگران نشان داد سیگنال‌های اقلیمی به‌عنوان متغیر پیش‌بینی‌کننده در بارش، خشک‌سالی، سیل و ... مورد استفاده قرار می‌گیرند. از این‌رو هدف اصلی این پژوهش بررسی میزان تأثیر سیگنال‌های بزرگ‌مقیاس اقلیمی بر بارش و دبی حوضه آبریز مطالعاتی و در نهایت ارائه مدل پیش‌بینی بارش و دبی با استفاده از سیگنال‌های بزرگ‌مقیاس اقلیمی و روش‌های هوش محاسباتی می‌باشد. در این مطالعه نقش سیگنال‌های بزرگ‌مقیاس اقلیمی در میزان بارش و دبی ماهانه حوضه آبریز مادرسو واقع در بالادست سد گلستان برای ۳ ایستگاه باران‌سنجی و ۳ ایستگاه هیدرومتری مهم در منطقه بررسی شد.

در مقیاس ماهانه، حداکثر همبستگی مجموع بارش و میانگین دبی ایستگاه‌های مطالعاتی برای سیگنال‌های اقلیمی با شاخص Nino 1+2 و برای داده‌های دمای سطح دریاهای گرینلند، شمال و جنوب خلیج فارس، جنوب دریای سرخ و شبکه سوران و با فشار سطح دریا خزر به دست آمد و این بدان معنا است که این شاخص بیش‌ترین تأثیر را بر بارش و دبی ماهانه حوضه‌ی آبریز مطالعاتی دارد. حداکثر میزان همبستگی شاخص Nino 1+2 با داده‌های ماهانه ایستگاه باران‌سنجی و هیدرومتری گالیکش به ترتیب ۰/۴۰ و ۰/۵۱ با تأخیر ۱۱ و ۱۳ ماه می‌باشد. با انجام تحلیل روی داده‌های دمای سطح دریا نیز بیش‌ترین ضریب همبستگی برای داده‌های بارش ۰/۴۵۵، ۰/۴۷۸ و ۰/۴۴ با تأخیرهای ۶ و ۳ و ۹ ماهه و برای داده‌های دبی نیز ۰/۴۴۲، ۰/۵۷۶ و ۰/۵۵۲ با تأخیرهای ۲ و ۷ و ۱۵ ماهه به‌دست آمده است. همچنین با انجام بررسی روی داده‌های فشار سطح دریا نیز بیش‌ترین ضریب همبستگی برای بارش و ۰/۴۲۵ با تأخیرهای ۷ و ۹ و ۹ ماهه و برای داده‌های دبی نیز ۰/۵۹۴، ۰/۴۳۳، ۰/۶۱ با تأخیر ۹ ماهه به‌دست آمده است. در کل ارتباط قوی میان بارش ایستگاه‌های تنگراه و تمر با SLP دریای خزر و گالیکش با SST دریای خزر و دبی ایستگاه‌های تنگراه و گالیکش و SLP دریای خزر و ایستگاه تمر با SST منطقه گرینلند وجود دارد. بیش‌ترین میزان همبستگی حداکثر

بارش ماهانه ایستگاه تنگراه در ماه می برابر با $0/641$ با SST شرق مدیترانه با تأخیر ۷ ماه، برای ایستگاه تمر در ماه اکتبر برابر با $0/537$ با SLP غرب دریای مدیترانه با تأخیر ۱۱ ماهه و برای ایستگاه گالیکش در ماه اوت برابر با $0/495$ با SLP اقیانوس اطلس با تأخیر ۴ ماهه به دست آمد. بیشترین میزان همبستگی دبی ایستگاه‌های تنگراه، تمر و گالیکش با ماه آوریل به ترتیب برابر با $0/937$ ، $0/782$ و $0/926$ با تأخیر ۸ ماهه و با SLP خلیج عدن به دست آمد. همچنین بررسی معنی‌داری این ضرایب به‌دست‌آمده از طریق P-Value نشان‌دهنده معنی‌دار بودن همه‌ی این ضرایب می‌باشد. در مرحله پیش‌بینی از هرکدام از این سیگنال‌ها برای پیش‌بینی بارش و دبی حداکثر ماهانه در ماه‌های دوم، سوم و چهارم میلادی سال به‌عنوان ماه‌های پربارش و همچنین ماه هشتم سال میلادی به‌عنوان ماهی که سیل‌های بزرگی مانند سیل‌های سال ۱۳۸۰ و ۱۳۸۴ در آن رخ داده استفاده شد. همچنین با استفاده از روش شبکه‌های عصبی مصنوعی چندلایه مقادیر بارش و دبی حداکثر ماهانه شبیه‌سازی شد. این شبکه‌ها دارای یک یا چند ورودی به‌عنوان سیگنال‌هایی که بیشترین همبستگی را با مقادیر بارش و دبی حداکثر ماهانه در بررسی همبستگی دارا بود و یک خروجی به‌عنوان مدل پیش‌بینی می‌باشد. با استفاده از این نتایج و همچنین شبکه‌های به‌دست‌آمده از هر سری زمانی در ماه‌های مختلف می‌توان وقایع حدی بارش و دبی در ماه‌های فوریه، مارس، آوریل و اوت را با دقت نسبتاً خوبی پیش‌بینی کرد. به‌عنوان مثال، شاخص‌های عملکرد ازجمله ریشه میانگین مربعات خطا، ضریب همبستگی و ضریب ناش-ساتکلیف برای حداکثر برای بارش ایستگاه باران‌سنجی تنگراه $0/067$ ، $0/95$ و $0/945$ در ماه اوت و دبی ماهانه برای ایستگاه هیدرومتری تمر $0/078$ ، $0/989$ و $0/958$ در ماه اوت، برای دوره آزمون به دست آمد. درنهایت شبکه‌های عصبی ذخیره‌شده برای پیش‌بینی بارش و دبی سیلاب مرداد اخیر ۱۳۹۳ مورد استفاده قرار گرفته و نتایج قابل‌قبولی به دست آمد.

کلیدواژگان: سیگنال‌های هواشناسی، دمای سطح دریا، فشار سطح دریا، دبی، بارش، شبکه عصبی مصنوعی، همبستگی

لیست مقالات:

Ruigar.H, Golian.s. (2014). **Prediction of maximum monthly rainfall in Golestan Dam Watershed using climate signals.** Theoretical and Applied Climatology

رویگر، ح؛ گلیان، س، " بررسی ارتباط بین شاخص‌های بزرگ‌مقیاس اقلیمی بر میزان بارش ماهانه و آبدهی متوسط ماهانه حوضه سد گلستان"، هشتمین کنگره ملی مهندسی عمران، دانشکده مهندسی عمران، بابل ۱۷ و ۱۸ اردیبهشت‌ماه ۱۳۹۳

فهرست مطالب:

فصل اول: مقدمه.....	۱
۱-۱ مقدمه.....	۲
۲-۱ رویداد النینو - نوسانات جنوبی	۳
۱-۲-۱ شاخص Nino 1+2.....	۶
۲-۲-۱ شاخص Nino3.....	۶
۳-۲-۱ شاخص Nino 3,4.....	۶
۴-۲-۱ شاخص Nino 4.....	۶
۵-۲-۱ شاخص چند متغیره انسو	۶
۶-۲-۱ شاخص انتقالی نینو.....	۷
۸-۳-۱ نوسان قطبی.....	۷
۴-۱ نوسان قطب شمال	۹
۵-۱ نوسان دهه‌ای اقیانوس آرام (PDO):.....	۱۰
۶-۱ شاخص نوسان جنوبی	۱۱
۷-۱ دمای سطح دریا.....	۱۲
۸-۱ فشار سطح دریا	۱۲
۹-۱ هدف از انجام پایان نامه	۱۳

۱۰-۱	بخش‌های مختلف پایان‌نامه	۱۳
فصل دوم:	مروری بر تحقیقات گذشته	۱۵
۱-۲	مقدمه	۱۶
۲-۲	بررسی ارتباط سیگنال‌های پیوند از دور با بارش، سیل و خشک‌سالی در نقاط مختلف	۱۷
۳-۲	پیش‌بینی دبی و بارش با استفاده از هوش مصنوعی با در نظر گرفتن سیگنال‌های	
	بزرگ‌مقیاس به‌عنوان ورودی	۲۲
۴-۲	جمع‌بندی	۲۸
<u>۳۱</u>	فصل سوم: مواد و روش‌ها	
۱-۳	مقدمه	۳۲
۲-۳	ضریب همبستگی	۳۳
۱-۲-۳	ضریب همبستگی پیرسون	۳۴
۳-۳	شبکه عصبی مصنوعی	۳۵
۴-۳	مدل ریاضی نرون‌های عصبی	۳۷
۵-۳	الگوریتم پس انتشار خطا	۳۹
۱-۵-۳	انتشار به عقب حساسیت‌ها	۴۴
۶-۳	توابع محرک (توابع انتقال)	۴۶
۱-۶-۳	تابع خطی	۴۶

۴۷.....	۲-۶-۳ تابع محدودکننده (حد آستانه)
۴۸.....	۳-۶-۳ تابع سیگموئیدی تک قطبی
۴۸.....	۴-۶-۳ تابع تانژانت هیپربولیک
۴۹.....	۷-۳ شبکه‌های MLP
۵۰.....	۸-۳ استانداردسازی داده‌های بارش و دبی قبل از ورود به پرسپترون چندلایه
۵۱.....	۹-۳ توابع هدف مورد استفاده برای بهینه‌سازی مدل‌ها
۵۲.....	۱۰-۳ جمع‌بندی
۵۳.....	فصل چهارم: منطقه تحقیق
۵۶.....	۱-۴ مقدمه
۵۷.....	۲-۴ منطقه تحقیق
۵۹.....	۳-۴ داده‌های مورد استفاده
۶۰.....	فصل پنجم: نتایج و بحث
۶۴.....	۱-۵ بررسی همبستگی
۶۴.....	۱-۱-۵ بررسی همبستگی مقادیر متوسط ماهانه با سیگنال‌های اقلیمی
۶۵.....	۲-۱-۵ بررسی همبستگی ماهانه با داده‌های دمای سطح دریا
۶۷.....	۳-۱-۵ بررسی همبستگی ماهانه با داده‌های فشار سطح دریا
۶۸.....	۴-۱-۵ بررسی همبستگی مقادیر حدی بارش و دبی ماهانه با سیگنال‌های بزرگ مقیاس اقلیمی

- ۵-۱-۵- جمع بندی ۷۴
- ۵-۲- پیش بینی بارش و دبی ماهانه با شبکه عصبی مصنوعی ۷۵
- ۵-۲-۱- پیش بینی بارش حداکثر ماهانه با شبکه عصبی مصنوعی ۷۷
- ۵-۲-۱-۱- پیش بینی با یک سیگنال ۷۹
- ۵-۲-۱-۲- پیش بینی با سه سیگنال ۸۰
- ۵-۲-۱-۳- پیش بینی با بهترین سیگنال ها ۸۱
- ۵-۲-۲- پیش بینی دبی حداکثر ماهانه ۸۸
- ۵-۲-۲-۱- پیش بینی دبی حداکثر ماهانه با یک سیگنال ۹۱
- ۵-۲-۲-۲- پیش بینی دبی حداکثر ماهانه با سه سیگنال ۹۲
- ۵-۲-۲-۳- پیش بینی دبی حداکثر ماهانه با بهترین سیگنال ها ۹۴
- ۵-۲-۳- جمع بندی ۱۰۰
- ۵-۲-۴- پیش بینی بارش و سیل اخیر مرداد ۱۳۹۳ ۱۰۱
- فصل ششم: نتیجه گیری و پیشنهادات ۱۰۳
- ۶-۱- نتیجه گیری ۱۰۴
- ۶-۲- پیشنهادات ۱۰۸
- فصل هفتم: منابع و مآخذ ۱۰۹

فهرست اشکال:

- شکل ۱-۱: چرخه وقوع فازهای گرم و سرد پدیده انسو در اقیانوس آرام جنوبی ۵
- شکل ۲-۱: موقعیت جغرافیایی شماتیک ۴ شاخص اول پدیده انسو ۵
- شکل ۳-۱: نمای شماتیکی وقوع نوسانات قطبی ۸
- شکل ۴-۱: وقوع فازهای مثبت و منفی نوسانات اطللس شمالی ۱۰
- شکل ۵-۱: نمای شماتیکی وقوع نوسانات دههای اقیانوس آرام ۱۱
- شکل ۱-۳: ساختار کلی شبکه عصبی مصنوعی ۳۷
- شکل ۲-۳: شبکه عصبی مک کلاچ- پیتز ۳۸
- شکل ۳-۳: تابع محدودکننده ۴۷
- شکل ۴-۳: تابع سیگموئیدی تک قطبی ۴۸
- شکل ۵-۳: تابع تانژانت هیپربولیک ۴۸
- شکل ۱-۴: موقعیت حوضه مادرسو و ایستگاههای باران سنجی و هیدرومتری مورد استفاده ۵۹
- شکل ۲-۴: نمای شماتیک نقاط مورد استفاده در تحلیلهای دما و فشار سطح دریا ۶۱
- شکل ۱-۵: حداکثر ضریب همبستگی محاسبه شده برای مجموع بارش ماهانه ایستگاههای باران سنجی و دمای سطح دریا ۶۶
- شکل ۲-۵: حداکثر ضریب همبستگی محاسبه شده برای میانگین دبی ماهانه ایستگاههای هیدرومتری و دمای سطح دریا ۶۶
- شکل ۳-۵: حداکثر ضریب همبستگی محاسبه شده برای مجموع بارش ماهانه ایستگاههای باران سنجی و فشار سطح دریا ۶۷
- شکل ۴-۵: حداکثر ضریب همبستگی محاسبه شده برای میانگین دبی ماهانه ایستگاههای هیدرومتری و فشار سطح دریا ۶۷

- شکل ۵-۵: ضریب همبستگی محاسبه شده حداکثر دبی ماهانه ایستگاه‌های باران‌سنجی و سیگنال-
های بزرگ‌مقیاس اقلیمی ۶۹
- شکل ۵-۶: ضریب همبستگی حداکثر بارش ماهانه ایستگاه‌های هیدرومتری و سیگنال‌های
بزرگ‌مقیاس اقلیمی ۶۹
- شکل ۵-۷: خط رگرسیون بین مقادیر مشاهداتی و پیش‌بینی‌شده بارش ایستگاه تنگراه ۸۴
- شکل ۵-۸: خط رگرسیون بین مقادیر مشاهداتی و پیش‌بینی‌شده بارش ایستگاه تمر ۸۵
- شکل ۵-۹: خط رگرسیون بین مقادیر مشاهداتی و پیش‌بینی‌شده بارش ایستگاه گالیکش ۸۶
- شکل ۵-۱۰: مقایسه نتایج به‌دست آمده بارش پیش‌بینی شده ANN و بارش مشاهداتی ماه‌های
مختلف ایستگاه‌های مطالعاتی ۸۷
- شکل ۵-۱۱: خط رگرسیون بین مقادیر مشاهداتی و پیش‌بینی‌شده دبی ایستگاه تنگراه ۹۶
- شکل ۵-۱۲: خط رگرسیون بین مقادیر مشاهداتی و پیش‌بینی‌شده دبی ایستگاه تمر ۹۷
- شکل ۵-۱۳: خط رگرسیون بین مقادیر مشاهداتی و پیش‌بینی‌شده دبی ایستگاه گالیکش ۹۸
- شکل ۵-۱۴: مقایسه نتایج به‌دست آمده دبی پیش‌بینی‌شده ANN و دبی مشاهداتی ماه‌های مختلف
ایستگاه‌های مطالعاتی ۹۹

فهرست جداول:

- جدول ۳-۱: مدل‌های ورودی و خروجی بارش حداکثر ماهانه در شبکه عصبی مصنوعی ۵۳
- جدول ۳-۲: مدل‌های ورودی و خروجی دبی حداکثر ماهانه شبکه عصبی مصنوعی ۵۳
- جدول ۴-۱: برخی از پارامترهای آماری داده‌های بارش حداکثر ماهانه ایستگاه‌های مطالعاتی ۵۸
- جدول ۴-۲: برخی از پارامترهای آماری داده‌های دبی حداکثر ماهانه ایستگاه‌های مطالعاتی ۵۸
- جدول ۴-۳: نام و مختصات نقاط مورد استفاده در تحلیل‌های دما و فشار سطح دریا ۶۰

- جدول ۵-۱: حداکثر ضریب همبستگی محاسبه شده برای مجموع بارش ماهانه ایستگاه‌های بارسنجی و شاخص‌های اقلیمی ۶۴
- جدول ۵-۲: حداکثر ضریب همبستگی برای میانگین دبی ماهانه ایستگاه‌های هیدرومتری و شاخص‌های اقلیمی ۶۵
- جدول ۵-۳: بررسی معنی داری حداکثر ضرایب همبستگی میانگین بارش و دبی ۶۸
- جدول ۵-۴: تأخیر و معنی داری برای حداکثر بارش ماهانه ایستگاه‌های باران‌سنجی و سیگنال‌های بزرگ مقیاس اقلیمی ۷۰
- جدول ۵-۵: تأخیر و معنی داری برای حداکثر دبی ماهانه ایستگاه‌های هیدرومتری و سیگنال‌های بزرگ مقیاس اقلیمی ۷۱
- جدول ۵-۶: مدل‌های استفاده شده برای پیش‌بینی بارش حداکثر ماهانه ۷۷
- جدول ۵-۷: نتایج آنالیز شبکه عصبی برای پیش‌بینی با یک سیگنال ۸۰
- جدول ۵-۸: نتایج آنالیز شبکه عصبی برای پیش‌بینی با سه سیگنال ۸۱
- جدول ۵-۹: نتایج آنالیز شبکه عصبی برای پیش‌بینی با بهترین سیگنال‌ها ۸۲
- جدول ۵-۱۰: مدل‌های استفاده شده برای پیش‌بینی دبی حداکثر ماهانه ۸۸
- جدول ۵-۱۱: نتایج آنالیز شبکه عصبی برای پیش‌بینی با یک سیگنال ۹۲
- جدول ۵-۱۲: نتایج آنالیز شبکه عصبی برای پیش‌بینی با سه سیگنال ۹۳
- جدول ۵-۱۳: نتایج آنالیز شبکه عصبی برای پیش‌بینی با بهترین سیگنال‌ها ۹۵
- جدول ۵-۱۴: مقادیر مشاهداتی و پیش‌بینی شده بارش منجر به سیلاب مرداد ۱۳۹۳ ۱۰۱
- جدول ۵-۱۵: مقادیر مشاهداتی و پیش‌بینی شده دبی سیلاب مرداد ۱۳۹۳ ۱۰۱

فصل

۱

مقدمه

همه جنبه‌های زندگی انسان به نحوی تحت تأثیر فرایندهای آب و هوایی است و این تأثیرگذاری در زمینه‌های گوناگونی چون کشاورزی، آبیاری، اقتصاد، مخابرات، حمل‌ونقل، ترافیک، آلودگی هوا و صنایع نظامی بیشتر دیده می‌شود. پیش‌بینی این فرایندها ابزار مناسبی در اختیار مدیران حوزه‌های گوناگون قرار می‌دهد تا با در نظر گرفتن این پیش‌بینی‌ها، سیاست‌های آینده را در جهت بهینه ساختن صرف هزینه‌ها و امکانات بهره‌وری حداکثر طرح‌ریزی کنند (Haltiner, 1980).

در مناطق مختلف جهان به‌ویژه مناطق خشک و نیمه‌خشک تقاضا برای آب در همه‌ی بخش‌های خانگی، کشاورزی و صنعتی در حال افزایش است و تأمین آب در این مناطق با مشکل جدی روبه‌روست. با توجه به اینکه پیش‌بینی و پیش‌آگاهی میزان بارش و آب‌های سطحی در زندگی انسان و در برنامه‌های مدیریتی نقش اساسی و قابل‌توجهی دارد، مطالعه آن در نقاط مختلف ضروری است. در سال‌های اخیر بررسی برهم‌کنش بین عوامل آب و هوایی در خشکی، اقیانوس و جو موردتوجه بسیاری از دانشمندان علوم هواشناسی و اقلیم‌شناسی و هیدرولوژی قرار گرفته است. یکی از عوامل اصلی مؤثر بر نوسانات اقلیمی سالانه کره‌ی زمین سیگنال‌های هواشناسی پیوند از دور در مقیاس جهانی و ناحیه‌ای است (فلاح قاله‌ری، ۱۳۸۵).

سیگنال‌های هواشناسی که در اثر تغییرات میدان‌های فشار در مناطق مختلف زمین شناخته شده‌اند، می‌توانند با تغییر توزیع فشار در سطح زمین، الگوهای بارش و به‌ویژه دمای سطح زمین را تعیین کنند. تاکنون محققین علم هواشناسی توانسته‌اند با استفاده از تغییرات میدان‌های فشار در مناطق مختلف کره زمین، سیگنال‌های متعددی را بیابند که هرکدام از آن‌ها می‌توانند پراکندگی بارش را در منطقه تحت تأثیر خود مشخص نماید، ازجمله سیگنال‌های مهم هواشناسی که هم‌اکنون محققین متعددی در حال مطالعه اثرات آن‌ها بر روی الگوهای بارش و دمای زمین هستند، می‌توان به پدیده‌ی النینو نوسانات جنوبی (ENSO)، نوسان اصلی شمالی (NAO)، نوسان قطبی (AO)، نوسان دهه‌ای

اقیانوس آرام (PDO)، نوسان جنوبی (SOI)، اشاره نمود. از دیگر روش‌های پیش‌بینی آب و هوایی، استفاده از علامت‌ها و پدیده‌های مشخصی از قبیل تغییرات دوره‌ای فشار سطح دریا (SLP) و تغییرات دوره‌ای دمای سطح دریا (SST) و مانند این‌ها است که از آن‌ها بانام سیگنال‌های بزرگ‌مقیاس اقلیمی یاد می‌شود. این سیگنال بر اساس فشار سطح دریا، گرادیان فشار سطح دریا، دمای سطح دریا، گرادیان دمای سطح دریا و دیگر پارامترهای هواشناسی به دست می‌آیند. در زیر به تعریف هر یک از موارد ذکرشده به‌صورت مختصر می‌پردازیم.

۱-۲ رویداد النینو – نوسانات جنوبی^۱

رویداد النینو / نوسان جنوبی (ENSO) یکی از مهم‌ترین و شاخص‌ترین رویدادهایی است که منجر به ظهور ناهنجاری‌های بزرگ آب و هوایی در بسیاری از نقاط جهان می‌شود (Alexander, 1999); ناظم السادات و قاسمی، (۱۳۸۳). برای نخستین بار والکر و بلیس (۱۹۳۲) بر وجود نوسانی در فشار سطح دریا و در مقیاس جهانی اشاره کردند و آن را نوسان جنوبی SO نامیدند. واژه انسو از ترکیب دو واژه نوسان جنوبی^۲ و النینو^۳ گرفته‌شده که النینو مؤلفه اقیانوسی و نوسان جنوبی مؤلفه اتمسفری این پدیده است. معمولاً اختلاف فشار سطحی بین تاهیتی در شرق و داروین استرالیا در غرب اقیانوس آرام به‌عنوان مبنای اندازه‌گیری شاخص نوسان جنوبی (SOI) مورد استفاده قرار می‌گیرد و مقادیر مثبت یا منفی این اختلاف بیانگر فازهای مختلف انسو است. شاخص‌های درجه حرارت سطحی اقیانوس آرام در مناطق ۴ گانه Nino1+2، Nino3، Nino3,4، Nino4 نیز به‌وسیله محققین مختلفی پیشنهادشده است (Trenberth, 1996). شاخص انتقالی نینو^۴ (TNI) که اخیراً به‌وسیله ترن برت پیشنهاد گردیده نیز از روش‌های کاملاً جدید جهت محاسبه شرایط النینو و لانینا است (Trenberth and Stepaniak,)

1 El-nino Southern Oscillation

2 Southern Oscillation

3 El- Nino


4 Trans-Nino index

(2001). شاخص چند متغیره انسو^۱ (MEI) نیز یکی از روش‌های معتبر در این زمینه است (Wolter, 1987). فازهای گرم انسو به النینو و فازهای سرد به لانینا معروف هستند. واژه النینو اساساً به جریان اقیانوسی گرم و ضعیف سالانه‌ای اطلاق می‌شود که به سمت جنوب در امتداد سواحل پرو و اکوادور در ایام کریسمس جریان می‌یابد و با گرمایش وسیع و غیرمعمول که هرچند سال اتفاق می‌افتد، بوم‌شناسی منطقه‌ای و محلی را تغییر می‌دهد (Trenberth & Hoar, 1996). النینو یک شکست میان اتمسفر و اقیانوس آرام می‌باشد که نتیجه آن ایجاد تغییرات آب و هوایی می‌باشد و بیشتر در سواحل غربی آمریکای جنوبی نزدیک به خط استوا اتفاق می‌افتد. در این رویداد لایه سطحی آب اقیانوس در شرق اقیانوس آرام در ناحیه‌ای گرم می‌شود (حداکثر تا ۳/۵ درجه سانتی‌گراد) و این گرما ۴ ماه و یا بیشتر ادامه می‌یابد، این پدیده در بعضی از سال‌ها همراه با گرم شدن بیش‌ازحد می‌باشد که در این حال دمای سطح آب با یک انحراف معیار بالاتر از متوسط ماهانه حداقل برای ۴ ماه پی‌درپی و در سه یا پنج محل ساحلی بالا می‌رود همراه با این شارش آب گرم دمای سطح آب دریا و هوا غالباً برای یک سال و یا حتی بیشتر به صورت غیرعادی گرم باقی می‌ماند و برای برگشتن به وضعیت عادی حداقل یک سال زمان لازم خواهد بود. پس از پایان دوره گرم، مرحله سرد شدن آب‌های سطحی اقیانوس شروع می‌شود که به این پدیده لانینا می‌گویند (Wallace and Gutzler, 1981). این الگوها در واقع منعکس‌کننده تأثیرات پدیده انسو در شدت و موقعیت چرخه‌های سیاره‌ای و الگوهای وزش رود بادهای در مناطق ورای حاره‌ای می‌باشند. پدیده انسو بر مناطق مختلف کره زمین تأثیرات متفاوتی را می‌گذارد که بیشتر تأثیرات فاز گرم (النینو) مورد ارزیابی قرار گرفته‌اند. این اثرات شامل خشک‌سالی شدید، بارش‌ها و سیلاب‌های غیرمعمول، آتش‌سوزی جنگل‌ها و وقوع هاریکن‌ها، افزایش بیماری‌های گرمسیری همچون مالاریا و دیگر اثرات اقتصادی و اجتماعی می‌باشد (WMO, 1998). شاخص‌های پدیده انسو عبارت‌اند از: Nino 1+2, Nino 3, Nino 3,4, Nino 4, MEI (شاخص


¹ Multivariate ENSO Index

چند متغیره انسو) و TNI (شاخص انتقالی نینو). شکل (۱-۱) نمای شماتیکی از چرخه پدیده انسو می‌باشد. همچنین شکل (۱-۲) نشان‌دهنده‌ی موقعیت جغرافیایی شاخص‌های این پدیده است.

ENSO El Niño- Southern Oscillation



شکل ۱-۱: چرخه وقوع فازهای گرم و سرد پدیده انسو در اقیانوس آرام جنوبی



شکل ۲۱-: موقعیت جغرافیایی شماتیک ۴ شاخص اول پدیده انسو

۱-۲-۱ شاخص Nino 1+2

شاخص مذکور از سنجه‌های اصلی پدیده انسو می‌باشد و بیانگر نوسان‌های درجه حرارت سطح دریا در شرقی‌ترین بخش اقیانوس آرام مداری (حداصل صفر تا ۱۰ درجه جنوبی و ۱۶۰ درجه غربی تا ۱۵۰ درجه غربی) است.

۱-۲-۲ شاخص Nino3

این شاخص نمایانگر اختلاف درجه حرارت سطح دریا در طرف شرقی، بخش مداری اقیانوس آرام بین دو منطقه (۵ درجه شمالی و ۵ درجه جنوبی تا حوالی ۹۰ و ۱۵۰ درجه غربی) است

۱-۲-۳ شاخص Nino 3,4

بیان‌کننده اختلاف دمای سطح دریا در دو ناحیه در بخش داخلی قسمت شرق آرام مداری (۵ درجه شمالی و ۵ درجه جنوبی تا حوالی ۱۲۰ و ۱۷۰ درجه غربی) است

این شاخص بیانگر اختلاف درجه حرارت سطح دریا در دو ناحیه مرکزی بخش حاره‌ای اقیانوس آرام (در ۵ درجه شمالی و ۵ درجه جنوبی تا حوالی ۱۶۰ درجه شرقی و ۱۵۰ درجه غربی) است.

۱-۲-۵ شاخص چند متغیره انسو

شاخص چند متغیره انسو (MEI) با شش متغیر اصلی مشاهداتی روی پاسیفیک حاره‌ای قابل مشاهده است. این شش متغیر عبارت‌اند از: فشار سطح دریا (P)، اجزای ناحیه‌ای (U) و مؤلفه ناحیه‌ای باد سطحی (V)، دمای سطح دریا (S)، دمای هوای سطح (A) و میزان ابری بودن کل آسمان (C). این مشاهدات گردآوری شده و در ICODAS سال‌ها منتشر می‌شوند. شاخص MEI (شاخص چند متغیره

ENSO) یکی از معتبرترین نمایه‌های انسو است و مزیت آن نسبت به شاخص‌های دیگر آن است که پارامترهای زیادی در آن در نظر گرفته شده است (رابطه ۱-۱).

$$MEI=f(P+V+U+S+A+C) \quad 1-1$$

که در آن U مؤلفه زونالی باد سطحی، P فشار سطح دریا، S دمای سطح دریا، V مؤلفه نصف‌النهاری باد سطحی، C درجه ابرناکی آسمان و A دمای هوای سطحی است (Wolter, 1987).

۱-۲-۶ شاخص انتقالی نینو

شاخص انتقالی نینو (TNI) می‌تواند بر اساس تفاوت بین ناهنجاری‌های SST نرمال‌سازی شده میانگین نینو ۱+۲ و نواحی نینو ۴ بیان شود. چون نینو ۳.۴ می‌تواند به صورت تقریبی از طریق مجموع این دو شاخص ارزیابی شود، نینو ۳.۴ و TNI به صورت تقریبی صفر در نظر گرفته می‌شوند. گستره ناحیه‌ای کمتر نینو ۱+۲ و واریانس بیشتر SSTها در ناحیه با میانگین‌های نینو ۴ قابل‌مقایسه‌اند که به صورت مطلوب قبل از ایجاد تفاوت، نرمال‌سازی می‌شوند. شاخص انتقالی نینو به صورت زیر تعریف می‌شود (Trenberth and Stepaniak, 2001). (رابطه ۲-۱)

$$TNI= SST_{Nino1+2} - SST_{Nino4} \quad 2-1$$


۱-۳ نوسان قطبی^۱

نوسان قطبی (AO) به عنوان یکی از الگوهای پیوند از دور نیمکره شمالی، عبارت است از ناهنجاری فشار جوی در تراز دریا در عرض‌های قطبی شمال و عرض‌های میانی (عرض ۴۵ درجه شمالی) (Hodges, 2000). نوسان قطبی از نظر متخصصین آب‌وهوا برحسب الگوهای آب و هوایی در

^۱ Arctic Oscillation

محل‌هایی روی می‌دهد که هزاران مایل فاصله‌دارند، از جمله خیلی از مناطق جمعیتی اصلی اروپا و آمریکای شمالی. متخصص آب‌وهوای ناسا، دکتر جیمز ای. هانسن مکانیزمی را توضیح می‌دهد که از طریق آن AO روی آب‌وهوا در نقاطی دورتر از قطب شمال تأثیر می‌گذارد. درجه‌ای که هوای قطب شمال در عرض‌های میانی تأثیر می‌گذارد مرتبط با شاخص AO است که برحسب الگوهای فشار اتمسفریک سطحی تعریف می‌شود. زمانی که شاخص AO مثبت باشد، فشار سطحی در ناحیه قطب پایین است. این به تندبادهای عرض‌های میانی کمک می‌کند شدیدتر بوزند و به‌صورت مداوم از غرب به شرق باشند، به‌نحوی که هوای سرد قطب شمال را در ناحیه قطبی حفظ می‌کنند. زمانی که AO منفی باشد و فشار بیشتری در ناحیه قطب وجود دارد، بادهای ناحیه‌ای ضعیف‌ترند و حرکت بیشتر هوای سرد قطب به عرض‌های میانی وجود دارد (Hansen and Lebedeff, 1987).

این الگوی ناحیه‌ای متقارن بین فشارهای سطح دریا در قطب و عرض‌های دمایی، اولین بار توسط لورنز کشف شد (Lorenz, 1951) و در ۱۹۹۸ توسط تامسون و والاس نام‌گذاری شد (Thompson and Wallace, 1998). شکل (۳) نمای شماتیکی از وقوع نوسان قطبی در کره‌ی زمین را نشان می‌دهد.



شکل ۱-۳: نمای شماتیکی وقوع نوسانات قطبی

۴-۱ نوسان قطب شمال^۱


یکی از شاخص‌ترین الگوهای ارتباط از دور در همه فصول، نوسان قطب شمال (NAO) می‌باشد. NAO بخش‌های الگوهای شرق آتلانتیک و غرب آتلانتیک را ترکیب می‌کند (Barnston and Livezey, 1987) که اولین بار والاس و گوتزلر (۱۹۸۱) آن‌ها را برای فصل زمان مطرح کردند (Wallace and Gutzler, 1981). NAO تشکیل شده از یک قطب دوگانه شمال جنوب از ناهنجاری‌ها با یک مرکز که در گرینلند واقع شده و مرکز دیگری که در مرکز عرض‌های مرکزی آتلانتیک شمالی بین ۳۵ درجه شمالی و ۴۰ درجه شمالی واقع شده است. مرحله مثبت NAO نشان‌دهنده ارتفاعات زیر نرمال و فشار در عرض‌های بالایی آتلانتیک شمالی و ارتفاعات بالای نرمال و فشار در مرکز آتلانتیک شمالی، شرق ایالات متحده و غرب اروپاست. مرحله منفی منعکس‌کننده الگوی متضاد بالا و فشار و ناهنجاری‌ها در این نواحی است. هر دو مرحله NAO مرتبط با تغییراتی می‌باشند که بر اساس شدت و موقعیت تندبادهای آتلانتیک شمالی مشخص می‌شود و الگوهای بزرگ قیاسی بر اساس تغییرات در الگوهای معمول ناحیه‌ای و مریدونیال و نیز انتقال رطوبت ایجاد می‌کند (Hurrell, 1995) که به نوبه خود منجر به تغییرات در الگوهای دما و بارش می‌شود که معمولاً از شرق امریکای شمالی به غرب و مرکز اروپا گسترش می‌یابد (Rogers and Van Loon, 1979; Walker and Bliss, 1932).

شاخص نوسانات شمالی بر پایه اختلاف فشار نرمال شده سطح دریا (P) بین منطقه حاره‌ای آزور (A) و منطقه کم‌فشار جنب قطبی ایسلند (I)، بنانهاده شده است (Marshall et al. 2001).

$$NAO = P(A) - P(I) \quad ۳-۱$$

شکل (۴-۱) به صورت شماتیک فازهای مثبت و منفی نوسان اطلس شمالی را نشان می‌دهد.

^۱ North Atlantic Oscillation




شکل ۴-۱: وقوع فازهای مثبت و منفی نوسانات اطلس شمالی

۵-۱ نوسان دهه‌ای اقیانوس آرام^۱ (PDO):

نوسان دهه‌ای اقیانوس آرام (PDO) یکی از ناهنجاری‌های دمای سطح دریای ماهانه (SSTA) در اقیانوس آرام شمالی است (در عرض ۲۰ درجه شمالی) که بعد از برداشتن میانگین جهانی SSTA، شاخص PDO به صورت سری‌های زمانی جزء اصلی، استانداردسازی می‌شوند. در طول یک مرحله گرم یا مثبت، اقیانوس آرام غربی سرد و بخشی از اقیانوس آرام شرقی گرم می‌شود. در طول یک مرحله سرد یا منفی، الگوی عکس این روی می‌دهد. این باعث تغییرات مراحل در حداقل زمان چند دهه‌ای و معمولاً ۲۰ تا ۳۰ می‌شود. نوسان دهه‌ای اقیانوس آرام اولین بار توسط هاری نام‌گذاری شد که در حال مطالعه الگوی تولید سالمون در ۱۹۹۷ بود (Mantua et al. 1997). سیگنال PDO در ۱۶۶۱ از طریق سه حلقه در ناحیه با جا کالیفرنیا شناسایی شد (Biondi et al, 2001). شکل (۵-۱) به صورت شماتیک وقوع نوسان دهه‌ای اقیانوس آرام را نشان می‌دهد.

^۱ Pacific Decadal Oscillation



شکل ۱-۵: نمای شماتیکی وقوع نوسانات دهه‌ای اقیانوس آرام

۱-۶ شاخص نوسان جنوبی^۱

نوسان جنوبی یک مقیاس زمانی ۲ تا ۷ ساله دارد و تشکیل شده از مقیاس جهانی و موج دوره‌ای با مراکز فعالیت در فشار سطحی روی اندونزی و پاسیفیک جنوبی حاره‌ای (Trenberth, 1984). در این شاخص، یک منطقه پرفشار در اقیانوس آرام جنوبی و یک منطقه کم‌فشار در اقیانوس آرام غربی در نظر گرفته شده است. ایستگاه تاهیتی به‌عنوان مرکز پرفشار (۱۷ درجه جنوبی و ۱۵۰ درجه غربی) و ایستگاه داروین (۱۲ درجه جنوبی و ۱۳۰ درجه شرقی) به‌عنوان مرکز کم‌فشار تعیین شده‌اند (Trenberth and Hoar, 1996).

$$P_{\text{Tahiti}} - P_{\text{Darwin}} = \text{شاخص نوسان جنوبی}$$

۴-۱

^۱ Southern Oscillation

۷-۱ دمای سطح دریا^۱

دمای سطح دریا (SST) درجه حرارت آب نزدیک به سطح اقیانوس است. معنای دقیق سطح با توجه به روش اندازه‌گیری که استفاده می‌شود متفاوت است، اما بین ۱ میلی‌متر (۰/۰۴ اینچ) و ۲۰ متر (۷۰ فوت) زیر سطح دریا است. توده‌های هوا در جو به‌شدت به‌وسیله دمای سطح دریا در فاصله کوتاهی از ساحل تغییر می‌یابد. دمای سطح دریا مانند هوای بالای آن به‌صورت روزانه تغییر می‌کند، اما به علت گرمای ویژه بالاتر آن این تغییرات کمتر است. تنوع SST در روزی که هوا باد ملایم دارد از روز آرام کمتر است. علاوه بر این، جریان‌های اقیانوسی جهانی متوسط SST به‌طور قابل‌توجهی در بیشتر از اقیانوس‌های جهان تحت تأثیر قرار می‌دهد. ارزش SST در پیش‌بینی آب‌وهوای محاسباتی به‌عنوان SST که جو بالا را تحت تأثیر قرار می‌دهد، از جمله در شکل‌گیری نسیم دریا و مه دریا و بارش مهم است (Alexander, 1999; Browsing, 1999; Rao, 1972).

۸-۱ فشار سطح دریا^۲

فشار سطح دریا (SLP)، از یک‌سو، به‌عنوان «پارامتر پل» که خواص ژئوفیزیکی در مرز هوا با دریا (به‌عنوان مثال، تنش باد و ارتفاع سطح دریا) به هم مرتبط می‌کند شناخته می‌شود و از سوی دیگر، به‌عنوان یک «پارامتر شاخص» که در آن نوسانات جوی بزرگ، از جمله نوسانات جنوبی، تعریف می‌شوند. فشارسنج (بارومتر) دستگاهی است (بیشتر ساعتی شکل) که توسط آن مقدار فشار از سطح دریا را اندازه‌گیری می‌نمایند. همچنین این پارامتر روی پدیده‌های اقلیمی تأثیر بسزایی دارد (Chen et al, 2012).

¹ Sea Surface Temperature

² Sea Level Pressure

۹-۱ هدف از انجام پایان نامه

با توجه به موارد فوق تحقیق حاضر در پی بررسی میزان همبستگی میان سیگنال‌های بزرگ‌مقیاس مانند شاخص‌های AO، ENSO، NAO، PDO و SOI و همچنین دما و فشار سطح دریاهای (SST و SLP) نقاط مختلف دنیا بر روی بارش و دبی متوسط و حدی ماهانه تعدادی از ایستگاه‌های باران‌سنجی و هیدرومتری حوضه آبریز مادرسو در استان گلستان و سپس پیش‌بینی مقادیر حداکثر بارش و دبی ماهانه حوضه آبریز مورد مطالعه می‌باشد؛ بنابراین در این پژوهش دو هدف اصلی زیر دنبال می‌شود:

۱- بررسی ارتباط بین سیگنال‌های بزرگ‌مقیاس اقلیمی و دبی و بارش ایستگاه‌های شاخص موجود در بالادست سد گلستان

۲- پیش‌بینی بارش و دبی با استفاده از روش‌های هوشمند با استفاده از سیگنال‌های بزرگ‌مقیاس اقلیمی

۱۰-۱ - بخش‌های مختلف پایان نامه

در فصل دوم این تحقیق به مروری بر کارهای انجام‌شده در زمینه بررسی همبستگی و همچنین پیش-بینی بارش و دبی که در سطح ایران و گستره‌ی جهانی انجام‌شده است، پرداخته شد. در فصل سوم به بررسی مواد و روش‌های به‌کاررفته در تحقیق شامل شبکه‌های عصبی چندلایه که در این فصل توضیح مختصری راجع به آن داده خواهد شد. فصل چهارم شامل منطقه تحقیق و داده‌های مورد استفاده در این تحقیق می‌باشد. فصل پنجم شامل نتایج به‌دست‌آمده از همبستگی بین سیگنال‌های اقلیمی و بارش و دبی حداکثر ماهانه منطقه تحقیق مورد مطالعه است. پس از به دست آوردن بهترین نتایج همبستگی در فصل ششم به بررسی نتایج حاصل از پیش‌بینی بارش و دبی حداکثر با توجه به

سیگنال‌های بزرگ‌مقیاس اقلیمی دارای همبستگی حداکثر با بارش و دبی، آورده شد.

فصل

۲

مروری بر تحقیقات گذشته

۱-۲ مقدمه:

رشد فزاینده جمعیت و به تبع آن افزایش نیازهای آبی از یک طرف و حجم محدود آب‌های شیرین در دسترس از طرفی دیگر، برنامه‌ریزی و مدیریت صحیح منابع آب را بیش‌ازپیش ضروری ساخته است. هدف از مدیریت منابع آب هماهنگ‌سازی الگوی توزیع زمانی و مکانی استحصال و نیازهای آبی می‌باشد. نیل به این هدف با بهره‌گیری توأم از روش‌های سازه‌ای و غیر سازه‌ای میسر است. در دهه‌های اخیر سازه‌های کنترل و استحصال آب و همچنین خطوط انتقال متعددی در سطح کشور ساخته شده و به بهره‌برداری رسیده‌اند. در سال‌های اخیر، هزینه‌های کلان تعریف و ساخت طرح‌های جدید و همچنین، محدودیت منابع آب موجود، موجب جهت‌گیری سیاست متولیان تأمین آب کشور به سمت افزایش کارایی سیستم‌های منابع آب در قالب روش‌های غیر سازه‌ای شده است. منبع اصلی تأمین آب شیرین در سیستم‌های منابع آب، نزولات جوی و به دنبال آن رواناب‌های سطحی است که اغلب توسط مخازن سطحی (سدها) و مخازن زیرزمینی (آبخوان‌ها) مهار و ذخیره شده و مورد استفاده قرار می‌گیرند. بارش و رواناب سطحی متغیرهای استوکستیک بوده و عدم قطعیت در تخمین آن‌ها، فرآیند برنامه‌ریزی و مدیریت بهینه منابع آب را برای متولیان و تصمیم‌گیرندگان دشوار می‌سازد. بسیاری از تکنیک‌ها و روش‌هایی که در برنامه‌ریزی و مدیریت منابع آب وجود دارد، ارتباط مستقیم یا غیرمستقیم با پیش‌بینی بارش، جریان و به‌طور کلی متغیرهای هیدروکلیماتولوژی دارند. وقوع سیلاب‌های ویرانگر و خشک‌سالی‌های متناوب و طولانی در سطح ایران، به همه فعالیت‌ها در مناطق شهری و روستایی آسیب می‌رساند و زمینه رکود اقتصادی، بیکاری و غیراقتصادی شدن بخش‌های مهم تولیدی را فراهم می‌آورد. به‌منظور کاهش آثار زیان‌بار مرتبط با خشک‌سالی و سیل، حجم زیادی از دامنه تحقیقات اقلیمی معطوف به شناخت برهم‌کنش عوامل آب و هوایی در خشکی، اقیانوس و جو شده است. قسمت عمده‌ای از تغییرات سالانه و فصلی بارش در ایران متأثر از تغییرات در سیگنال‌های هواشناسی می‌باشد که پیش‌بینی بارش و یا دبی رودخانه‌ها با توجه به این سیگنال‌ها برای هشدار سیلاب و یا

خشک‌سالی برای پیشگیری از خسارات وارده می‌تواند از لحاظ اقتصادی مفید باشد. مطالعات متعددی در زمینه پدیده‌های اقلیمی و تأثیرات آن‌ها روی آب‌وهوای مناطق مختلف دنیا و ایران و همچنین در رابطه با کاربرد مدل‌های هوشمند و ترکیب آن با روش‌های دیگر (مانند سیستم فازی-عصبی تطبیقی که ترکیبی از منطق فازی و شبکه عصبی است) در پیش‌بینی بارش و دبی در زمینه مهندسی منابع آب انجام گرفته است. در ادامه به تعدادی از این تحقیقات اشاره خواهد شد.

۲-۲ بررسی ارتباط سیگنال‌های پیوند از دور^۱ با بارش، سیل و خشک‌سالی در

نقاط مختلف

هیوز و ساندرز (۲۰۰۱) دما و بارندگی‌های ماهانه را برای یک دوره ۹۵ ساله روی منطقه اروپا بررسی نموده و از شاخص‌های Nino3,4 و شاخص نوسان جنوبی برای بررسی همبستگی با بارندگی استفاده کردند. در این پژوهش مشخص گردید که همبستگی بارندگی فصلی (دوره مارس، آوریل و می) با Nino3,4 فصلی (دوره دسامبر، ژانویه و فوریه) از همبستگی ماهانه و سالانه بیشتر است (Hughes and Saunders, 2002).

رودکار و کولکارنی (۲۰۰۸) به بررسی تأثیر انسو بر روی بارش‌های حدی زمستانه هند پرداختند. در این پژوهش از یک دوره آماری ۱۰۲ ساله برای مطالعه شاخص‌های حدی بارش استفاده شد. در این پژوهش فراوانی و شدت وقایع حدی بارش روند آماری معنی‌داری نداشت. ارتباط انسو با این وقایع حدی نشان داد که این شاخص می‌تواند برای تخمین فراوانی و شدت وقایع حدی بارش ۴ تا ۶ ماه زودتر به کار رود (Revadekar and Kulkarni, 2008).

جوچن و ولفگانگ (۲۰۰۶) نشان دادند که نوسانات دبی رودخانه‌ها در مناطق حاره‌ای با شاخص‌های انسو مانند شاخص نوسان جنوبی و تغییر دمای سطح آب در منطقه نینو ۳.۴، هماهنگی دارد. فاز گرم

^۱ Teleconnection Signals

این پدیده (النینو)، موجب افت سطوح سیلابی شده و برعکس فاز سرد (لانینا)، موجب افزایش دبی رودخانه‌ها و خیز سطوح سیلابی می‌گردد (Jochen and Wolfgang, 2007).

کاهایا و دراکوپ (۱۹۹۳) مطالعاتی جهت تعیین همبستگی بین وقوع پدیده النینو- نوسانات جنوبی و دبی رودخانه در ایالات متحده انجام دادند. آن‌ها نشان دادند وقوع پدیده النینو باعث افزایش دبی رودخانه‌ها در چهار منطقه ایالات متحده (خلیج مکزیکو، شمال غرب، شمال و شمال شرق) می‌شود (Kahya and Dracup, 1993).

انگل (۱۹۸۱) به بررسی همبستگی بین تغییرات دمای سطح دریا (SST) در شرق اقیانوس آرام استوایی با تغییرات در درجه حرارت جوی، گردش جوی، بارش باران پرداخت. نتایج حاصل از این تحقیق نشان‌دهنده‌ی همبستگی منفی و معنی‌داری را بین مقادیر SST شرق اقیانوس آرام و بارش فصلی کوئینزلند استرالیا است (Angell, 1981).

نیکولس (۱۹۸۹) نشان داد که تغییرات دمای سطح آب قسمت‌های اقیانوس هند و دریای عرب می‌تواند، به‌عنوان یک عامل مستقل، بخش قابل‌ملاحظه‌ای از واریانس بارش زمستانه در ایالت‌های مختلفی از استرالیا را توجیه نماید (Nicholls, 1989).

نیکلسون (۲۰۰۱) از آمار بارندگی ماهانه استاندارد شده ۱۲۲ ایستگاه در بوتسوانا و نواحی اطراف آن و شاخص‌های نینو ۳.۴ و شاخص نوسان جنوبی برای پیش‌بینی بارش استفاده نمودند. نتایج نشان داد که درجه حرارت سطح دریا برای پیش‌بینی خشک‌سالی محدودیت داشته و با توجه به همبستگی بهتر انسو با بارندگی، این شاخص پتانسیل بالاتری برای پیش‌بینی دارد (Nicholson et al, 2001).

پرالتا هرناوندز و همکاران (۲۰۰۹) در پژوهشی که به‌منظور بررسی تغییرات و روند شاخص‌های حدی بارش در ۴۴ ایستگاه در جنوب مکزیک انجام دادند به این نتیجه دست یافتند که تغییرات در وقایع

حدی بارش به طور معنی داری با انسو مرتبط بوده و فراوانی وقایع حدی در طی دوره لانینا تأثیر انسو را بر (فاز مثبت انسو) افزایش می دهد (Hernandez et al, 2009).

کارابوک و همکاران (۲۰۰۴) ارتباط بین متغیرهای اقلیمی ترکیه از جمله بارش، دبی سیلاب و ماکزیمم و مینیمم دما را با انسو بررسی کردند. نتایج حاصله نشان می دهد که ارتباطات مذکور خیلی قوی نیست و تنها رابطه معنی داری بین جریان و انسو در دوره زمستان مشاهده شد (Karabork et al, 2003).

گریم و همکاران (۱۹۹۸) تأثیر پدیده انسو را بر بارندگی در نواحی جنوبی برزیل در ۴ منطقه همگن بررسی کردند در این پژوهش مشخص گردید که در این مناطق بارندگی بهاره تحت تأثیر انسو می باشد کاهش بارندگی در دوران لانینا (ماه های اکتبر و نوامبر) و افزایش بارندگی در پاییز و زمستان در سه منطقه در دوران النینو وجود داشته است (Grimm et al, 1998).

ناظم السادات و کوردری (۲۰۰۰) نتیجه گرفتند که تغییرات دمای سطح آب در خلیج فارس، تأثیر معنی داری بر تغییرات بارندگی در مناطق جنوب و جنوب غربی ایران دارد. تحقیقات آنها روشن ساخت که بارش زمستانه (ژانویه تا مارس) مناطق موردنظر با دمای سطح دریا در خلیج فارس نسبت عکس دارد (Nazemosadat and Cordery, 2000).

مدرس پور (۱۳۷۶) در پژوهشی که به منظور بررسی پدیده انسو بر بارندگی و دمای ایران انجام داد به این نتیجه رسید که مناطق مختلف در فصول مختلف و هم زمان با شرایط النینو وضعیت مشابهی را تجربه نمی کنند و اندازه تأثیرپذیری بارندگی و دما با انسو از فصلی به فصلی و از مکانی به مکان دیگر متفاوت است (مدرس پور، ۱۳۷۶).

غیور و خسروی (۱۳۸۰) تأثیر پدیده انسو را بر ناهنجاری‌های بارش تابستان و پاییز منطقه جنوب شرق ایران بررسی نمودند و به این نتیجه رسیدند که خشک‌سالی پاییزه به‌طور عموم طی لائینا (فاز سرد) به وقوع می‌پیوندد (خسروی، ۱۳۸۰).

یاراحمدی و عزیزی (۱۳۸۶) در پژوهشی به بررسی ارتباط بین بارش در فصول پاییز، زمستان و بهار با شاخص‌های اقلیمی از طریق تحلیل رگرسیونی در ۲۵ ایستگاه سینوپتیکی ایران پرداختند. نتایج پژوهش آن‌ها نشان داده است که از میان شاخص‌های اقلیمی مرتبط با انسو، شاخص نینو ۳.۴، بیش‌ترین ارتباط را با میزان بارش پاییزه و زمستانه ایران دارد. همچنین ضریب ارتباط میزان بارش‌های پاییز و زمستان با شاخص Nino ۳.۴ مثبت است (یاراحمدی و عزیزی، ۱۳۸۶).

معتمدی و همکاران (۱۳۸۶) در پژوهشی که به‌منظور بررسی ارتباط از دور سیگنال هواشناسی انسو با نوسانات بارندگی و دما در استان خراسان انجام دادند، به این نتیجه رسیدند که بین شاخص نوسان جنوبی و مقادیر بارندگی و دما در سطح استان خراسان همبستگی وجود داشته و این همبستگی با شاخص نوسان جنوبی سالانه و فصلی منفی است؛ یعنی با افزایش مقادیر این شاخص مقادیر بارندگی و دما در استان خراسان در فصول و سال‌های مختلف کاهش می‌یابد (معتمدی و همکاران، ۱۳۸۶).

فلاح قاله‌ری (۱۳۹۰) به ارزیابی نقش تغییرات سیگنال‌های اقلیمی بر نوسان‌های بارش بهاره در استان خراسان رضوی پرداخت. با بررسی همبستگی به‌دست‌آمده بین بارش متوسط منطقه‌ای و سیگنال‌های هواشناسی شاخص در بازه‌های زمانی گوناگون، سیگنال‌های اقلیمی مؤثر بر آب‌وهوای استان خراسان رضوی مشخص شد که از این سیگنال‌ها می‌توان در مدل‌های پیش‌بینی بارش و همچنین تشخیص دوره‌های خشک، تر و نرمال استفاده کرد (قاله‌ری، ۱۳۹۰).

زارع ابیانه و بیات ورکشی (۱۳۹۱) به بررسی نقش پدیده‌های جوی- اقیانوسی انسو در تغییرپذیری تعداد روزهای بارانی کشور بر اساس اطلاعات ۳۰ ایستگاه همدید در یک بازه زمانی بلندمدت از بدو

تأسیس تا سال ۲۰۰۵ میلادی پرداختند. از شاخص‌های اقلیمی Nino 4, Nino 3.4, Nino 3, Nino 1+2 و SOI برای بررسی استفاده شد. به این منظور از شاخص‌های اقلیمی به‌عنوان متغیر مستقل استفاده شد. نتایج به‌دست‌آمده از به‌کارگیری روش تحلیل همبستگی پیرسون نیز بیانگر ارتباط بین شاخص‌های اقلیمی انسو و تعداد روزهای بارانی ایستگاه‌های همدید کشور بود. در بین ایستگاه‌های مورد مطالعه، بیش‌ترین میزان همبستگی تعداد روزهای بارانی با شاخص Nino 3 در ایستگاه سبزوار معادل ۰/۴۹ و کمترین میزان همبستگی معنی‌دار در ایستگاه‌های بوشهر و شیراز معادل ۰/۲۸ بود (زارع ابیانه و بیات ورکشی، ۱۳۹۱).

ناظم السادات و قاسمی (۱۳۸۳) به بررسی میزان تأثیر دمای سطح آب دریای خزر (SST) بر بارش فصلی نواحی شمالی و جنوب غربی ایران پرداختند. نتایج نشان داد، وقوع شرایط گرم در دمای دریای خزر عموماً موجب ۲۰ درصد کاهش در بارش فصل زمستان در سواحل دریای خزر زمستانه، تمام ایستگاه‌های مورد بررسی در نواحی ساحلی دریا نواحی شمالی استان‌های فارس و خوزستان می‌شود. همچنین در فاز گرم خزر با افزایش بارش بهاره همراه می‌باشند. بیش‌ترین تأثیر در بندر انزلی و آستارا دیده شد، به‌نحوی که وقوع فاز گرم دمای دریا موجب زمستانه منجر به کاهش بارش بهاره در ناحیه غربی دریای خزر ۸۰ درصد افزایش در بارش این دو ایستگاه و در مقابل وقوع شرایط سرد می‌شود (ناظم السادات و قاسمی، ۱۳۸۳).

حجازی زاده و همکاران (۱۳۹۲) در پژوهشی به بررسی ارتباط بارش با سیگنال‌های اقلیمی AO, ENSO, SOI, NAO در ناحیه مرکزی ایران پرداختند. داده‌های تحقیق آن‌ها به‌صورت ماهانه طی دوره‌ی آماری ۳۰ ساله، بین سال‌های ۱۹۷۸ تا ۲۰۰۸ بود. درنهایت با به‌کارگیری روش شبکه عصبی مصنوعی، مدل‌های شبیه‌سازی شده برای بازه‌های ۰، ۳ و ۶ ماهه محاسبه شد و نتایج نشان داد از بین سیگنال‌های مورد مطالعه سیگنال ENSO در مناطق Nino 1+2 و Nino 3 بر بارش منطقه مورد مطالعه تأثیر معنی‌داری دارد و تأخیر ۳ و ۶ ماهه موجب قوی شدن ضریب همبستگی شاخص

انسو در مناطق Nino 1+2 و Nino 3 با بارش ایستگاه‌های مورد مطالعه شده است. همچنین تأخیر ۶ ماهه باعث منفی شدن ضریب همبستگی بین شاخص انسو در مناطق Nino 1+2 و Nino 3 است. مطابق با مدل‌های ارائه شده، سیگنال انسو در مناطق Nino 1+2 و Nino 3 می‌تواند به عنوان پیش‌بینی کننده بارش در کنار سایر پارامترهای تأثیرگذار مورد استفاده قرار گیرد و سایر سیگنال‌های اقلیمی مورد مطالعه تأثیر معنی‌داری بر بارش ایستگاه‌های مورد مطالعه ندارد (حجازی زاده و همکاران، ۱۳۹۲).

۲-۳ پیش‌بینی دبی و بارش با استفاده از هوش مصنوعی^۱ با در نظر گرفتن

سیگنال‌های بزرگ مقیاس به عنوان ورودی

موکری و همکاران (۲۰۰۹) به پیش‌بینی سیلاب در رودخانه آجای در چهارخند در هندوستان پرداختند. آن‌ها از سه روش شبکه‌ی عصبی مصنوعی^۲ (ANN)، تفکیک‌های عصبی فازی^۳ (ANFIS) و شبکه عصبی-الگوریتم ژنتیک^۴ (ANGIS) استفاده کردند. در تحقیق آن‌ها از ۲۰ اتفاق بارش-رواناب استفاده شد که ۱۵ تای آن برای آزمایش و ۵ تا برای ارزیابی استفاده شد. نتایج حاصل از تحقیق آن‌ها نشان‌دهنده دقت بالای مدل ANGIS در پیش‌بینی واقعه سیل می‌باشد (Mukerji et al, 2009).

ویی و همکاران (۲۰۱۳) به پیش‌بینی جریان رودخانه ویهه در چین با روش ترکیبی عصبی-ویولت (WNN) پرداختند. در روش آن‌ها دو روش پیش‌بینی شبکه عصبی به تنهایی و شبکه عصبی-ویولت مقایسه شد. همچنین اطلاعات دبی سه ایستگاه با تأخیر ۴۸ ماهه استفاده شد. مقایسه نتایج پیش‌بینی روش‌های WNN و ANN نشان داد که روش ترکیبی عصبی مصنوعی-ویولت دقت بالاتری در پیش‌بینی دبی رودخانه دارد (Wei et al, 2013).

¹ Artificial Intelligence

² Artificial Neural Network

³ Adaptive Neuro-fuzzy Method

⁴ Artificial Neural Genetic Interface System

گامیز و همکاران (۲۰۱۰) به بررسی توانایی پیش‌بینی جریان رودخانه ایبرین بر اساس SST زمستان‌های قبل پرداختند. آن‌ها در تحقیق خود از مدل‌های میانگین متحرک سری زمانی (ARMA) استفاده کردند. همچنین از SST های مرکز و جنوب غربی اقیانوس اطلس بین سال‌های ۱۹۵۶ تا ۲۰۰۶ استفاده کردند. نتایج حاصل از تحقیق آن‌ها نشان‌دهنده‌ی آن است که مدل (4,3) ARMA و مدل SST به‌طور قابل‌توجهی می‌تواند پیش‌بینی جریان رودخانه در فصل بهار برای رودخانه مورد مطالعه را بهبود ببخشد (Gámiz et al, 2010).

رانهاو و همکاران (۲۰۱۱) با پیش‌بینی بارش ماهانه در کوه‌های دکینگ واقع در شمال چین با استفاده از روش‌های رگرسیون چندخطی پرداختند. در تحقیق آن‌ها از اطلاعات ۵۶ ایستگاه بین سال‌های ۱۹۵۵ تا ۱۹۹۰ استفاده شد. مقادیر MAE و RMSE به ترتیب ۱۰/۴۲٪ و ۱۳/۶۴٪ به دست آمد. نتایج نشان‌دهنده آن است که دقت مدل به مقادیر بارش و دقت وسایل سینوپتیک بستگی دارد. همچنین نتایج حاصل از این تحقیق و مدل‌سازی بارش می‌تواند در پژوهش‌های آب و هوایی هیدرولوژی در کوهستان مورد مطالعه، مورد استفاده قرار گیرد (Ranhao et al, 2011).

پارتال و کیسی (۲۰۰۷) پیش‌بینی بارندگی را به کمک مدل ترکیبی عصبی- فازی- تئوری موجک انجام دادند. این تکنیک درواقع تلفیقی از مدل عصبی- فازی و تئوری موجک است. تکنیک تئوری موجک سیگنال اصلی ورودی را به چند سیگنال کوچک تجزیه، سپس به‌عنوان ورودی وارد مدل تطبیقی عصبی- فازی می‌کند. در این مطالعه بارندگی مشاهده‌ای روزانه توسط این تکنیک به چند زیرگروه کوچک تجزیه‌شده سپس وارد مدل تطبیقی عصبی- فازی شد. در این مطالعه از بارندگی روزانه سه ایستگاه به‌عنوان ورودی مدل استفاده شد. نتایج حاصل از مدل ترکیبی عصبی- فازی و تئوری موجک بیانگر همخوانی خوب نتایج به‌دست‌آمده از شبیه‌سازی مدل با داده‌های مشاهده‌ای بود. مخصوصاً برای سری‌های زمانی که در ماه‌های تابستان دارای بارندگی صفر و حداکثر در دوره آزمون بود. نتایج حاصل از مقایسه مدل ترکیبی عصبی- فازی و تئوری موجک با مدل کلاسیک عصبی- فازی نشان داد

که نتایج به دست آمده به طور معنی داری بهتر از نتایج مدل تطبیقی عصبی - فازی است (Partal and Kişi, 2007).

عقیل و همکاران (۲۰۰۷) مزایای مدل تطبیقی عصبی - فازی و مدل شبکه عصبی مصنوعی را در مدل سازی پیوسته رفتار ساعتی و روزانه رواناب مورد ارزیابی قرار دادند. سه مدل مختلف بانام لونبرگ - مارکوف و شبکه عصبی پیش خور و مدل عصبی مثلثی پیش خور را طراحی و مورد ارزیابی قرار دادند. آن ها همچنین تأثیر تبدیل داده ها را بر اجرای مدل از طریق اجرای سه مدل طراحی شده با داده های خام و تبدیل شده انجام دادند. نتایج بیانگر خروجی رضایت بخش از مدل حاوی داده های تبدیل شده بود. ضمناً نتایج نشان داد که مدل تطبیقی عصبی - فازی بهتر از هر دو مدل دیگر اجرا شده و این قابلیت را به کاربر می دهد که به راحتی داده ها را پردازش کند و با استفاده از این تکنیک فرآیند بارش - رواناب را با انواع ورودی مورد آموزش و آزمون قرار دهد (Aqil et al, 2007).

فاتحی مرج و مهدیان (۱۳۸۸) به پیش بینی بارش پاییزه با استفاده از شاخص های انسو به روش شبکه عصبی در حوضه دریاچه ارومیه پرداختند. در تحقیق آن ها برای بررسی ارتباط بین انسو و بارش در حوضه دریاچه ارومیه واقع در شمال غرب کشور از اطلاعات ۱۸ ایستگاه باران سنجی و کلیماتولوژی و برای پیش بینی بارش پاییزه از اطلاعات دو ایستگاه سینوپتیک تبریز و ارومیه استفاده شد. برای پیش بینی بارش پاییزه از یک مدل توانمند و انعطاف پذیر مانند شبکه عصبی و اطلاعات SOI و Nino 3.4 استفاده و برای بررسی عملکرد آن با رگرسیون چند متغیره مقایسه گردید. نتایج بررسی آن ها نشان داد که مدل غیر خطی با استفاده از شاخص های اقلیمی مورد استفاده، بارش پاییزه را با دقت بیشتری پیش بینی می کنند. همچنین تحقیق آن ها نشان داد با استفاده از شاخص های اقلیمی پیوند از دور و به کارگیری شبکه عصبی با معماری مشخص می توان بارش پاییزه را یک فصل زودتر پیش بینی کرد (فاتحی مرج و مهدیان، ۱۳۸۸).

فتاحی و همکاران (۱۳۹۱) به پیش‌بینی جریان رودخانه‌های کارون شمالی با استفاده از شبکه عصبی مصنوعی پرداختند. هدف تحقیق آن‌ها بررسی امکان پیش‌آگاهی و پیش‌بینی دبی رودخانه‌های کارون شمالی (رودخانه ارمند و بازفت) با استفاده از روش‌های نوین شبیه‌سازی بود. در مطالعه آن‌ها نوسانات جریان رودخانه‌های ارمند و بازفت در ارتباط با سیگنال‌های بزرگ‌مقیاس اقلیمی بررسی شده است. بدین منظور از داده‌های ماهانه شاخص نوسان جنوبی (SOI)، نوسان اطلس شمالی (NAO) و پدیده انسو در مناطق Nino3.4، Nino1+2، Nino3 و Nino4 استفاده شد. مطالعه آن‌ها به‌منظور طراحی بهینه معماری شبکه عصبی مصنوعی جهت پیش‌بینی دبی رودخانه‌ها بر اساس سیگنال‌های اقلیمی از الگوریتم ژنتیک^۱ بهره گرفته شد. نتایج تحقیق نشان داد که سیگنال‌های انسو در ناحیه NINO1+2 و NINO3 به‌عنوان مؤثرترین سیگنال بر تغییرات جریان رودخانه‌های ارمند و بازفت هستند و برای پیش‌آگاهی از وضعیت دبی رودخانه‌های کارون شمالی می‌توان از سیگنال‌های فوق استفاده کرد (فتاحی و همکاران، ۱۳۹۱).

اژدری مقدم و همکاران (۱۳۹۱) به پیش‌بینی خشک‌سالی با استفاده از مدل فازی-عصبی، شاخص‌های اقلیمی، بارندگی و شاخص خشک‌سالی در زاهدان به‌وسیله متغیرهای ورودی مختلف پرداختند. این متغیرها عبارت‌اند از: بارندگی، مقادیر پیشین شاخص خشک‌سالی SPI و ۱۹ عدد از شاخص‌های اقلیمی. برای این منظور، میانگین سه‌ماهه اکتبر-نوامبر-دسامبر شاخص خشک‌سالی SPI به‌عنوان متغیر خروجی انتخاب شد. سپس هرکدام از متغیرهای ورودی یادشده، در تأخیرهای زمانی صفر، ۱، ۲ و ۳ ماهه (به ترتیب میانگین سه‌ماهه اکتبر-نوامبر-دسامبر، سپتامبر-اکتبر-نوامبر، اوت-سپتامبر-اکتبر و ژولای-اوت-سپتامبر) وارد مدل شدند. مدل‌های پیش‌بینی نیز با استفاده از مدل فازی-عصبی ANFIS توسعه داده شدند. بر اساس نتایج به‌دست‌آمده، در تأخیر زمانی صفر، بارندگی و شاخص اقلیمی Nino3 به ترتیب با ضرایب همبستگی ۰/۹۷ و ۰/۷۵ و خطاهای ۰/۱۳ و ۰/۳۳ مناسب‌ترین متغیرهای ورودی را تشکیل دادند؛ در تأخیر زمانی ۱ ماهه، بارندگی، شاخص

^۱ Genetic Algorithm

خشک‌سالی SPI و شاخص اقلیمی AMO به ترتیب با ضرایب همبستگی ۰/۶۷، ۰/۷۲، ۰/۶۵ و خطاهای ۰/۳۶، ۰/۳۵ و ۰/۳۹ بهترین متغیرهای ورودی را شامل شدند؛ در تأخیر زمانی ۲ ماهه، شاخص اقلیمی SOI با ضریب همبستگی ۰/۷۸ و خطای ۰/۳۱ به‌عنوان بهترین متغیر ورودی انتخاب شد و درنهایت در تأخیر زمانی ۳ ماهه، شاخص اقلیمی AMO با ضریب همبستگی ۰/۵۹ و خطای ۰/۴۲ مناسب‌ترین متغیر ورودی را تشکیل داد (اژدري مقدم و همکاران، ۱۳۹۱).

پوستی زاده و همکاران (۱۳۸۷) در تحقیقی با استفاده از سیستم استنتاج فازی و بر اساس دبی، درجه حرارت و بارش ماهانه، سری پیوسته‌ای از دبی جریان رودخانه و هر یک از متغیرهای مذکور تشکیل و تأثیر هر یک از متغیرهای فوق در توالی‌های زمانی گذشته بر روی میزان دبی جریان رودخانه در ماه‌های آینده بررسی و میزان دبی رودخانه در ماه‌های پیش‌بینی کردند. در این تحقیق آن‌ها با استفاده از سیستم استنتاج فازی و بر اساس میزان متوسط دبی از ۶ ماه قبل، مقدار متوسط دما در یک ماه قبل و مجموع بارش ۴ ماه قبل به پیش‌بینی دبی فروردین‌ماه در رودخانه بختیاری پرداختند. نتایج حاصل از تحقیق آن‌ها نشان داد که رگرسیون چند متغیره نشان‌دهنده‌ی نتایج مناسب‌تر نسبت به سیستم استنتاج فازی بود (پوستی زاده و همکاران، ۱۳۸۷).

صداقت کردار و فتاحی (۱۳۸۷) به بررسی شاخص‌های پیش‌آگاهی خشک‌سالی در ایران پرداختند. در تحقیق آن‌ها از داده‌های ماهانه‌ی شاخص نوسان جنوبی (SOI)، شاخص (NAO) و پدیده انسو در مناطق Nino3، Nino3.4، Nino4 و Nino1+2 استفاده شد. برای تعیین مهم‌ترین سیگنال‌های مؤثر بر بارش نواحی مختلف کشور از روش رگرسیون چند متغیره استفاده شد. نتایج تحلیل رگرسیونی نشان داد که تقریباً در تمامی ایستگاه‌های مورد مطالعه شاخص ENSO در مناطق Nino1+2، Nino3، پراهمیت‌ترین سیگنال در بارش می‌باشد. در این تحقیق با استفاده از شبکه‌ی عصبی مصنوعی، پیش‌بینی بارش برای بازه‌های زمانی همزمان، سه ماه و شش ماه بعد انجام گردید. تحلیل نتایج خروجی مدل شبکه عصبی با داده‌های مشاهده‌ای نشان داد که طی فاز گرم ENSO و فاز منفی

NAO شرایط ترسالی و طی فاز سرد انسو و مثبت NAO شرایط خشک‌سالی در سطح ایران به وقوع می‌پیوندد (صداقت کردار و فتاحی، ۱۳۸۷).

عراقی نژاد و کارآموز (۱۳۸۴) از مدل‌های مفهومی برای پیش‌بینی بلندمدت جریان رودخانه زاینده‌رود در محل ورودی به سد زاینده‌رود استفاده کردند. در تحقیقات آن‌ها، سیستم استنتاج فازی برای بارش فصلی به صورت عدد فازی و شبکه‌های عصبی مصنوعی برای شبیه‌سازی تبدیلات اطلاعات هیدروکلیماتولوژیکی به جریان رودخانه مورد استفاده قرار گرفته است. نتایج این تحقیق دلالت بر دقت قابل قبول روش ارائه شده در پیش‌بینی نقطه‌ای و بلندمدت جریان و امکان پیش‌بینی به صورت مجموعه‌ای از جریان‌های ممکن را داشت (عراقی نژاد و کارآموز، ۱۳۸۴).

فلاح قاله‌ری و همکاران (۱۳۸۸) با استفاده از سیستم استنتاج فازی ممدانی و شبکه‌های عصبی مصنوعی به پیش‌بینی بارش فصلی منطقه خراسان در بازه‌ی زمانی دسامبر تا می‌پرداختند. نتایج این تحقیق حاکی از آن است که سیستم استنتاج فازی و شبکه‌های عصبی مصنوعی می‌تواند بارش را با دقت قابل قبولی پیش‌بینی کنند. آن‌ها گزارش کردند که ریشه دوم میانگین مربعات خطا برای سیستم استنتاج فازی و شبکه‌های عصبی به ترتیب ۵۲ و ۴۱ میلی‌متر می‌باشد، بنابراین شبکه‌های عصبی مصنوعی در پیش‌بینی بارش موفق‌تر از مدل فازی بوده است (فلاح قاله‌ری و همکاران، ۱۳۸۸).

نبی زاده و همکاران (۱۳۹۱) به مقایسه عملکرد نمونه‌های مبتنی بر منطق فازی در پیش‌بینی آب دهی روزانه رودخانه ليقوان پرداختند. در تحقیق آن‌ها به منظور پیش‌بینی جریان روزانه رودخانه از سیستم‌های فازی و فازی-عصبی تطبیقی استفاده شده است. به این منظور، از سه پارامتر بارندگی، دما و دبی روزانه حوضه آبریز ليقوان چای برای پیش‌بینی جریان روزانه رودخانه ليقوان، استفاده شد. برای تعیین مدل‌های بهینه ورودی به سیستم‌ها، همبستگی نگار داده‌ها مورد بررسی قرار گرفت. پیش‌بینی در دو بخش ترکیبی و پیش‌بینی بر اساس دبی روزهای قبل انجام شد. ارزیابی نتایج پیش‌بینی‌ها با استفاده از معیارهای گوناگون از جمله معیار ناش-ساتکلیف نشان‌دهنده دقت بیشتر مدل ANFIS

در پیش‌بینی بود. همچنین با بررسی دو بخش طراحی‌شده، مشخص شد که به‌طور کلی، در بررسی دوره‌های سالیانه، دما در پیش‌بینی جریان روزانه این رودخانه تأثیر چندانی نداشت و بارندگی روز جاری مؤثرتر از دبی دو روز قبل در پیش‌بینی جریان روزانه بود (نبی زاده و همکاران، ۱۳۹۱).

آچاریا و همکاران (۲۰۱۱) یک مدل برای پیش‌بینی بارش‌های موسمی تابستانه هند با استفاده از سیگنال‌های بزرگ‌مقیاس اقلیمی به وجود آوردند. آن‌ها از شاخص دمای سطح دریا برای پیش‌بینی به روش‌های رگرسیون چندخطی و شبکه عصبی استفاده کردند. نتایج تحقیق آن‌ها نشان داد که روش شبکه عصبی مصنوعی کارایی بهتری در پیش‌بینی نسبت به روش رگرسیون چندخطی دارد (Acharya et al, 2011).

فرخ نیا و همکاران (۲۰۱۱) به بررسی کارایی داده‌های دما و فشار سطح دریا در پیش‌بینی خشک‌سالی منطقه‌ی تهران و با استفاده از داده‌کاوی و تکنیک فازی عصبی- تطبیقی (ANFIS) پرداختند. آن‌ها در ابتدا SST و SLP هایی که بیش‌ترین تأثیر را بر خشک‌سالی منطقه داشتند را پیدا کرده و سپس به‌عنوان ورودی ANFIS مورد استفاده قرار دادند. نتایج تحقیق آن‌ها نشان داد که بیشتر از ۹۰ درصد موارد تکنیک ANFIS شاخص‌های خشک‌سالی را با $R^2 = 0/62$ و $RMSE = 0/58$ در ماه ژوئن به‌درستی پیش‌بینی کرده است (Farokhnia et al, 2010).

۴-۲ جمع‌بندی:

همان‌طور که مطالعات پژوهشگران نشان داد سیگنال‌های اقلیمی به‌عنوان متغیر پیش‌بینی‌کننده در بارش، خشک‌سالی، سیل و ... مورد استفاده قرار می‌گیرند و تأثیر این سیگنال‌ها در مناطق مختلف متفاوت است. تاکنون تأثیر این سیگنال‌ها در حوزه آبریز بالادست سد گلستان مورد مطالعه جدی قرار نگرفته و از طرفی پیش‌آگاهی بارش با روش‌های نوین و پیشرفته در این منطقه به‌خاطر کمبود منابع آب و اینکه مسئله تأمین آب با بحران جدی روبه‌روست و نیاز به مدیریت بهینه دارد امری ضروری و بااهمیت است. از این‌رو هدف اصلی این پژوهش بررسی میزان تأثیر بر بارش و دبی حوضه آبریز

مطالعاتی و درنهایت ارائه مدل پیش‌بینی بارش و دبی با استفاده از سیگنال‌های بزرگ‌مقیاس اقلیمی و
روش‌های هوش محاسباتی می‌باشد.

فصل

۳

مواد و روش‌ها

مدیریت منابع آب امری پیچیده است. با توجه به محدود و ثابت بودن منابع آب نحوه مدیریت برای بالا بردن راندمان استفاده از منابع آب بسیار مهم می‌باشد. رودخانه‌ها از مهم‌ترین منابع تأمین آب شیرین می‌باشند. در مناطق جنوبی ایران، به علت بارش و ضریب تغییرات بالای بارش، نبود مدیریتی صحیح بر منابع آبی، خسارات جبران‌ناپذیری را به دنبال خواهد داشت. همچنین موقعیت جغرافیایی ایران در منطقه جنب حاره باعث قرار گرفتن آن در کمربند خشک جهان گردیده است. با توجه به تبعات اقتصادی و اجتماعی بسیار بالای ناشی از نوسانات بارش هم در دوره‌های خشک‌سالی و هم در دوره‌های تر (سیلاب‌ها و طغیان رودخانه‌ها) شناخت عوام مؤثر در ایجاد شرایط مذکور می‌تواند نقش قاب ملاحظه‌ای را در پیش‌بینی دوره‌های پرباران و کم باران و در نتیجه برنامه‌ریزی‌های دقیق‌تر اقتصادی داشته باشد. قسمت عمده‌ای از تغییرات سالانه و فصلی بارش در ایران متأثر از تغییرات در سیگنال‌های هواشناسی می‌باشد که پیش‌بینی بارش و یا دبی رودخانه‌ها با توجه به این سیگنال‌ها در به وجود آوردن سیستمی برای هشدار سیلاب و یا خشک‌سالی برای پیشگیری از خسارات وارده می‌تواند از لحاظ اقتصادی مفید باشد. با توجه به پیچیدگی و عدم قطعیت متغیرهای هواشناسی شامل بارش و ... به دست آوردن مدلی برای پیش‌بینی متغیرهای آب- هواشناسی مسئله مهمی است. از سوئی دیگر محققین با ابداع و پیشرفت علمی چون روش‌های هوشمند که ابزاری توانمند و انعطاف‌پذیر و مستقل از مدل‌های دینامیکی سیستم هستند، در جست‌وجوی راه‌هایی برای پیشرفت در شناخت و پیش‌بینی پارامترهای مهم هواشناسی می‌باشند (خلیلی و همکاران، ۱۳۸۷). یکی از مؤلفه‌های هوش مصنوعی شبکه‌های عصبی هستند که با توجه به توانایی آن‌ها در محاسبه و تقریب هر تابع حسابی و منطقی، مورد توجه محققان قرار گرفته است. لذا، در سال‌های اخیر، محققان از جمله خلیلی و همکاران (۱۳۸۷)، اصغری مقدم و همکاران (۱۳۸۷)، اسفندیاری درآباد و همکاران (۱۳۸۹) در ایران با استفاده از تکنیک‌های جدید، به بررسی و پیش‌بینی پدیده‌های هواشناسی به‌تنهایی و یا با ترکیبی از

شاخص‌های اقلیمی پرداخته‌اند. شبکه‌های عصبی مصنوعی در دو دهه‌ی اخیر به‌عنوان یکی از پرکاربردترین روش‌ها در پیش‌بینی توسط محققین مختلف استفاده‌شده است (Ghalkhani et al, 2009; Modarres, 2013). از توانایی‌های این روش می‌توان به مدل‌سازی مسائل پیچیده غیرخطی اشاره کرد. همچنین در شبکه عصبی مصنوعی نیاز به اطلاعاتی از قبیل ایستا بودن داده‌ها، داشتن یا نداشتن توزیع یکنواخت داده‌ها یا اینکه بین داده‌های ورودی چه ارتباطی وجود دارد، نیست (Kisi and Cigizoglu, 2007). اگرچه مراحل مدل‌سازی در شبکه عصبی مصنوعی نیاز به اطلاعات زیادی در مورد مشخصه‌های هیدرولوژیکی ندارد، اما شبکه عصبی خوب آموزش‌دیده می‌تواند به‌راحتی در موضوعات منابع آبی اعمال شود. مزایای توسعه‌ی یک شبکه عصبی خودآموزش بودن، خود سازمانده بودن و خود تطبیق بودن است. بسیاری از مطالعات ثابت کردند که مدل‌های شبکه عصبی عملکرد خوبی در پیش‌بینی دارند هرچند که سری‌های زمانی هیدرولوژیکی با مشخصات غیرخطی بودن زیاد و غیر ایستا بودن شناخته می‌شوند (Wei et al, 2013).

هدف اصلی این تحقیق، بررسی امکان پیش‌بینی بارش و دبی حداکثر ماهانه در حوضه سد گلستان با استفاده از کاربرد روش‌های نوین مطرح در امر شبیه‌سازی و پیش‌بینی می‌باشد. در این تحقیق پس از بررسی میزان همبستگی سیگنال‌های بزرگ‌مقیاس اقلیمی و میزان دبی و بارش حوضه آبریز مطالعاتی سیگنال‌های دارای بیش‌ترین مقادیر همبستگی با بارش و دبی حداکثر ماهانه شناسایی شد. همچنین سعی شده است با لحاظ کردن سیگنال‌های بزرگ‌مقیاس اقلیمی و با به‌کارگیری شبکه‌های عصبی مصنوعی امکان پیش‌بینی بارش و دبی حداکثر ماهانه حوضه آبریز مطالعاتی مورد ارزیابی قرار گیرد.

۳-۲ ضریب همبستگی

ضریب همبستگی ابزاری آماری برای تعیین نوع و درجه رابطه یک متغیر کمی با متغیر کمی دیگر است. ضریب همبستگی، یکی از معیارهای مورد استفاده در تعیین همبستگی دو متغیر است. ضریب همبستگی شدت رابطه و همچنین نوع رابطه (مستقیم یا معکوس) را نشان می‌دهد. این ضریب بین ۱

تا ۱- است و در عدم وجود رابطه بین دو متغیر، برابر صفر است. در این تحقیق از ضریب همبستگی پیرسون برای بررسی ارتباط میان سیگنال‌ها و بارش و دبی حوضه مطالعاتی استفاده شد.

۳-۲-۱ ضریب همبستگی پیرسون^۱

ضریب همبستگی پیرسون که به نام‌های ضریب همبستگی گشتاوری و یا ضریب همبستگی مرتبه‌ی صفر نیز نامیده می‌شود، توسط سر کارل پیرسون معرفی شده است. این ضریب به منظور تعیین میزان رابطه، نوع و جهت رابطه‌ی بین دو متغیر فاصله‌ای یا نسبی و یا یک متغیر فاصله‌ای و یک متغیر نسبی به کار برده می‌شود. ضریب همبستگی پیرسون که به نام‌های ضریب همبستگی گشتاوری و یا ضریب همبستگی مرتبه‌ی صفر نیز نامیده می‌شود. این ضریب از رابطه زیر به دست می‌آید (زارع ابیانه و بیات ورکشی، ۱۳۹۱):

$$r = \frac{n(\sum xy) - (\sum x)(\sum y)}{\sqrt{n(\sum x^2) - (\sum x)^2} \sqrt{n(\sum y^2) - (\sum y)^2}} \quad ۱-۳$$

در روابط بالا X و Y متغیرهای مورد بررسی، n تعداد داده‌ها می‌باشد. ضریب همبستگی پیرسون بین ۱- و ۱ تغییر می‌کند. اگر $r = 1$ باشد، بیانگر رابطه‌ی مستقیم و کامل بین دو متغیر است، رابطه‌ی مستقیم یا مثبت به این معناست که اگر یکی از متغیرها افزایش (کاهش) یابد، دیگری نیز افزایش (کاهش) می‌یابد. $r = -1$ نیز وجود یک رابطه‌ی معکوس و کامل بین دو متغیر را نشان می‌دهد. رابطه‌ی معکوس یا منفی نشان می‌دهد که اگر یک متغیر افزایش یابد، متغیر دیگر کاهش می‌یابد و بالعکس، زمانی که ضریب همبستگی برابر صفر است نشان می‌دهد که بین دو متغیر رابطه‌ی خطی وجود ندارد.

^۱ Pearson product moment correlation

صفر بودن ضریب همبستگی تنها عدم وجود رابطه‌ی خطی بین دو متغیر را نشان می‌دهد. سپس مقدار P-Value نیز محاسبه شد که در سطح معنی‌داری ۰/۰۵ مبنای پذیرش یا عدم پذیرش همبستگی بین متغیرهاست. به بیان دیگر قبول یا رد فرض اولیه H_0 مقایسه با مقدار ۰/۰۵ هست. در آزمون‌های یک دامنه اگر P-Value کوچک‌تر از ۰/۰۵ باشد، فرض اولیه H_0 (عدم همبستگی) رد می‌شود و اگر $P\text{-Value} > 0.05$ فرض اولیه رد نمی‌شود؛ اما در آزمون‌های دو دامنه به جای ۰/۰۵ از ۰/۰۲۵ استفاده می‌شود. به طور مثال اگر بخواهیم همبستگی بارش یک ایستگاه خاص را با یکی از سیگنال‌های هواشناسی در یک منطقه را با فرض اولیه همبستگی آن شاخص با بارش آن ایستگاه خاص در سطح معنی‌داری ۰/۰۵ بررسی کنیم برای P-value های بزرگ‌تر از ۰/۰۵ این فرض اولیه رد می‌شود.

همچنین برای مقایسه داده‌های بارش و دبی در مقابل داده‌های شاخص‌های هواشناسی، همه داده‌ها استاندارد شدند. در این تحقیق برای استانداردسازی و تبدیل داده‌ها از رابطه زیر استفاده شد:

$$Z = \frac{x - \bar{x}}{S} \quad ۲-۳$$


که در آن x مقدار اولیه (تغییرنیافته)، $\bar{x}$ میانگین داده‌ها و S انحراف معیار آن‌هاست.

۳-۳ شبکه عصبی مصنوعی

شبکه عصبی مصنوعی سیستم پردازش موازی و هوشمند اطلاعات بوده و دارای عملکردی شبیه نرون‌های عصبی مغز انسان است (Haykin, 1994). این شبکه با داده‌های موجود طی فرایند یادگیری آموزش‌دیده و جهت پیش‌بینی در آینده مورد استفاده قرار می‌گیرد و با تجزیه و تحلیل شرایط، محدودیت‌ها و پارامترهای دخیل در یک فرایند؛ تصمیم بهینه را اتخاذ کرده و این فرایند را به حدی تکرار می‌کند که ضرایب هر یک از پارامترها اپتیمم شده و با واقعیت موضوع تطابق بسیار نزدیکی پیدا

کنند (عبقری، ۱۳۸۴). شبکه‌های عصبی مصنوعی در سال ۱۹۴۳ میلادی توسط مک کلاچ و پیتز با ساختن یک شبکه ساده متشکل از چندین نرون ساده مصنوعی، به دنیای علم معرفی شد (منهاج، ۱۳۸۴). در سال ۱۹۴۹ هب اولین قانون آموزش برای شبکه‌های عصبی مصنوعی را مطرح کرد. در محدوده سال‌های ۱۹۵۸ تا ۱۹۶۲ روزنبلات گروه بزرگی از شبکه‌های عصبی به نام پرسپترون را معرفی نمود. شبکه‌های عصبی تابع بنیادی شعاعی در دهه ۹۰ میلادی معرفی شدند (نوری، ۱۳۸۵). پردازش موازی؛ باعث افزایش سرعت پردازش‌شده و احتمال خطا را در آن تا حد ممکن کاهش می‌دهد به‌طوری‌که تعداد زیادی نرون ساده به‌صورت مشترک پردازش را به عهده می‌گیرند و وظیفه کلی پردازش بین پردازنده‌های کوچک‌تر مستقل از هم توزیع می‌گردد. یکی از محاسن این روش این است که اگر یکی از نرون‌ها نتواند به سمت پاسخ درست حرکت کند سهم آن در کل سیستم چندان حائز اهمیت نیست (البرزی، ۱۳۸۳). این ویژگی به دلیل این‌که همواره در اطلاعات و آمار هیدرولوژیکی امکان خطا در اندازه‌گیری‌ها موجود است، بسیار بااهمیت و کارساز است. درواقع شبکه داده‌های ورودی راجع به هر موضوع را می‌تواند با یک سری تجزیه و تحلیل‌های منطقی که با یافته‌های موجود برقرار می‌سازد به‌عنوان نمونه در نظر گرفته و با به‌کارگیری ارتباط بین این داده‌های ورودی و یافته‌ها روابطی که ممکن است غیرخطی و نامشخص هم باشند به وجود آورده و با استفاده از این ارتباط منطقی به وجود آمده، می‌تواند کار شبیه‌سازی را برای موارد احتمالی مشابه انجام دهد. شبکه‌های عصبی به دودسته کلی پیش‌خور و پس‌خور تقسیم می‌شوند که برای تحقیقات هیدرولوژی شبکه‌های پیش‌خور توصیه‌شده است (Haykin, 1994). ساختار کلی شبکه عصبی مصنوعی در شکل (۱-۳) نشان داده‌شده است. این لایه‌ها وظیفه دریافت داده‌ها، پردازش و تولید کمیت خروجی را به عهده‌دارند. لایه‌های ورودی فاقد نرون بوده و لایه ایست که متغیرهای ورودی را به نرون‌های لایه مخفی انتقال می‌دهد. عموماً تعداد نرون‌ها در این لایه تابعی از تعداد متغیرهای ورودی به شبکه است. لایه مخفی دارای یک یا چند نرون بوده و تعداد لایه‌های مخفی می‌تواند یک یا چند لایه باشند و لایه

خروجی دارای یک یا چند نرون بوده و تعداد نرون‌های آن تابعی از تعداد خروجی است. تمام لایه‌های شبکه توسط اتصالاتی با وزن‌های متفاوت به هم متصل هستند.



شکل ۳-۱: ساختار کلی شبکه عصبی مصنوعی

۳-۴ مدل ریاضی نرون‌های عصبی

میزان یادگیری در انتقال سیگنال‌های ورودی به نرون‌ها را می‌توان با استفاده از ضربی که در ورودی‌های نرون ضرب می‌شود، مدل‌سازی کرد (البرزی، ۱۳۸۳). رابطه ریاضی شبکه عصبی اولین بار در سال ۱۹۴۳ میلادی توسط مک کلاچ و پیتز ارائه گردید (نبی زاده و همکاران، ۱۳۹۱) (روابط ۳-۳ و ۴-۳) و شکل (۳-۲)؛ اما در این مدل روند آموزشی ارائه نشد. در سال ۱۹۴۹ هب الگوریتم ساده‌ای را برای آموزش شبکه عصبی پیشنهاد داد که بر اساس آن با تغییر وزن‌ها نتایج شبکه بهینه گردید (رابطه ۳-۳). علی‌رغم به‌کارگیری یک ساختمان ساده از این مدل، سرعت و قدرت محاسباتی آن به‌شدت موردتوجه قرار گرفت. نحوه کار در این نرون به این صورت است که ورودی اسکالر x در وزن اسکالر w ضرب می‌شود و به واحد جمع کننده فرستاده می‌شود و ورودی دیگر که یک می‌باشد در بایاس b ضرب شده و به واحد جمع کننده می‌رود. خروجی واحد جمع کننده n ، معمولاً ورودی خالص نامیده می‌شود و به قسمت تابع انتقال ϕ می‌رود و در آنجا خروجی اسکالر y تولید می‌شود (نوری، ۱۳۸۵).

۳-۳

$$n = \sum_{i=1}^N x_i w_{1,i} + b = xw + b$$


۴-۳

$$y = f\left(\sum_{i=1}^N w_i x_i - b_i\right)$$

که در آن x_i ورودی‌ها، w_i وزن‌ها، b_i آستانه یا اریب؛ $\varphi(0)$ تابع تحریک یا المان پردازش که توسط کاربر انتخاب می‌گردد و y سیگنال خروجی نرون.

۵-۳

$$\Delta w_i(n) = \mu y(n) x_i(n)$$



شکل ۳-۲: شبکه عصبی مک کلاچ - پیترز

روزنبلات در سال ۱۹۵۸ با مقایسه جواب‌های شبکه و نتایج مطلوب و برآورد مقادیر خطا فرایند آموزش شبکه را با بروز رسانی ضرایب وزنی به‌صورت رابطه (۳-۶) ارائه داد.

۶-۳

$$\Delta w_{ij}(n) = \mu [d_i(n) - y_i(n)] x_j(n)$$

که در آن m ، $i=1,2,3,\dots$ ورودی‌های شبکه، $j=1,2,3,\dots$ خروجی‌ها و d_i جواب مطلوب.

پارامترهای w و x قابل تنظیم بوده و تابع φ (تابع متحرک) نیز توسط کاربر انتخاب می‌گردد. با انتخاب یک توپولوژی مناسب یا همان توپولوژی بهینه شبکه، یعنی قرار دادن اصولی و صحیح تمامی اجزا و معرفی تابع محرک و قانون آموزش مناسب آن، می‌توان شبکه را در راستای دستیابی به هدف موردنظر آموزش داد و رفتار و پاسخ مطلوبی دریافت نمود (منهاج، ۱۳۸۴).

۳-۵ الگوریتم پس انتشار خطا^۱

همچنان که قبلاً گفتیم در شبکه‌های چندلایه، خروجی یک‌لایه؛ ورودی لایه بعد می‌باشد. رابطه زیر این عمل را نشان می‌دهد.

۷-۳

$$a^{m+1} = f^{m+1}(W^{m+1}a^{m+1} + b^{m+1}) \quad m=0,1,\dots,m-1$$

که در این رابطه a خروجی لایه، f تابع انتقال لایه، W ماتریس وزن لایه، b بردار بایاس لایه و m تعداد لایه‌های شبکه است. فرآیندی را که رابطه (۳-۸) نشان می‌دهد انتشار به جلو گویند. ورودی نرون‌های لایه اول، بردار ورودی شبکه می‌باشد، یعنی:

۸-۳

$$a^0 = p$$

^۱ Backpropagation Algorithm

این رابطه منشأ و سرآغاز رابطه (۹-۳) می‌باشد، خروجی‌های نرون‌های لایه آخر، بردار خروجی شبکه را تشکیل می‌دهند.

۹-۳

$$a = a^m$$

در الگوریتم پس از انتشار خطا برای شبکه‌های چندلایه از تابع هدف میانگین مربعات خطا (MSE) یا مجموع مربعات خطا (SSE) استفاده می‌شود. الگوریتم باید پارامترهای شبکه را به گونه‌ای تنظیم کند که شاخص کارایی به کمترین مقدار ممکن برسد. مقدار خطای شبکه، اختلاف بین مقادیر واقعی ثبت‌شده و خروجی تخمینی شبکه است. پس می‌توانیم یک رابطه برای تابع خطا به صورت زیر بنویسیم:

۱۰-۳

$$F(x) = E[e^2] = E[(t - a)^2] = E[(t - X^T Z)^2]$$

که در این رابطه $F(x)$ خطای مربع میانگین، e اختلاف بین ورودی و هدف و $E[e^2]$ امید ریاضی بر روی کل مجموعه ورودی و هدف می‌باشد. اگر شبکه چندین خروجی داشته باشد در حالت کلی می‌نویسیم:

۱۱-۳

$$F(x) = E[e^2 e] = E[(t - a)^T (t - a)]$$

ویدر و هاف مربع میانگین را از رابطه زیر تقریب زدند:

۱۲-۳

$$\hat{F}(x) = (t(k) - a(k))^T (t(k)) = e^T(k) e(k)$$

که در آن امید ریاضی خطای مربع با خطای مربع در تکرار x ام جایگزین شده است. از این رابطه وزن ها و بایاس ها به صورت زیر تنظیم می شوند:

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha \frac{\partial \hat{F}}{\partial w_{i,j}^m} \quad ۱۳-۳$$

۱۴-۳

$$b_i^m(k+1) = b_i^m(k) - \alpha \frac{\partial \hat{F}}{\partial b_i^m}$$

که در آن α نرخ یادگیری می باشد.

از روابط اخیر تحت عنوان الگوریتم سریع ترین کاهش نیز یاد می شود و برای محاسبات مشتقات جزئی روابط (۱۵-۳) و (۱۶-۳) از قاعده زنجیری استفاده می شود.

در شبکه های چندلایه، مقدار خطا در لایه های مخفی تابعی صریح از وزن ها نیست، لذا مشتقات به راحتی قابل محاسبه نیستند. به همین دلیل از قاعده زنجیری برای محاسبه مشتقات استفاده می کنیم. برای توضیح قاعده زنجیری فرض می کنیم که تابعی مانند f داشته باشیم که تابعی صریح از متغیر n باشد. می خواهیم مشتق f را نسبت به متغیر سومی مانند w حساب کنیم (Fausett, 1993). قاعده زنجیری به صورت ذیل است:

۱۵-۳

$$\frac{d(n(w))}{dw} = \frac{df(n)}{dn} \times \frac{dn(w)}{dw}$$

از این مفهوم برای محاسبه مشتق در روابط (۱۳-۳) و (۱۴-۳) استفاده می‌کنیم.

۱۶-۳

$$\frac{\partial \hat{F}}{\partial w_{i,j}^m} = \frac{\partial \hat{F}}{\partial n_i^m} \times \frac{\partial n_i^m}{\partial w_{i,j}^m}$$

۱۷-۳

$$\frac{\partial \hat{F}}{\partial b_i^m} = \frac{\partial \hat{F}}{\partial n_i^m} \times \frac{\partial n_i^m}{\partial b_i^m}$$

ورودی خالص لایه m که با n^m نشان می‌دهیم، یک تابع صریح از وزن‌ها و بایاس‌های آن لایه می‌باشد؛ یعنی:

۱۸-۳

$$n_i^m = \sum_{j=1}^{i^{m-1}} w_{i,j}^m a_j^{m-1} + b_i^m$$

لذا بخش دوم معادلات (۱۶-۳) و (۱۷-۳) می‌تواند به راحتی به صورت زیر محاسبه شود:

۱۹-۳

$$\frac{\partial n_i^m}{\partial b_i^m} = 1 \quad , \quad \frac{\partial n_i^m}{\partial w_{i,j}^m} = a_j^{m-1}$$

اگر شاخصی به اسم حساسیت به صورت:

۲۰-۳

$$s_i^m = \frac{\partial \hat{F}}{\partial n_i^m}$$

تعریف نماییم، می‌توانیم رابطه را بر اساس آن به شکل زیر بازنویسی کنیم:

۲۱-۳

$$\frac{\partial \hat{F}}{\partial n_i^m} = s_i^m \times a_j^{m-1}$$

۲۲-۳

$$\frac{\partial \hat{F}}{\partial b_i^m} = s_i^m$$

که s_i^m شاخص حساسیت می‌باشد. اکنون می‌توان الگوریتم آموزش را به صورت زیر بیان کرد:

۲۳-۳

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha \times s_i^m \times a_j^{m-1}$$

۲۴-۳

$$b_i^m(k+1) = b_i^m(k) - \alpha \times s_i^m$$

نوشتار ماتریسی این روابط به صورت زیر است:

۲۵-۳

$$w^m(k+1) = w^m(k) - \alpha \times s^m \times a^{m-1}$$

$$b^m(k+1) = b^m(k) - \alpha \times s^m$$

۲۶-۳

که S^m به صورت زیر می باشد:

$$S^m = \frac{\Delta \hat{F}}{\Delta n^m} = \begin{bmatrix} \frac{\Delta \hat{F}}{\Delta n_1^m} \\ \frac{\Delta \hat{F}}{\Delta n_2^m} \\ \cdot \\ \cdot \\ \cdot \\ \frac{\Delta \hat{F}}{\Delta n_n^m} \end{bmatrix} \quad ۲۷-۳$$

۳-۵-۱ انتشار به عقب حساسیت ها

اکنون باید حساسیت ها محاسبه شوند که به بخش دیگری از قاعده زنجیری نیاز دارد و سپس با گسترش آن به سمت ورودی شبکه، پارامترهای شبکه تنظیم شوند. چون در این فرآیند یک عملیات برگشتی انجام می گیرد که بر اساس آن حساسیت لایه m از حساسیت لایه $m+1$ محاسبه می شود، تین فرآیند باعث شده که اسم این نوع شبکه ها انتشار برگشتی باشد.

۲۸-۳

$$S^m = F^m(n^m).(W^{m+1})^T . S^{m+1}, m=1,2,...,m-1$$

بدین ترتیب، حساسیت ها از لایه آخر به سمت لایه اول، به سمت عقب انتشار پیدا می کند:

۲۹-۳

$$S^m \rightarrow S^{m-1} \rightarrow \dots \rightarrow S^2 \rightarrow S$$

پیچیدگی الگوریتم انتشار برگشتی فقط در این می‌باشد که برای محاسبه گرادیان‌ها لازم است ابتدا حساسیت‌ها را به سمت عقب انتشار دهیم. هنوز چند گام دیگر برای تکمیل الگوریتم باقی مانده است. ما نیاز داریم برای اجرای رابطه بازگشتی نقطه شروع یعنی S^m را داشته باشیم که از لایه آخر به دست می‌آید:

۳۰-۳

$$s_i^m = \frac{\partial \hat{F}}{\partial n_i^m} = \frac{\partial (t-a)^T (t-a)}{\partial n_i^m} = -2(t_i - a_i) \frac{\partial a_i}{\partial n_i^m}$$

که در آن:

۳۱-۳

$$\frac{\partial a_i}{\partial n_i^m} = \frac{\partial a_i^m}{\partial n_i^m} = \frac{\partial f^m(n_i^m)}{\partial n_i^m} = f'(n_i^m)$$

رابطه (۳۱-۳) را می‌توان با توجه به رابطه (۳۲-۳) به صورت زیر نوشت:

۳۲-۳

$$s_i^m = -2(t_i - a_i) f'(n_i^m)$$

این رابطه را می‌توان به شکل ماتریسی به شکل زیر نوشت:

۳۳-۳

$$s^m = -2(t-a) f'(n^m)$$

اکنون الگوریتم پس از انتشار خطا کامل شده است و با توجه به اختلاف بین بردار خروجی شبکه و بردار خروجی واقعی، خطای شبکه محاسبه شده و مقدار وزن‌ها اصلاح می‌گردد. این تنظیم بر اساس قانون آموزش اصلاح خطا و یا قانون آموزش دلتا انجام می‌شود. عمل اصلاح وزن‌ها از محل اتصال لایه خروجی شروع شده و سپس در لایه میانی (پنهان) صورت می‌گیرد. لایه آخر بعد از آن اصلاح شده و مجدد لایه میانی با توجه به وزن‌های جدید اصلاح می‌شود. وزن‌ها و بایاس‌ها در هر مرحله از انتشار خطاها و حساسیت‌ها به عقب تنظیم می‌گردد. به هر یک از مراحل تکرار الگوریتم یک ϵ می‌گویند و تا زمانی که اختلاف بین خروجی شبکه و مقدار هدف به حد قابل قبول برسد، تکرارها ادامه می‌یابد (حجازی زاده و همکاران، ۱۳۹۲). در این وضعیت وزن‌ها ثابت مانده و شبکه آموزش دیده و آماده مدل‌سازی ورودی‌های جدید است. پس از مرحله آموزش، با معرفی هر بردار ورودی شبکه، خروجی متناظر آن به دست می‌آید که مرحله آزمون شبکه نام دارد و با آن میزان دقت شبکه تعیین می‌گردد.

۳-۶ توابع محرک (توابع انتقال)


در تمامی شبکه‌های عصبی مصنوعی، هر نرون دارای تابعی است که نشان‌دهنده رفتار آن سلول عصبی بوده و تابع محرک نامیده می‌شود. تابع انتقال می‌تواند یک تابع خطی یا غیرخطی باشد و در واقع تابعی از پارامتر n است (Demuth and Beale, 2000). نرون‌ها می‌توانند از توابع محرک متفاوتی جهت تولید خروجی استفاده کنند. که از رایج‌ترین آن‌ها می‌توان به موارد زیر اشاره کرد:

این تابع مقادیر خروجی را به صورت خطی می‌دهد. (شکل ۳-۴ و رابطه ۳-۳۴)

¹ Purelin Function

۳۴-۳

$$f(x) = x$$



شکل ۳-۳: تابع خطی


۲-۶-۳ تابع محدودکننده^۱ (حد آستانه):

مقادیر تابع به بیشتر یا کمتر بودن مقادیر ورودی از برخی مقادیر حدی بستگی دارد. (شکل ۳-۵ و

رابطه ۳-۳۵)

$$f(x) = \begin{cases} 1, & x \geq \frac{1}{2} \\ x, & -\frac{1}{2} \leq x \leq \frac{1}{2} \\ 0, & x \leq -\frac{1}{2} \end{cases}$$

۳۵-۳



شکل ۳-۳: تابع محدودکننده

^۱ Threshold Function


۳-۶-۳ تابع سیگموئیدی تک قطبی:

ورودی این تابع انتقال می تواند هر مقداری بین منفی بی نهایت تا مثبت بی نهایت باشد درحالی که

خروجی آن در بازه صفر و ۱ محدود شده است. (شکل ۳-۵ و رابطه ۳-۳۶)

۳۶-۳

$$a = \frac{1}{1 + e^{-x}}$$



شکل ۳-۴: تابع سیگموئیدی تک قطبی


۳-۶-۴ تابع تانژانت هیپربولیک:

یک تابع فرد و نامتقارن است که تجربه نشان داده آموزش شبکه را زودتر به نتیجه می رساند (شکل

۳-۷ و رابطه ۳-۳۷)

۳۷-۳

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



شکل ۳-۵: تابع تانژانت هیپربولیک


۳-۷ شبکه‌های MLP

در این تحقیق شبکه استفاده‌شده برای پیش‌بینی، شبکه پیش‌خور چندلایه است که به آن شبکه پرسپترون چندلایه هم می‌گویند. نمای شماتیک این شبکه عصبی در شکل (۳-۵) نشان داده‌شده است. در این شبکه نرون‌های هر لایه تماماً به نرون‌های لایه قبل متصل شده است. خروجی هر لایه پس از تأثیر گذاشتن تابع محرک، ورودی لایه بعدی می‌گردد و این روند تا به دست آمدن خروجی شبکه ادامه می‌یابد. در مطالعات هیدرولوژیکی استفاده از شبکه‌های پیش‌رو و روش انتشار برگشتی بیشترین کاربرد را دارند (Coulibaly et al, 2000). در این تحقیق هم از این شبکه برای پیش‌بینی استفاده‌شده است. دو فرآیند اصلی روش انتشار برگشتی عبارت‌اند از: انتشار روبه‌جلو و انتشار به عقب. در مرحله انتشار روبه‌جلو، یک الگوی خروجی به شبکه ارائه می‌شود و اثر آن لایه به لایه در شبکه انتشار می‌یابد. برای هر نرون، مقدارهای ورودی به شرح زیر محاسبه می‌شود:

$$net_i^n = \sum_{j=1}^m W_{ji}^n \times O_j^{n-1} \quad 38-3$$

که در آن net_i^n مقدار ورودی نرون i ام لایه n ام، W_{ji}^n وزن متصل شده بین نرون i ام لایه n ام و j ام لایه $n-1$ ام و O_j^{n-1} خروجی j ام لایه $n-1$ ام و همچنین m تعداد نرون‌های لایه $n-1$ ام است (Ghalkhani et al, 2013). جهت آموزش شبکه‌های عصبی چهار الگوریتم آموزشی مرسوم که بر اساس ساختار پرسپترون چندلایه می‌باشد، وجود دارد. معروف‌ترین این روش‌ها عبارت‌اند از: انتشار خطا به عقب، گرادیان مزدوج و لونیبرگ-مارکوات. الگوریتم لونیبرگ-مارکوات از سال ۱۹۹۳ م. تا امروز به‌عنوان سریع‌ترین روش آموزش شبکه‌های عصبی شناخته‌شده است. استفاده از این نوع شبکه در منابع آب با تابع انتقال سیگموئیدی در لایه مخفی و تابع انتقال خطی در لایه خروجی می‌تواند هر تابع پیچیده‌ای با توجه به تعداد نرون‌ها را پیش‌بینی کند. در این تحقیق نیز از تابع انتقال سیگموئیدی در لایه مخفی و تابع انتقال خطی در لایه خروجی استفاده‌شده است (Haykin, 1994).

همچنین هیچ قاعده و قانون سیستماتیکی برای به دست آوردن تعداد نرون‌های لایه مخفی وجود ندارد. تعداد نرون‌های کم ممکن است کم برآزش^۱ و تعداد نرون‌های زیاد ممکن است فرابرازش^۲ برای شبکه ایجاد کنند (Dawson and Wibly, 1998).



شکل ۳-۵: نمای شماتیک شبکه عصبی مصنوعی چندلایه (MLP)

می‌توان از این شبکه برای تقریب زدن هر تابع با تعداد محدود ناپیوستگی استفاده کرد.

۳-۸ استانداردسازی داده‌های بارش و دبی قبل از ورود به پرسپترون چندلایه

قبل از مراحل آموزش و آزمون شبکه، باید فرایند استانداردسازی روی داده‌ها انجام شود تا داده‌ها در دامنه خاصی وارد شبکه گردند. با استفاده از دستور استانداردسازی، داده‌ها در محدوده (۰-۱) و یا در بازه ۱- تا ۱+ نرمال می‌شوند. هرچند در این روش خطر از دست رفتن برخی داده‌ها وجود دارد، ولی داده‌ها فرم همگنی پیدا کرده و با سایر داده‌ها قابل مقایسه می‌گردند. به‌طوری‌که در هنگام فرایند آموزش و در صورت متفاوت بودن رنج داده‌ها تأثیر داده‌های بزرگ‌تر بیشتر می‌شود (Haykin, 1999).

^۱ Under-fit

^۲ Over-fit

برای یکسان نمودن ارزش داده‌ها، قبل از آموزش شبکه عصبی، داده‌های سیگنال‌های هواشناسی برای هرماه در دوره زمانی ۴۰ و ۳۸ سال استاندارد شدند. دامنه برای استانداردسازی داده‌ها بین ۰ و ۱ انتخاب شد (Wei et al. 2013). در ادامه این تحقیق از رابطه (۳-۴۰) برای استانداردسازی داده‌های ورودی به مدل استفاده شد.

رابطه ۳-۳۹

$$X_{norm} = \left(\frac{X - X_{min}}{X_{max} - X_{min}} \right)$$

که در آن:

X_{norm} مقدار نرمال شده، X_{max} و X_{min} به ترتیب مقدار حداکثر و حداقل داده‌ها می‌باشد.

۳-۹ توابع هدف مورد استفاده برای بهینه‌سازی مدل‌ها

برای تعیین میزان دقت مدل‌های پیش‌بینی بارش و دبی باید از معیار مناسبی استفاده گردد. این معیار، پارامتری است که توسط آن به کار آیی شبکه در حین آموزش پی می‌بریم، همچنین همگرایی شبکه توسط این شاخص کنترل می‌شود. در این قسمت بر اساس مطالعات باراتی و همکاران (۲۰۰۳)، دیبیک و سولماتین (۲۰۰۱) انتخاب تعداد لایه مخفی، تعداد نرون‌های لایه‌ها، نوع تابع محرک، انتخاب نوع قانون یادگیری و تنظیم ضرایب مرتبط و تعداد تکرار مطلوب بر اساس مقایسه شاخص‌های RMSE و R در آزمون توپولوژی‌های متفاوت مدل‌های توسعه‌یافته انجام گردید (Baratti et al. 2001; Dibike and Solomatine, 2003). در این روش طراحی و آموزش شبکه عصبی بر مبنای کاهش خطای شبکه است. بدین شکل که مقادیر پیش‌بینی‌شده توسط شبکه با مقادیر ثبت‌شده بارش و دبی حوضه آبریز مطالعاتی با توابع هدف مقایسه گردید. توابع هدف مورد استفاده برای بهینه‌سازی

نمونه‌ها عبارت‌اند از: RMSE (میانگین مربعات خطا)^۱، MAE (میانگین مطلق خطا)^۲، R (ضریب همبستگی)^۳ و CNS (ضریب ناش - ساتکلیف)^۴ (Nash and Sutcliffe, 1970) که روابط آن‌ها به صورت زیر می‌باشد:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_s - X_o)^2}{n}} \quad ۴۰-۳$$

$$MAE = \frac{\sum_{i=1}^n |X_s - X_o|}{n} \quad ۴۱-۳$$

$$CNS = 1 - \left(\frac{\sum_{i=1}^n (X_o - X_s)^2}{\sum_{i=1}^n (X_o - \bar{X})^2} \right) \quad ۴۲-۳$$

$$R = \left[\frac{\sum_{i=1}^n (X_o - \bar{X}_o)(X_s - \bar{X}_s)}{\sqrt{\sum_{i=1}^n (X_o - \bar{X}_o)^2} \sqrt{\sum_{i=1}^n (X_s - \bar{X}_s)^2}} \right] \quad ۴۳-۳$$

که X_o مقدار مشاهداتی، X_s مقدار تخمینی، $\bar{X}$ میانگین مقادیر مشاهداتی یا تخمینی می‌باشد.

۳-۱۰ جمع‌بندی:

از هرکدام از این سیگنال‌ها برای پیش‌بینی بارش و دبی حداکثر ماهانه در ماه‌های دوم، سوم و چهارم میلادی سال به‌عنوان ماه‌های پربارش و همچنین ماه هشتم سال میلادی به‌عنوان ماهی که سیل‌های

¹ Root Mean Square Error

² Mean Absolute Error

³ Correlation Coefficient

⁴ Nash -Sutcliffe

بزرگی مانند سیل‌های سال ۱۳۸۰ و ۱۳۸۴ در آن رخ داده استفاده شد. برای پیش‌بینی از روش شبکه‌های عصبی مصنوعی چندلایه طبق موارد توضیح داده‌شده در بخش‌های قبل استفاده شد. همچنین با انتخاب یک شبکه پرسپترون چندلایه و الگوریتم پس انتشار خطا، مقادیر بارش و دبی شبیه‌سازی شد. شبکه‌های استفاده‌شده در مطالعه حاضر دارای ۳ لایه است. لایه‌ی اول ورودی، لایه دوم به‌عنوان لایه پنهان و لایه سوم به‌عنوان خروجی در نظر گرفته شدند. همچنین تعداد نورون‌های لایه میانی با سعی و خطا بین ۱ تا ۲۰ نورون به دست آمد. در این بررسی از الگوریتم لونیگ - مارکوات برای آموزش شبکه و همچنین تابع انتقال سیگموئیدی در لایه مخفی و تابع انتقال خطی در لایه‌ی خروجی با استفاده از کد نویسی در برنامه MATLAB.V2013a استفاده‌شده است. این شبکه‌ها دارای یک یا چند ورودی به‌عنوان سیگنال‌هایی که بیش‌ترین همبستگی را با مقادیر بارش و دبی حداکثر ماهانه در بررسی همبستگی دارا بود و یک خروجی به‌عنوان مدل پیش‌بینی می‌باشد. مدل - های نمونه مختلف ورودی و خروجی شبکه عصبی مصنوعی در جداول (۱-۳) و (۲-۳) آمده است.

جدول ۱-۳: مدل‌های ورودی و خروجی بارش حداکثر ماهانه در شبکه عصبی مصنوعی

مدل	ورودی	خروجی
مدل ۱	سیگنال دارای بهترین همبستگی	بارش حداکثر ماهانه
مدل ۲	۳ سیگنال دارای بهترین همبستگی	بارش حداکثر ماهانه
مدل ۳	همه‌ی سیگنال‌های دارای بهترین همبستگی	بارش حداکثر ماهانه

جدول ۲-۳: مدل‌های ورودی و خروجی دبی حداکثر ماهانه شبکه عصبی مصنوعی

مدل	ورودی	خروجی
مدل ۱	سیگنال دارای بهترین همبستگی	دبی حداکثر ماهانه
مدل ۲	۳ سیگنال دارای بهترین همبستگی	دبی حداکثر ماهانه
مدل ۳	همه‌ی سیگنال‌های دارای بهترین همبستگی	دبی حداکثر ماهانه

فصل

۴

منطقه تحقیق

۴-۱ مقدمه:

استان گلستان در بخشی از حوضه آبریز^۱ دریای خزر واقع شده است. این استان که بالغ بر ۲۱۰۰۰ کیلومترمربع وسعت دارد، ۱/۲ درصد از مساحت کشور و ۱۱/۷ درصد از مساحت حوضه آبریز دریای خزر را تشکیل داده و شامل حوضه‌های آبریز اترک سفلا، گرگان رود، قره‌سو، شرق خلیج گرگان و نکا رود علیا می‌باشد. وسعت این حوضه‌های آبریز متفاوت بوده به‌نحوی که بزرگ‌ترین حوضه در استان، حوضه آبریز گرگان رود با ۱۰۱۲۰ کیلومتر، سپس حوضه آبریز اترک سفلا با ۸۶۰۰ کیلومترمربع و رده سوم حوضه آبریز قره‌سو با ۱۶۱۰ کیلومترمربع هستند. حوضه آبریز شرق خلیج گرگان با ۳۴۰ کیلومترمربع و حوضه آبریز نکا رود علیا با ۳۳۰ کیلومترمربع رده‌های بعدی را اشغال می‌کنند. میزان پتانسیل آب سطحی حوضه‌های مختلف با توجه به شکل، اندازه، شرایط اقلیمی، پوشش گیاهی و سایر موارد متفاوت است. در حوضه آبریز گرگان رود ۸۲۸ میلیون مترمکعب، در حوضه آبریز اترک سفلا (سهم ایران - گلستان) ۲۵۷ میلیون مترمکعب، در حوضه آبریز قره‌سو ۱۰۰ میلیون مترمکعب، در حوضه آبریز شرق خلیج گرگان ۴۰ میلیون مترمکعب و در حوضه آبریز نکا رود علیا (سهم استان گلستان) ۱۰ میلیون مترمکعب جریان دارد. از آنجاکه این استان دارای دو اقلیم کاملاً متفاوت به‌نحوی که جنوب استان منطقه‌ای کوهستانی و مرتفع با سطحی پوشیده از جنگل‌های متراکم و شمال استان منطقه‌ای بیابانی و پست با دمای کاملاً متفاوت با جنوب می‌باشد، لذا در میزان بارندگی، تبخیر، نفوذ، رواناب و سایر فاکتورهای هیدرولوژی تفاوت عمده و اساسی مشاهده می‌شود. میزان بارندگی متوسط سالانه در جنوب استان ۷۰۰ میلی‌متر، در شمال استان ۲۰۰ میلی‌متر و میانگین آن در استان ۴۵۰ میلی‌متر است که نسبت به متوسط بارندگی در کشور ۸۰ درصد بیشتر است. مقدار تبخیر متوسط سالانه در شمال استان ۲۰۰۰ میلی‌متر و در جنوب استان ۸۰۰ میلی‌متر می‌باشد. رواناب حاصله از بارندگی در رودخانه‌ها و نیز تغذیه آبخوان‌های زیرزمینی در این دو بخش استان

^۱ Watershed

متفاوت است و پتانسیل تجدیدشونده سالانه آب استان در حدود ۲/۴۸۵ میلیارد مترمکعب می‌باشد. این حجم آب ۱/۶ درصد از پتانسیل تجدیدشونده سالانه آب کشور را در برمی‌گیرد. از میزان کل پتانسیل آب استان، ۵۰/۳ درصد آن یعنی ۱/۲۵ میلیارد مترمکعب در آبخوان‌های زیرزمینی تجمع یافته و باقیمانده یعنی ۱/۲۳۵ میلیارد مترمکعب یا به عبارتی ۴۹/۷ درصد، سالانه در رودخانه‌ها جریان می‌یابد. از مجموع پتانسیل آب استان، ظرفیت استحصال برای ۷۸/۶ درصد آن یعنی ۱/۹۵۴ میلیارد مترمکعب به وجود آمده است. راه‌های استفاده از آب‌های سطحی عبارت‌اند از شق نهرها، بندها و سدهای انحرافی، موتورپمپ‌ها، ایستگاه‌های پمپاژ، آب‌بندان‌ها و سدهای مخزنی کوچک و بزرگ که در استان گلستان در مجموع ۶۲/۹ درصد از پتانسیل آب‌های سطحی یعنی ۷۷۷ میلیون مترمکعب را در سال مهار کرده و در اختیار بخش‌های مختلف مصرف می‌گذارند.

۴-۲ منطقه تحقیق^۱:

منطقه مطالعاتی در این پژوهش، حوضه مادرسو در بالادست سد گلستان در استان گلستان می‌باشد. وسعت حوضه موردنظر ۵۱۵۵ کیلومترمربع می‌باشد. در این تحقیق از داده‌های سه ایستگاه باران‌سنجی^۲ تنگراه، تمر و گالیکش و همچنین سه ایستگاه هیدرومتری^۳ تنگراه، تمر و گالیکش برای بررسی ارتباط بین سیگنال‌های بزرگ‌مقیاس هواشناسی و بارش و رواناب این حوضه استفاده می‌شود. شکل (۴-۱) موقعیت این حوضه و ایستگاه‌های باران‌سنجی و هیدرومتری مورد استفاده در این تحقیق را نشان می‌دهد. برای این منظور بارش و دبی متوسط ماهانه در ایستگاه‌های مذکور و همچنین حداکثر بارش و دبی ماهانه برای ماه‌های مختلف به دست آمدند. همچنین جداول (۴-۱) و (۵-۱) برخی از خصوصیات آماری داده‌های دبی حداکثر ماهانه مورد استفاده در طول دوره مورد مطالعه را نشان می‌دهد.

^۱ Case Study

^۲ Raingauging


^۳ Hydrometry

جدول ۱-۴ برخی از پارامترهای آماری داده‌های بارش حداکثر ماهانه ایستگاه‌های مطالعاتی

ایستگاه	خصوصیات آماری				چولگی
	حداکثر	حداقل	میانگین	ضریب تغییرات	
تنگراه	۱۵۰	۰	۲۱/۹۶	۱۶/۳	۲/۰۸
تمر	۷۰	۰	۱۶/۳۷	۱۱/۳	۱/۰۹
گالیکش	۱۸۸	۰	۲۱/۷۶	۱۷/۱	۳/۰۲

جدول ۲-۴ برخی از پارامترهای آماری داده‌های دبی حداکثر ماهانه ایستگاه‌های مطالعاتی

ایستگاه	خصوصیات آماری				چولگی
	حداکثر	حداقل	میانگین	ضریب تغییرات	
تنگراه	۷۷۷	۰	۵/۹۴	۲۱/۰۵	۱۸/۲۳
تمر	۲۵۵	۰	۸/۲۱	۱۹/۱۴	۵/۷۲
گالیکش	۲۳۲/۵	۰/۱۲	۷/۲۷	۱۹/۵۶	۱۲/۳۳



شکل ۴-۱: موقعیت حوضه مادر سو و ایستگاه‌های باران‌سنجی و هیدرومتری مورد استفاده


۴-۳ داده‌های مورد استفاده

برای منطقه مورد مطالعه ابتدا آمار درازمدت ۴۰ سال بارندگی و ۳۸ سال دبی ایستگاه‌های حوضه تهیه گردید. از بین ایستگاه‌های موجود در سطح حوضه آبریز تنها ۳ ایستگاه باران‌سنجی دارای آمار بارندگی با طول دوره آماره کافی (۴۰ ساله) و ۳ ایستگاه هیدرومتری دارای آمار دبی (۳۸ ساله) انتخاب شدند. پس از حذف آمار مشکوک، برای کنترل کیفیت داده‌ها، آزمون‌های همگنی و یکنواختی روی داده‌ها انجام شد. داده‌های مربوط به سیگنال‌های اقلیمی نیز از سایت‌های (noaa.gov) و (ncep.noaa.gov) دانلود شد. داده‌های دما و فشار سطح دریا نیز از سایت (noaa.gov) در

شبکه‌هایی با توان تفکیک مکانی 2×2 درجه در فاصله بین سال‌های ۲۰۱۱-۱۹۷۲ میلادی استخراج شده است. به منظور بررسی ارتباط تغییرات SST و SLP با بارش و دبی در محدوده مورد مطالعه، نقاطی تحت عنوان نقاط شاخص در مناطق مختلفی از دریاها که بر آب‌وهوای ایران تأثیرگذار هستند، مورد بررسی قرار گرفت. این نقاط شامل نقاطی در دریای مدیترانه، خلیج فارس، دریای عمان، خلیج عدن، دریای عرب، دریای سرخ، دریای سیاه، دریای آدریاتیک، اقیانوس هند، اقیانوس اطلس، دریای شمال و سیبری و غیره می‌باشند که مختصات این نقاط در جدول (۴-۱) نشان داده شده است. همچنین شکل (۴-۲) نمای شماتیکی از نقاط استفاده شده برای داده‌های دما و فشار سطح دریا را نشان می‌دهد.

جدول ۴-۳: نام و مختصات نقاط مورد استفاده در تحلیل‌های دما و فشار سطح دریا

نام نقاط مورد استفاده	عرض جغرافیایی (شمالی)	طول جغرافیایی	نام نقاط مورد استفاده	عرض جغرافیایی (شمالی)	طول جغرافیایی
دریای آدریاتیک	۴۳	۱۵	دریای خزر	۴۵	۵۰
خلیج عدن	۱۲/۵	۴۵	شمال خلیج فارس	۲۷	۵۰
دریای عرب	۲۰	۶۵	شمال دریای سرخ	۲۵	۳۵
آزور	۴۱	۳۳۰	دریای شمال	۵۴	۵
جنوب خلیج فارس	۵۵	۲۵	دریای عمان	۲۴	۶۵
دریای سیاه	۴۵	۳۵	جنوب دریای سرخ	۱۴	۴۰
مرکز اطلس	۳۰	۳۲۰	غرب دریای مدیترانه	۴۱	۵
گرینلند	۶۵	۳۳۰	دریای لابرادور	۶۰	۳۰۹
اقیانوس هند	۵-۱۴	۶۰-۷۰	شبکه سوران	۲۰	۲۵
شرق دریای مدیترانه	۳۵	۳۰			



شکل ۲۴:- نمای شماتیک نقاط مورد استفاده در تحلیل های دما و فشار سطح دریا

فصل

۵

نتایج و بحث

۵-۱ بررسی همبستگی:

در این قسمت میزان همبستگی‌ها در دو بخش که شامل همبستگی مقادیر متوسط ماهانه و همبستگی مقادیر حداکثر ماهانه با سیگنال‌های اقلیمی شامل شاخص‌های عددی Nino3, Nino1+2, MEI, Nino3,4, Nino4, SOI, NAO, AO, TNI و PDO و همبستگی با دمای سطح دریا (SST) و همبستگی با فشار سطح دریا (SLP) بررسی می‌شود:

۵-۱-۱ بررسی همبستگی مقادیر متوسط ماهانه با سیگنال‌های اقلیمی:

پس از استانداردسازی داده‌های دبی و بارش در مرحله‌ی اول مقادیر ضرایب همبستگی و P-value بین مجموع بارش ماهانه و میانگین دبی ماهانه و سیگنال‌های اقلیمی با تأخیرهای ۱ الی ۲۴ ماهه محاسبه شد. مقادیر حداکثر ضریب همبستگی بین شاخص‌های اقلیمی و بارش و دبی ماهانه با تأخیرهای مختلف به ترتیب در جداول شماره (۵-۱) و (۵-۲) آورده شده است. همان‌گونه که از جداول استنباط می‌شود، بیش‌ترین مقدار ضرایب همبستگی بارش و دبی برای همه‌ی ایستگاه‌ها با سیگنال Nino1+2 و به ترتیب با تأخیر ۱۱ و ۱۳ ماهه برای بارش و دبی به‌دست‌آمده است.

جدول ۵-۱: حداکثر ضریب همبستگی محاسبه‌شده برای مجموع بارش ماهانه ایستگاه‌های بارسنجی و شاخص‌های اقلیمی


شاخص / ایستگاه	Nino1+2	Nino 3	Nino 4	Nino 3.4	MEI	TNI	AO	SOI	NAO	PDO
تنگراه	۰/۳۸	۰/۳۳	۰/۲۱	۰/۲۴	۰/۱۳	۰/۱۸	۰/۰۹	۰/۰۹	۰/۱	۰/۱۳
تأخیر (ماه)	۱۲	۱۰	۵	۲۱	۲۰	۵	۲۴	۲۴	۱	۷
تمر	۰/۴	۰/۳۶	۰/۲۶	۰/۳	۰/۱۵	۰/۱۷	۰/۰۶	۰/۰۶	۰/۱	۰/۲
تأخیر (ماه)	۱۱	۱۰	۵	۲۱	۲۱	۵	۱۰	۲۴	۱	۷
گالیکش	۰/۴	۰/۳۷	۰/۱۷	۰/۲۵	۰/۱۲	۰/۰۸	۰/۰۸	۰/۰۸	۰/۱۲	۰/۱
تأخیر (ماه)	۱۱	۱۰	۵	۹	۹	۵	۱۷	۲۴	۱	۷

جدول ۵-۲: حداکثر ضریب همبستگی برای میانگین دبی ماهانه ایستگاه‌های هیدرومتری و شاخص‌های اقلیمی

شاخص/ایستگاه	Nino1+2	Nino 3	Nino 4	Nino 3.4	MEI	TNI	AO	SOI	NAO	PDO
تنگراه	۰/۳۹	۰/۳۵	۰/۱۸	۰/۲۸	۰/۱۴	۰/۱۲	۰/۰۴	۰/۱۲	۰/۱۱	۰/۱۵
تأخیر (ماه)	۱۳	۱۲	۱۰	۱۱	۱۱	۲۲	۱۸	۱۲	۱	۸
تمر	۰/۳۶	۰/۳۴	۰/۲	۰/۲۹	۰/۱۷	۰/۱۵	۰/۰۷	۰/۱۵	۰/۰۷	۰/۰۵
تأخیر (ماه)	۱۳	۱۱	۱۰	۱۱	۱۱	۲۲	۳	۱۲	۱	۸
گالیکش	۰/۵۱	۰/۴۳	۰/۱۴	۰/۳	۰/۱۲	۰/۰۴	۰/۰۵	۰/۱۱	۰/۰۶	۰/۱۴
تأخیر (ماه)	۱۳	۱۲	۱۰	۱۱	۱۰	۲۲	۸	۱۲	۱	۸


۵-۱-۲ بررسی همبستگی ماهانه با داده‌های دمای سطح دریا:

در مرحله‌ی دوم مقادیر ضرایب همبستگی و P-value بین مجموع بارش ماهانه و میانگین دبی و داده‌های دمای سطح دریا با تأخیرهای ۱ الی ۲۴ ماهه محاسبه شد. در شکل‌های (۵-۱) و (۵-۲) مقادیر حداکثر ضریب همبستگی بین داده‌های دمای سطح دریا و بارش و دبی ماهانه با تأخیرهای مختلف به آورده شده است. همان‌گونه که از شکل (۵-۱) استنباط می‌شود، بیش‌ترین مقدار ضرایب میزان همبستگی بارش برای ایستگاه تنگراه و تمر با SST جنوب دریای سرخ به ترتیب با تأخیر ۶ و ۳ ماه به‌دست‌آمده است. بیش‌ترین مقدار ضرایب همبستگی بارش ایستگاه گالیکش با SST دریای خزر با تأخیرهای ۹ ماهه به‌دست‌آمده است.



شکل ۱۵-: حداکثر ضریب همبستگی محاسبه شده برای مجموع بارش ماهانه ایستگاه‌های باران‌سنجی و دمای سطح دریا


همچنین از شکل (۵-۲) استنباط می‌شود که بیش‌ترین مقدار ضرایب همبستگی دبی برای ایستگاه تنگراه با SST شبکه سوران با تأخیر ۲ ماهه به‌دست‌آمده است. بیش‌ترین مقدار ضرایب همبستگی دبی برای ایستگاه تمر با SST دریای گرینلند با تأخیر ۷ ماهه به‌دست‌آمده است. بیش‌ترین مقدار ضرایب همبستگی دبی برای ایستگاه گالیکش نیز با SST شبکه سوران با تأخیر ۱۵ ماهه به‌دست‌آمده است.



شکل ۵-۲: حداکثر ضریب همبستگی محاسبه شده برای میانگین دبی ماهانه ایستگاه‌های هیدرومتری و دمای سطح دریا


۳-۱-۵ بررسی همبستگی ماهانه با داده‌های فشار سطح دریا:

همان‌گونه که از شکل (۳-۵) استنباط می‌شود، بیش‌ترین مقدار ضرایب همبستگی بارش برای ایستگاه‌های تنگراه، تمر و با SLP دریای خزر با تأخیرهای به ترتیب ۷ و ۹ ماهه و برای ایستگاه گالیکش با SLP جنوب خلیج فارس با تأخیر ۹ ماهه به‌دست آمده است.



شکل ۳-۵: حداکثر ضریب همبستگی محاسبه‌شده برای مجموع بارش ماهانه ایستگاه‌های باران‌سنجی و فشار سطح دریا

همچنین با توجه به شکل (۴-۵)، بیش‌ترین مقدار ضرایب همبستگی دبی برای ایستگاه‌های تنگراه، تمر و گالیکش با SLP دریای خزر همگی با تأخیر ۹ ماهه به‌دست آمده است.



شکل ۴-۵: حداکثر ضریب همبستگی محاسبه‌شده برای میانگین دبی ماهانه ایستگاه‌های هیدرومتری و فشار سطح دریا

جدول (۳-۵) نشان‌دهنده‌ی نتایج کلی بیش‌ترین همبستگی‌های بارش و دبی در مقیاس‌های ماهانه و فصلی با دما و فشار سطح دریای نقاط مختلف در کره‌ی زمین همراه با بررسی معنی‌داری ضرایب همبستگی به‌دست‌آمده می‌باشد.

جدول ۳-۵: بررسی معنی‌داری حداکثر ضرایب همبستگی میانگین بارش و دبی

		شاخص	r	P-Value	Lag
سیگنال‌های اقلیمی	بارش ماهانه	Nino 1+2 - تنگراه	۰/۳۸	۰/۰۲	۱۲
		Nino 1+2 - تمر	۰/۴	۰/۰۱۵	۱۱
		Nino 1+2 - گالیکش	۰/۴	۰/۰۰۳	۱۱
	دبی ماهانه	Nino 1+2 - تنگراه	۰/۳۹	۰/۰۲۳	۱۳
		Nino 1+2 - تمر	۰/۳۶	۰/۰۰۱	۱۳
		Nino 1+2 - گالیکش	۰/۵۱	۰/۰۳	۱۳
دما یا فشار سطح دریا	بارش ماهانه	SLP دریای خزر - تنگراه	۰/۴۸۸	۰	۷
		SLP دریای خزر - تمر	۰/۴۸۷	۰	۹
		SST دریای خزر - گالیکش	۰/۴۴۴	۰	۹
	دبی ماهانه	SLP دریای خزر - تنگراه	۰/۵۹۴	۰	۹
		SST دریای گرینلند - تمر	۰/۵۷۶	۰	۷
		SLP دریای خزر - گالیکش	۰/۶۱	۰	۹

۴-۱-۵ بررسی همبستگی مقادیر حدی بارش و دبی ماهانه با سیگنال‌های بزرگ‌مقیاس

اقلیمی

در مرحله‌ی بعد مقادیر ضرایب همبستگی و P-value بین حداکثر بارش و دبی ماهانه و داده‌های دما و فشار سطح دریا و همچنین سیگنال‌های هواشناسی با تأخیرهای ۱ الی ۱۲ ماهه محاسبه شد. برای

این کار حداکثر بارش و دبی ماهانه در طول دوره‌ی آماری مورد مطالعه به دست آمد و سپس همبستگی این مقادیر در هر ماه میلادی به‌طور جداگانه با ماه‌های دیگر محاسبه شد. نتایج به‌دست‌آمده از این کار در شکل‌های (۵-۵) و (۶-۵) و جداول (۴-۵) و (۵-۵) نشان داده شده است.



شکل ۵-۵: ضریب همبستگی محاسبه شده حداکثر دبی ماهانه ایستگاه‌های باران‌سنجی و سیگنال‌های بزرگ مقیاس اقلیمی



شکل ۶-۵: ضریب همبستگی حداکثر بارش ماهانه ایستگاه‌های هیدرومتری و سیگنال‌های بزرگ مقیاس اقلیمی

جدول ۵-۴: تأخیر و معنی‌داری برای حداکثر بارش ماهانه ایستگاه‌های باران‌سنجی و سیگنال‌های بزرگ مقیاس اقلیمی

تأخیر	P-Value	نقطه	تأخیر	P-Value	نقطه	تأخیر	P-Value	نقطه	ماه
۷	۰/۰۰۹	SST شبکه سوران	۳	۰/۰۰۱	SLP دریای خزر	۴	۰/۰۰۲	SLP دریای خزر	ژانویه
۸	۰/۰۰۴	SST گرینلند	۰	۰/۰۰۶	SLP دریای سیاه	۴	۰/۰۱۳	SST شرق مدیترانه	فوریه
۱	۰/۰۲۷	SLP اقیانوس اطلس	۲	۰/۰۰۵	SLP شرق مدیترانه	۰	۰/۰۰۲	SST اقیانوس اطلس	مارس
۲	۰/۰۱۲	SLP غرب مدیترانه	۰	۰/۰۰۱	SST اقیانوس اطلس	۱۱	۰/۰۲۷	SLP دریای سیاه	آوریل
۰	۰/۰۰۹	SST جنوب خلیج فارس	۱۱	۰/۰۰۱	SST شرق مدیترانه	۷	۰	SST شرق مدیترانه	مه
۶	۰/۰۱۴	SST غرب مدیترانه	۴	۰/۰۰۴	SLP دریای خزر	۳	۰/۰۳۱	SLP شرق مدیترانه	ژوئن
۸	۰/۰۲۱	SLP غرب مدیترانه	۷	۰/۰۰۵	SST دریای خزر	۱	۰/۰۰۴	SLP دریای سیاه	ژوئیه
۴	۰/۰۰۱	SLP اقیانوس اطلس	۹	۰/۰۰۹	SST شبکه سوران	۳	۰/۰۱۳	SLP دریای خزر	اوت
۵	۰/۰۱۶	SLP غرب مدیترانه	۰	۰/۰۱۱	SLP دریای سیاه	۴	۰/۰۲۸	SST شبکه سوران	سپتامبر
۱۰	۰/۰۳۵	SLP شرق مدیترانه	۱۱	۰	SLP غرب مدیترانه	۹	۰/۰۱۳	SLP دریای سیاه	اکتبر
۱۰	۰/۰۰۵	SLP شرق مدیترانه	۱۰	۰/۰۰۶	SLP دریای خزر	۴	۰/۰۲۱	SLP دریای سیاه	نوامبر
۱۱	۰/۰۲۷	SLP اقیانوس اطلس	۱۱	۰/۰۰۵	SST غرب مدیترانه	۵	۰	SLP اقیانوس اطلس	دسامبر

جدول ۵-۵: تأخیر و معنی‌داری برای حداکثر دبی ماهانه ایستگاه‌های هیدرومتری و سیگنال‌های بزرگ‌مقیاس اقلیمی

ایستگاه	ایستگاه تنگراه			ایستگاه تمر			ایستگاه گالیکش		
	داده	P-Value	تأخیر	داده	P-Value	تأخیر	داده	P-Value	تأخیر
ژانویه	SLP دریای سیاه	۰/۰۰۱	۹	SLP اقیانوس اطلس	۰/۰۲۴	۳	SLP دریای خزر	۰/۰۱	۳
فوریه	SLP شرق مدیترانه	۰/۰۲۹	۹	SST اقیانوس اطلس	۰/۰۰۲	۲	SST گرینلند	۰/۰۰۴	۸
مارس	SST دریای سیاه	۰/۰۰۱	۹	SLP خلیج عدن	۰	۷	SLP خلیج عدن	۰/۰۰۵	۱۰
آوریل	SLP خلیج عدن	۰	۲	SLP خلیج عدن	۰	۸	SLP خلیج عدن	۰	۸
مِه	SST جنوب خلیج فارس	۰/۰۰۷	۴	SLP اقیانوس اطلس	۰/۰۱۹	۷	SST جنوب خلیج فارس	۰/۰۱۵	۰
ژوئن	SST دریای سیاه	۰/۰۰۹	۹	SLP غرب مدیترانه	۰/۰۰۲	۰	SLP شرق مدیترانه	۰/۰۰۵	۱
ژوئیه	SST دریای سیاه	۰/۰۰۷	۴	SLP اقیانوس اطلس	۰/۰۰۱	۱۰	SLP اقیانوس اطلس	۰/۰۰۵	۹
اوت	SLP دریای سیاه	۰/۰۰۴	۴	SLP اقیانوس اطلس	۰/۰۰۷	۱۱	SLP دریای سیاه	۰/۰۰۱	۴
سپتامبر	SST شبکه سوران	۰/۰۰۱	۴	SLP شرق مدیترانه	۰/۰۰۵	۱۰	SLP اقیانوس اطلس	۰/۰۰۲	۱۱
اکتبر	SLP شرق مدیترانه	۰/۰۳۲	۴	SLP غرب مدیترانه	۰/۰۳۵	۸	SLP غرب مدیترانه	۰/۰۳۱	۱۱
نوامبر	SLP خلیج عدن	۰/۰۰۶	۴	SLP شرق مدیترانه	۰/۰۱۶	۶	SLP دریای خزر	۰/۰۳۷	۱
دسامبر	SLP شرق مدیترانه	۰/۰۰۸	۴	SLP غرب مدیترانه	۰/۰۱۵	۹	SLP خلیج عدن	۰/۰۰۲	۲

با توجه به نتایج به دست آمده بیشترین میزان همبستگی حداکثر بارش ماهانه ایستگاه تنگراه در ماه می برابر با ۰/۶۴۱ با SST شرق مدیترانه با تأخیر ۷ ماه، برای ایستگاه تمر در ماه اکتبر برابر با ۰/۵۳۷ با SLP غرب دریای مدیترانه با تأخیر ۱۱ ماهه و برای ایستگاه گالیکش در ماه اوت برابر با ۰/۴۹۵ با SLP اقیانوس اطلس با تأخیر ۴ ماهه به دست آمد.

مقادیر بعدی مشاهده شده برای همبستگی بارش حداکثر با دما یا فشار سطح دریا در ایستگاه تنگراه در ماه دسامبر برابر با ۰/۵۴۳ با SLP نقطه شاخص در اقیانوس آرام با تأخیر ۵ ماه، برای ایستگاه تمر در ماه می برابر با ۰/۵۱۹ با SST شرق مدیترانه با تأخیر ۱۱ ماهه و برای ایستگاه گالیکش در ماه فوریه برابر با ۰/۴۵۴ با SLP غرب مدیترانه با تأخیر ۴ ماهه به دست آمد.

همچنین در نتایج به دست آمده از ارتباط دبی ایستگاه‌ها با سیگنال‌های بزرگ مقیاس اقلیمی نیز نتایج زیر به دست آمد. بیشترین میزان همبستگی دبی ایستگاه‌های تنگراه، تمر و گالیکش با ماه آوریل به ترتیب برابر با ۰/۹۳۷، ۰/۷۸۲ و ۰/۹۲۶ با تأخیر ۸ ماهه و با SLP خلیج عدن به دست آمد. مقادیر بعدی مشاهده شده برای همبستگی دبی حداکثر با دما یا فشار سطح دریا در ایستگاه تنگراه در ماه سپتامبر برابر با ۰/۵۴۴ با SST دریای سیاه با تأخیر ۸ ماه، برای ایستگاه تمر در ماه مارس برابر با ۰/۷۶۴ با SLP خلیج عدن با تأخیر ۷ ماهه و برای ایستگاه گالیکش در ماه اوت برابر با ۰/۵۱۵ با SLP دریای سیاه با تأخیر ۴ ماهه به دست آمد. با توجه به این نکته که مقادیر همبستگی دبی حداکثر ماهانه و شاخص‌های بررسی شده مقادیر خوبی به دست آمده است فقط مقادیر همبستگی بعد از مقادیر حداکثر آورده شده است. این مقادیر نشان‌دهنده همبستگی خوب بارش و دبی حداکثر ماه‌های مختلف سال و ایستگاه‌های منطقه مطالعاتی می‌باشد.

با بررسی مقادیر ضرایب همبستگی برای ایستگاه‌های باران‌سنجی و سیگنال‌های اقلیمی بیشترین مقدار همبستگی با شاخص Nino 1+2 برای ایستگاه گالیکش با تأخیر ۱۱ ماهه به دست آمد و این بدان معنا است که هرچقدر مقدار شاخص Nino 1+2 افزایش (کاهش) یابد، میزان بارش در ایستگاه گالیکش افزایش (کاهش) می‌یابد. برای این تحقیق بعضی از مقادیر همبستگی منفی به دست آمد

بدان معنا است که در این موارد هرچقدر مقدار شاخص Nino 1+2 افزایش (کاهش) یابد، میزان بارش در ایستگاه موردنظر کاهش (افزایش) می‌یابد. برای ایستگاه‌های هیدرومتری بیش‌ترین مقدار همبستگی با شاخص Nino 1+2 برای ایستگاه گالیکش با تأخیر ۱۳ ماهه به دست آمد و این بدان معنا است که هرچقدر مقدار شاخص Nino 1+2 افزایش (کاهش) یابد، میزان دبی در ایستگاه گالیکش افزایش (کاهش) می‌یابد. نتیجه‌ی دیگری که از محاسبه‌ی ضرایب همبستگی به‌دست‌آمده این است که با تأخیرهای مختلف میزان همبستگی بارش و دبی با شاخص Nino3 مقادیر قابل‌توجهی به‌دست‌آمده است که نسبت به شاخص‌های دیگر بیشتر است و ارتباط بارش متوسط و دبی میانگین ایستگاه‌های منطقه مطالعاتی با پدیده‌ی انسو را نشان می‌دهد. معنادار بودن ضرایب همبستگی با تأخیر برای بارش و دبی ایستگاه‌ها به این معنا است که دمای سطح آب در محدوده‌ی سیگنال‌های اقلیمی علاوه بر تأثیرات هم‌زمان می‌تواند با تأخیر موجب تغییرات در بارش و دبی ایستگاه‌های مورد مطالعه شود. با بررسی بیشتر و به دست آوردن ضرایب همبستگی با دما و فشار سطح دریا در نقاط مختلف کره‌ی زمین نتیجه شد که مقادیر بارش و دبی ارتباط بیشتری با دما و یا فشار سطح دریا در نقاط مختلف دارند. همچنین با بررسی همبستگی‌ها به این نتیجه می‌رسیم که مجموع بارش ماهانه در ایستگاه‌های تنگراه و تمر با SLP دریای خزر و در ایستگاه گالیکش با SST دریای خزر بیش‌ترین همبستگی را دارند. همچنین دبی متوسط ماهانه در ایستگاه‌های تنگراه و گالیکش با SLP دریای خزر و در ایستگاه تمر با SST گرینلند همبستگی بیشتری دارد.

همچنین نتایج حاصل از بررسی همبستگی بین مقادیر حدی بارش و دبی نیز نشان‌دهنده‌ی همبستگی خوب داده‌های بارش با فشار سطح دریا‌های سیاه و غرب و شرق دریای مدیترانه و Nino 1+2 و داده‌های دبی با فشار سطح نقطه شاخص اقیانوس اطلس، دمای سطح دریای سیاه و شبکه سوران با تأخیرهای متفاوت در سطوح معنی‌داری ۱ و ۵ درصد است.

۵-۱-۵- جمع‌بندی:

در این مطالعه نقش سیگنال‌های بزرگ‌مقیاس اقلیمی در میزان بارش و دبی ماهانه حوضه آبریز مادرسو واقع در بالادست سد گلستان برای ۳ ایستگاه باران‌سنجی و ۳ ایستگاه هیدرومتری مهم در منطقه بررسی شد. برای این منظور سیگنال‌های مختلف اقلیمی شامل Nino 1+2 و غیره و همچنین دما و فشار سطح دریاهای نقاط مختلف کره‌ی زمین برای این مطالعه در نظر گرفته شدند. انجام تحلیل همبستگی و به دست آوردن ضرایب همبستگی، ارتباط بین این سیگنال‌های اقلیمی و بارش و دبی ماهانه در حوضه مطالعاتی را تأیید می‌نماید. مقادیر همبستگی هم برای داده‌های ماهانه و هم برای داده‌های حداکثر مجموع بارش و میانگین دبی ماهانه به دست آمد.

در مقیاس ماهانه، حداکثر همبستگی مجموع بارش و میانگین دبی ایستگاه‌های مطالعاتی برای سیگنال‌های اقلیمی با شاخص Nino 1+2 و برای داده‌های دمای سطح دریاهای گرینلند، شمال و جنوب خلیج فارس، جنوب دریای سرخ و شبکه سوران و با فشار سطح دریا خزر به دست آمد و این بدان معنا است که این شاخص بیش‌ترین تأثیر را بر بارش و دبی ماهانه حوضه‌ی آبریز مطالعاتی دارد. حداکثر میزان همبستگی شاخص Nino 1+2 با داده‌های ماهانه ایستگاه باران‌سنجی و هیدرومتری گالیکش به ترتیب ۰/۴۰ و ۰/۵۱ با تأخیر ۱۱ و ۱۳ ماه می‌باشد. با انجام تحلیل روی داده‌های دمای سطح دریا نیز بیش‌ترین ضریب همبستگی برای داده‌های بارش ۰/۴۵۵، ۰/۴۷۸ و ۰/۴۴ با تأخیرهای ۶ و ۳ و ۹ ماهه و برای داده‌های دبی نیز ۰/۴۴۲، ۰/۵۷۶ و ۰/۵۵۲ با تأخیرهای ۲ و ۷ و ۱۵ ماهه به‌دست‌آمده است. همچنین با انجام بررسی روی داده‌های فشار سطح دریا نیز بیش‌ترین ضریب همبستگی برای بارش ۰/۴۷۸، ۰/۴۷۸ و ۰/۴۲۵ با تأخیرهای ۷ و ۹ و ۹ ماهه و برای داده‌های دبی نیز ۰/۵۹۴، ۰/۴۳۳ و ۰/۶۱ با تأخیر ۹ ماهه به‌دست‌آمده است. در کل ارتباط قوی میان بارش ایستگاه‌های تنگراه و تمر با SLP دریای خزر و گالیکش با SST دریای خزر و دبی ایستگاه‌های تنگراه و گالیکش و SLP دریای خزر و ایستگاه تمر با SST منطقه گرینلند وجود دارد.

بیشترین میزان همبستگی حداکثر بارش ماهانه ایستگاه تنگراه در ماه می برابر با ۰/۶۴۱ با SST شرق مدیترانه با تأخیر ۷ ماه، برای ایستگاه تمر در ماه اکتبر برابر با ۰/۵۳۷ با SLP غرب دریای مدیترانه با تأخیر ۱۱ ماهه و برای ایستگاه گالیکش در ماه اوت برابر با ۰/۴۹۵ با SLP اقیانوس اطلس با تأخیر ۴ ماهه به دست آمد.

بیشترین میزان همبستگی دبی ایستگاه‌های تنگراه، تمر و گالیکش با ماه آوریل به ترتیب برابر با ۰/۹۳۷، ۰/۷۸۲ و ۰/۹۲۶ با تأخیر ۸ ماهه و با SLP خلیج عدن به دست آمد. همچنین بررسی معنی‌داری این ضرایب به‌دست‌آمده از طریق P-Value نشان‌دهنده معنی‌دار بودن همه‌ی این ضرایب می‌باشد. همچنین برای پیش‌بینی بارش و دبی حداکثر ماهانه ایستگاه‌های مطالعاتی از داده‌های سیگنال‌هایی که دارای بیشترین همبستگی با مقادیر بارش و دبی حداکثر ماهانه هستند استفاده می‌شود.

۵-۲ پیش‌بینی بارش و دبی ماهانه با شبکه عصبی مصنوعی:

در این تحقیق از روش همبستگی پیرسون برای بررسی همبستگی مقادیر بارش حداکثر ماهانه و سیگنال‌های بزرگ‌مقیاس اقلیمی در سطح معنی‌داری ۵ درصد با تأخیرهای ۱ تا ۱۲ ماه استفاده شد. سپس مقادیر سیگنالی که بیشترین همبستگی را دارا بود برای پیش‌بینی بارش و دبی حدی ماهانه در مرحله اول استفاده شد. در مرحله دوم از سه سیگنالی که بیشترین همبستگی را با بارش و دبی حدی ماهانه را داشتند استفاده شد. همچنین برای پیش‌بینی مقادیر حدی از ماه‌های دوم، سوم، چهارم و هشتم (فوریه، مارس، آوریل و اوت) سال به‌عنوان ماه‌های پر بارش و ماه هشتم که سیل‌های مهیبی در آن رخ داده است استفاده شد. برای این کار در این مرحله از شبکه‌های عصبی مصنوعی چندلایه (MLP) طبق آنچه در بخش مواد و روش‌ها توضیح داده شد استفاده شد. این شبکه‌ها دارای یک و سه ورودی و چند ورودی به‌عنوان سیگنال‌هایی که بیشترین همبستگی را با مقادیر بارش و دبی حداکثر ماهانه در بررسی همبستگی دارا بود و یک خروجی به‌عنوان مدل پیش‌بینی می‌باشد. همچنین تعداد

نورون‌های لایه میانی با سعی و خطا بین ۱ تا ۲۰ نورون به دست آمد. شبکه‌ها دارای یک لایه پنهان هستند. نتایج حاصل از بررسی‌ها در جداول زیر برای بارش و دبی حداکثر ماهانه در روش شبکه عصبی MLP نشان داده شده است. در جداول زیر R ضریب همبستگی بین مقادیر مشاهداتی و برآورد شده در دوره‌های آموزش و آزمون است. همچنین برای ارزیابی عملکرد شبکه‌ها از معیارهای میانگین مجذور خطا^۱ (RMSE)، متوسط قدر مطلق خطا (MAE) و معیار ناش-ساتکلیف (CNS) استفاده شد. شاخص MAE یک مقدار نامنفی است و متوسط انحراف مقادیر پیش‌بینی شده از مشاهدات را ارائه می‌کند. از طرف دیگر RMSE نیز که مقداری مثبت است نسبت به MAE به خطاهای بیشتر پیش‌بینی حساس‌تر می‌باشد. شاخص ناش-ساتکلیف که میزان رابطه بین مقادیر پیش‌بینی شده و مشاهداتی بارش و دبی حدی ماهانه را نشان می‌دهد در بازه $-\infty$ تا ۱ تغییر می‌کند. نزدیکی این شاخص به ۱ نشان‌دهنده رابطه قوی بین مقادیر پیش‌بینی و مشاهده شده است. همچنین برای یافتن بهترین نتایج پیش‌بینی باید مقدار ضریب همبستگی به ۱ نزدیک بوده و آماره‌های RMSE و MAE کوچک باشد.

داده‌های ورودی بارش حداکثر ماهانه شبکه به ۳ دسته تقسیم شدند: مرحله آموزش و ارزیابی برای سال‌های ۱۹۷۲-۲۰۰۳ (۳۱ داده) و مرحله صحت یابی (آزمون) برای سال‌های ۲۰۰۴-۲۰۱۱ (۸ داده). همچنین داده‌های ورودی دبی حداکثر ماهانه شبکه به ۳ دسته تقسیم شدند: مرحله آموزش و ارزیابی برای سال‌های ۱۹۷۴-۲۰۰۴ (۳۰ داده) و مرحله صحت یابی (آزمون) برای سال‌های ۲۰۰۵-۲۰۱۱ (۷ داده). به عبارتی دیگر ۸۰ درصد داده‌ها برای آموزش و ارزیابی و ۲۰ درصد دیگر برای آزمون شبکه مورد استفاده قرار گرفتند. پس از انجام آموزش و آزمون شبکه‌های مختلف نتایج در سه بخش زیر نشان داده شده است.

^۱ معادل فارسی کلمه Root Mean Square Error

۵-۲-۱ پیش‌بینی بارش حداکثر ماهانه با شبکه عصبی مصنوعی:

همان‌گونه که اشاره شد در این تحقیق از روش همبستگی پیرسون برای بررسی همبستگی مقادیر بارش حداکثر ماهانه و سیگنال‌های بزرگ‌مقیاس اقلیمی در سطح معنی‌داری ۵ درصد با تأخیرهای ۱ تا ۱۲ ماه استفاده شد. در ابتدا از یک سیگنال و برای دستیابی به نتایج بهتر از سیگنال‌های بیشتری به‌عنوان ورودی به شبکه عصبی مصنوعی استفاده شد. در صورتی که نتایج و شاخص‌های آماری بهتر شوند از همین شبکه‌ها و نتایج حاصل از آن در پیش‌بینی بارش‌های حداکثر ماهانه استفاده می‌کنیم. برای پیش‌بینی در این مرحله مقادیر همبستگی‌های معنی‌دار بارش ماکزیمم ماه‌های مورد مطالعه و SST و SLP های دیگر نقاط مختلف که محاسبه شد و مدل‌های مختلف پیش‌بینی بارش حداکثر ماهانه در جدول (۵-۶) نشان داده شده است.

جدول ۵-۶: مدل‌های استفاده شده برای پیش‌بینی بارش حداکثر ماهانه

تأخیر	ایستگاه گالیکش	تأخیر	ایستگاه تمر	تأخیر	ایستگاه تنگراه	ماه	مدل ورودی
۸	SST گرینلند	۰	SLP دریای سیاه	۴	SST شرق مدیترانه	فوریه	مدل ۱
۱	SLP اقیانوس اطلس	۲	SLP شرق مدیترانه	۰	SST اقیانوس اطلس	مارس	
۲	SLP غرب مدیترانه	۰	SST اقیانوس اطلس	۱۱	SLP دریای سیاه	آوریل	
۴	SLP اقیانوس اطلس	۹	SST شبکه سوران	۳	SLP دریای خزر	اوت	
۲	SST شرق مدیترانه	۳	SST شرق مدیترانه	۴	SLP دریای خزر	فوریه	مدل ۲
۳	SST شرق مدیترانه	۱۱	SLP اقیانوس اطلس	۹	SLP خلیج عدن		
۲	SST گرینلند	۶	SLP دریای سیاه	۳	SLP دریای خزر		
۴	SLP غرب مدیترانه	۲	SLP دریای سیاه	۱۰	SST اقیانوس اطلس	مارس	
۳	SST اقیانوس اطلس	۴	SST دریای سیاه	۱۱	SST جنوب خلیج فارس		

			SLP اقیانوس اطلس	۹	SST گرینلند	۴	SLP اقیانوس اطلس	۹
		آوریل	SST شرق مدیترانه	۱۰	SST اقیانوس اطلس	۱	SLP دریای سیاه	۲
			SST دریای سیاه	۵	SST اقیانوس اطلس	۲	SLP خلیج SLP عدن	۷
			SST شرق مدیترانه	۵	SST دریای خزر	۲	SLP شرق مدیترانه	۱۱
		اوت	SLP اقیانوس اطلس	۳	SLP خلیج عدن	۵	SLP غرب مدیترانه	۴
			SLP دریای خزر	۲	SLP اقیانوس اطلس	۱۱	SST شبکه سوران	۹
			SLP اقیانوس اطلس	۱	SLP دریای سیاه	۲	SLP اقیانوس اطلس	۴
	مدل ۳	فوریه	SLP دریای خزر	۴	SST شرق مدیترانه	۳	SST شرق مدیترانه	۲
			SLP خلیج عدن	۹	SLP اقیانوس اطلس	۱۱	SST شرق مدیترانه	۳
			SLP دریای خزر	۳	SLP دریای سیاه	۶	SST گرینلند	۲
			SST گرینلند	۸	SST جنوب خلیج فارس	۳	SST شرق مدیترانه	۸
			-	-	SST شبکه سوران	۴	SST گرینلند	۳
			-	-	SLP خلیج عدن	۱۰	SST گرینلند	۹
			-	-	-	-	SST شبکه سوران	۳
		مارس	SST اقیانوس اطلس	۱۰	SLP دریای سیاه	۲	SLP غرب مدیترانه	۴
			SST جنوب خلیج فارس	۱۱	SST دریای سیاه	۴	SST اقیانوس اطلس	۳
			SLP اقیانوس اطلس	۹	SST گرینلند	۴	SLP اقیانوس اطلس	۹
			SST غرب مدیترانه	۱۰	SLP غرب مدیترانه	۱۰	SLP غرب مدیترانه	۲

		SST شرق مدیترانه	۱۱	SST دریای سیاه	۱۰	-	-
		SST دریای سیاه	۵	SST غرب مدیترانه	۱۰	-	-
		-	-	SLP غرب مدیترانه	۰	-	-
	آوریل	SST شرق مدیترانه	۱۰	SST اقیانوس اطلس	۱	SLP دریای سیاه	۲
		SST دریای سیاه	۵	SST اقیانوس اطلس	۲	SLP خلیج عدن	۷
		SST شرق مدیترانه	۵	SST دریای خزر	۲	SLP شرق مدیترانه	۱۱
		SLP دریای خزر	۸	SST شبکه سوران	۳	SLP اقیانوس اطلس	۲
		-	-	SST شبکه سوران	۲	SLP دریای سیاه	۰
		-	-	SST شبکه سوران	۱	SLP دریای سیاه	۱۰
		-	-	SST غرب مدیترانه	۳	-	-
	اوت	SLP اقیانوس اطلس	۳	SLP خلیج عدن	۵	SLP غرب مدیترانه	۴
		SLP دریای خزر	۲	SLP اقیانوس اطلس	۱۱	SST شبکه سوران	۹
		SLP اقیانوس اطلس	۱	SLP دریای سیاه	۲	SLP اقیانوس اطلس	۴
		SLP دریای سیاه	۲	SST جنوب خلیج فارس	۹	SLP غرب مدیترانه	۵
		SLP دریای سیاه	۶	-	-	-	-

۵-۲-۱-۱ پیش‌بینی با یک سیگنال:

در این مرحله از سیگنالی که بیشترین همبستگی را با مقادیر بارش حدی ماهانه داشت استفاده شد. از این سیگنال که دارای بیشترین همبستگی بود به‌عنوان ورودی و بارش حداکثر ماهانه ماه‌های فوریه، مارس، آوریل و اوت به‌عنوان توابع هدف استفاده شد. نتایج برای سه ایستگاه مختلف

مورد مطالعه در ماه‌های مختلف در جدول زیر نشان داده شده است. مطابق جدول (۵-۷) برای بارش ایستگاه تنگراه بهترین مقادیر R ، $RMSE$ و CNS به ترتیب برابر با ۰/۰۸، ۰/۸۹۸ و ۰/۸۰۷ در مرحله آموزش و در ماه اوت و ۰/۱۳، ۰/۷۹ و ۰/۵۹۸ در مرحله آزمون و برای ماه آوریل به دست آمد. برای بارش ایستگاه تمر بهترین مقادیر R ، $RMSE$ و CNS به ترتیب برابر با ۰/۰۶، ۰/۹۱۱ و ۰/۸۲۹ در مرحله آموزش در ماه فوریه و ۰/۱۷، ۰/۸۱۵ و ۰/۶۴۶ در مرحله آزمون و برای ماه آوریل به دست آمد. برای بارش ایستگاه گالیکش بهترین مقادیر R ، $RMSE$ و CNS به ترتیب برابر با ۰/۰۶، ۰/۸۳۲ و ۰/۶۹۱ در مرحله آموزش و برای ماه فوریه و ۰/۱۸، ۰/۵۸۶ و ۰/۴۷۷ در مرحله آزمون و برای ماه مارس به دست آمد.

جدول ۵-۷: نتایج آنالیز شبکه عصبی برای پیش‌بینی با یک سیگنال

ایستگاه	ماه	آموزش				آزمون			
		RMSE	MAE	R	CNS	RMSE	MAE	R	CNS
تنگراه	فوریه	۰/۱۲۵	۰/۰۷۹	۰/۷۲۳	۰/۵۲۲	۰/۲۷۱	۰/۲۰۴	۰/۶۰۸	۰/۵۳۳
	مارس	۰/۱۴۹	۰/۱۱۲	۰/۸۴۱	۰/۷۰۵	۰/۲۳۴	۰/۲۱۷	۰/۶۴۴	۰/۵۲۸
	آوریل	۰/۱۳۸	۰/۰۹۲	۰/۷۷۵	۰/۵۹۴	۰/۱۳۵	۰/۱۰۴	۰/۷۹۱	۰/۵۹۸
	اوت	۰/۰۷۸	۰/۰۵۲	۰/۸۹۸	۰/۸۰۷	۰/۱۶	۰/۱۲۵	۰/۵۲۸	۰/۴۴۷
تمر	فوریه	۰/۰۶۲	۰/۰۴۳	۰/۹۱۱	۰/۸۲۹	۰/۱۹۱	۰/۱۵۵	۰/۸۵۵	۰/۶۰۸
	مارس	۰/۱۸	۰/۱۱۸	۰/۷۷۷	۰/۶۰۲	۰/۲۴۷	۰/۲۲۴	۰/۸۷۹	۰/۷۸۲
	آوریل	۰/۲۴۱	۰/۱۹۲	۰/۴۲۶	۰/۱۷۶	۰/۱۷۵	۰/۱۴۸	۰/۸۱۵	۰/۶۴۶
	اوت	۰/۱۴۷	۰/۱۰۵	۰/۷۴۵	۰/۵۵۴	۰/۲۸۳	۰/۲۲۵	۰/۵۲	۰/۳۴۴
گالیکش	فوریه	۰/۰۶۶	۰/۰۵۰	۰/۸۳۲	۰/۶۹۱	۰/۲۷۷	۰/۲۰۴	۰/۵۷۳	۰/۴۶۴
	مارس	۰/۱۴۷	۰/۰۹۱	۰/۸۲۳	۰/۶۷۲	۰/۱۸۲	۰/۱۵۶	۰/۵۸۶	۰/۴۷۷
	آوریل	۰/۱۷۶	۰/۱۲۳	۰/۷۵۵	۰/۵۷	۰/۲۹۱	۰/۲۵۱	۰/۴۲	۰/۳۵۹
	اوت	۰/۱۰۷	۰/۰۷۲	۰/۸۴۹	۰/۷۱۹	۰/۲۰۶	۰/۱۶۱	۰/۴۸	۰/۳۵۷

۵-۲-۱-۲ پیش‌بینی با سه سیگنال:

در این مرحله از سه سیگنال اولی که بیشترین همبستگی را با بارش حداکثر ماهانه ایستگاه‌های مطالعاتی داشتند استفاده شد. مطابق جدول (۵-۸) برای بارش ایستگاه تنگراه بهترین مقادیر

R.RMSE و CNS به ترتیب برابر با ۰/۰۱۱، ۰/۹۹۹ و ۰/۹۹۷ در مرحله آموزش در ماه و ۰/۱۰۳، ۰/۹۲۱ و ۰/۸۸۴ در مرحله آزمون و برای ماه آوریل به دست آمد. برای بارش ایستگاه تمر بهترین مقادیر R.RMSE و CNS به ترتیب برابر با ۰/۰۲۵، ۰/۹۸۶ و ۰/۹۷۱ در مرحله آموزش در ماه فوریه و ۰/۱۱، ۰/۹۰۱ و ۰/۸۸۸ در مرحله آزمون و برای ماه مارس به دست آمد. برای بارش ایستگاه گالیکش بهترین مقادیر R.RMSE و CNS به ترتیب برابر با ۰/۰۳، ۰/۹۷۸ و ۰/۹۵۵ در مرحله آموزش و ۰/۰۸۳، ۰/۸۰۱ و ۰/۷۷۲ در مرحله آزمون و برای ماه فوریه به دست آمد.

جدول ۵-۸: نتایج آنالیز شبکه عصبی برای پیش‌بینی با سه سیگنال

ایستگاه	ماه	آموزش				آزمون			
		RMSE	MAE	R	CNS	RMSE	MAE	R	CNS
تنگراه	فوریه	۰/۰۴	۰/۰۱۸	۰/۹۸۶	۰/۹۷۲	۰/۱۷۷	۰/۱۵۷	۰/۸۲۸	۰/۸
	مارس	۰/۱۴۱	۰/۱۱۲	۰/۸۷۵	۰/۷۳۵	۰/۲۶۴	۰/۲۲۷	۰/۸۱	۰/۷۷۵
	آوریل	۰/۰۱۱	۰/۰۰۵	۰/۹۹۹	۰/۹۹۷	۰/۱۰۳	۰/۰۸۸	۰/۹۲۱	۰/۸۸۴
	اوت	۰/۰۳۶	۰/۰۲۷	۰/۹۸	۰/۹۵۹	۰/۲۵۹	۰/۲۱۲	۰/۷۷۶	۰/۷۳۴
تمر	فوریه	۰/۰۲۵	۰/۰۱۴	۰/۹۸۶	۰/۹۷۱	۰/۱۸۶	۰/۱۵۴	۰/۸۸۹	۰/۸۷۵
	مارس	۰/۱۵۸	۰/۱۰۶	۰/۸۳۷	۰/۶۹۶	۰/۱۱۶	۰/۰۹۷	۰/۹۰۱	۰/۸۸۸
	آوریل	۰/۱۷۵	۰/۱۲۸	۰/۷۴۹	۰/۵۵۷	۰/۱۳۷	۰/۱۱۴	۰/۸۸۸	۰/۷۲۳
	اوت	۰/۰۴۲	۰/۰۲۸	۰/۰۸۴	۰/۹۶۳	۰/۲۷۹	۰/۲۰۲	۰/۷۸۶	۰/۷۵۵
گالیکش	فوریه	۰/۰۷۵	۰/۰۳۷	۰/۹۱۴	۰/۸۲۳	۰/۰۸۳	۰/۴	۰/۸۰۱	۰/۷۷۲
	مارس	۰/۰۳۷	۰/۰۱۷	۰/۹۷۸	۰/۹۵۵	۰/۰۸۳	۰/۰۶۹	۰/۶۳۶	۰/۶۸۱
	آوریل	۰/۱۲۵	۰/۰۹۳	۰/۸۹۲	۰/۷۸۳	۰/۲۵۱	۰/۲۱۲	۰/۶۷۸	۰/۵۷۲
	اوت	۰/۰۵۹	۰/۰۳۴	۰/۹۶۱	۰/۹۲۳	۰/۱۶۴	۰/۱۳	۰/۷۹۵	۰/۷۵۱

۵-۲-۱-۳ پیش‌بینی با بهترین سیگنال‌ها:

همان‌طور که در بخش ۴-۲ توضیح داده شده در مدل ۳ از همه سیگنال‌هایی که دارای همبستگی معنی‌داری با بارش حداکثر ماه‌های موردبررسی دارند؛ استفاده شد. مطابق جدول (۵-۹) برای بارش ایستگاه تنگراه بهترین مقادیر R.RMSE و CNS به ترتیب برابر با ۰/۰۰۳، ۰/۹۹۸ و ۰/۹۹۷ در مرحله آموزش در ماه مارس و ۰/۰۶۷، ۰/۹۵ و ۰/۹۴۵ در مرحله آزمون و برای ماه اوت به دست آمد. برای

بارش ایستگاه تمر بهترین مقادیر R.RMSE و CNS به ترتیب برابر با ۰/۰۰۳، ۰/۹۹۸ و ۰/۹۹۷ در مرحله آموزش و ۰/۱۶، ۰/۹۴۸ و ۰/۹۳۱ در مرحله آزمون و برای ماه فوریه به دست آمد. برای بارش ایستگاه گالیکش بهترین مقادیر R.RMSE و CNS به ترتیب برابر با ۰/۰۰۴، ۰/۹۹۶ و ۰/۹۹۱ در مرحله آموزش و ۰/۰۴۴، ۰/۹۳۵ و ۰/۸۹۲ در مرحله آزمون و برای ماه فوریه به دست آمد.


جدول ۵-۹: نتایج آنالیز شبکه عصبی برای پیش‌بینی با بهترین سیگنال‌ها

ایستگاه	ماه	آموزش				آزمون			
		RMSE	MAE	R	CNS	RMSE	MAE	R	CNS
تنگراه	فوریه	۰/۰۳	۰/۰۲۲	۰/۹۹۲	۰/۹۸۵	۰/۰۹۳	۰/۰۷۴	۰/۸۷۸	۰/۸۶۶
	مارس	۰/۰۰۳	۰/۰۰۲	۰/۹۹۸	۰/۹۹۷	۰/۲۲۶	۰/۱۸۳	۰/۸۱۶	۰/۷۹
	آوریل	۰/۰۷۲	۰/۰۵۳	۰/۹۵۳	۰/۸۸۹	۰/۰۸۱	۰/۰۶۴	۰/۹۵۱	۰/۹۳۵
	اوت	۰/۰۳۶	۰۲۵/۰	۰/۹۸	۰/۹۵۹	۰/۰۶۷	۰/۰۵۵	۰/۹۵۰	۰/۹۴۵
تمر	فوریه	۰/۰۰۳	۰۰۱/۰	۰/۹۹۸	۰/۹۹۷	۰/۱۶۴	۰/۱۳۹	۰/۹۴۸	۰/۹۳۱
	مارس	۰/۰۲۶	۰/۰۰۷	۰/۹۹۶	۰/۹۹۲	۰/۲۰۶	۰/۱۹۱	۰/۹۴۰	۰/۸۸۴
	آوریل	۰/۰۹۴	۰/۰۶۸	۰/۹۳۴	۰/۸۷۲	۰/۱۹۸	۰/۱۸۰	۰/۹۱۹	۰/۸۹۶
	اوت	۰/۰۴	۰/۰۲۵	۰/۹۸۴	۰/۹۶۷	۰/۱۷۰	۰/۱۰۷	۰/۸۶۸	۰/۸۴۶
گالیکش	فوریه	۰/۰۱۷	۰/۰۰۶	۰/۹۹۶	۰/۹۹۱	۰/۱۲۹	۰/۱۱۶	۰/۹۰۷	۰/۸۸۲
	مارس	۰/۰۰۴	۰/۰۰۳	۰/۹۹۸	۰/۹۹۳	۰/۰۸۶	۰/۰۷۴	۰/۸۲۶	۰/۷۸۱
	آوریل	۰/۱۱۱	۰/۰۸۰	۰/۹۲	۰/۸۴۰	۰/۲۵۱	۰/۱۸۳	۰/۷۹۴	۰/۷۸۱
	اوت	۰/۰۸۶	۰/۰۶۴	۰/۹۳۴	۰/۸۳۶	۰/۰۴۴	۰/۱۰۱	۰/۹۳۵	۰/۸۹۲


در حالت کلی با بررسی معیارهای آماری نتایج حاصل از شبکه‌ی عصبی چندلایه با همه‌ی سیگنال‌ها به‌عنوان ورودی بهتر از سایر نتایج به‌دست‌آمده است.

در مرحله بعد نمودار پراکندگی بهترین نتایج به‌دست‌آمده وهم چنین خط رگرسیون بین مقادیر پیش-بینی و مشاهداتی و نمودار برای بارش حداکثر ماهانه به ترتیب برای ایستگاه‌های تنگراه، تمر و گالیکش در شکل‌های (۷-۵) تا (۱۲-۵) برای روش شبکه عصبی MLP در ماه‌های مختلف موردبررسی نشان داده‌شده است. در این نمودارها محور عمودی بارش پیش‌بینی‌شده و محور افقی بارش مشاهداتی می‌باشد. با بررسی مقادیر R^2 مشاهده می‌شود که دقت شبکه در پیش‌بینی بارش


خوب بوده است. همچنین در شکل (۵-۱۰) مقادیر حداکثر بارش پیش‌بینی شده توسط شبکه عصبی مصنوعی و مقادیر مشاهداتی برای داده‌های مرحله آزمون نشان داده شده است. این نمودارها نیز بیانگر دقت نسبتاً خوب شبکه‌ها با معماری‌های مختلف در پیش‌بینی مقادیر حدی بارش است. مقایسه نتایج آماری حاصل از پیش‌بینی با تعداد ورودی‌های مختلف نشان داد که هرچقدر تعداد ورودی‌ها بیشتر شود دقت شبکه در پیش‌بینی بیشتر می‌شود. با استفاده از این نتایج و همچنین شبکه‌های به‌دست‌آمده از هر سری زمانی در ماه‌های مختلف می‌توان وقایع حدی بارش در ماه‌های فوریه، مارس، آوریل و اوت را با دقت نسبتاً خوبی پیش‌بینی کرد. همچنین با توجه به اینکه سیل‌های بزرگی و مخربی در ماه اوت سال‌های ۲۰۰۱ و ۲۰۰۴ در ایستگاه تنگراه رخ داده است و حداکثر بارش ماهانه در ماه موردنظر تابع هدف می‌باشد، می‌توان گفت که با داشتن سیگنال‌ها در ماه‌های قبل با توجه به دقت قابل قبول شبکه می‌توان وقایع بارش حدی ایستگاه موردنظر را با توجه به سیگنال‌ها و مقادیر آن‌ها در ماه‌های قبل پیش‌بینی کرد.




شکل ۵-۷: خط رگرسیون بین مقادیر مشاهده‌ای و پیش‌بینی شده بارش ایستگاه تنگراه



شکل ۵-۸: خط رگرسیون بین مقادیر مشاهداتی و پیش‌بینی شده بارش ایستگاه تمر



شکل ۵-۹: خط رگرسیون بین مقادیر مشاهداتی و پیش بینی شده بارش ایستگاه گالیکش



شکل ۵-۱۰: مقایسه نتایج به دست آمده بارش پیش بینی شده ANN و بارش مشاهداتی ماه های مختلف ایستگاه های مطالعاتی

۵-۲-۲ پیش‌بینی دبی حداکثر ماهانه:

همان‌گونه که در بخش ۵-۲-۱ اشاره شد برای بررسی همبستگی مقادیر دبی حداکثر ماهانه و سیگنال‌های بزرگ‌مقیاس اقلیمی در سطح معنی‌داری ۵ درصد با تأخیرهای ۱ تا ۱۲ ماه استفاده شد. در ابتدا از یک سیگنال و برای دستیابی به نتایج بهتر از سیگنال‌های بیشتری به‌عنوان ورودی به شبکه عصبی مصنوعی استفاده شد. پس از انجام بررسی بر روی ضرایب همبستگی به‌دست‌آمده و معنی‌داری آن‌ها سیگنال‌های مختلف استفاده‌شده برای پیش‌بینی دبی حداکثر ماهانه در جدول (۵-۱۰) نشان داده‌شده است. مدل‌های مختلف استفاده‌شده در بخش‌های زیر آورده شده است

جدول ۵-۱۰- مدل‌های استفاده‌شده برای پیش‌بینی دبی حداکثر ماهانه

تأخیر	ایستگاه گالیکش	تأخیر	ایستگاه تمر	تأخیر	ایستگاه تنگراه	ماه	مدل ورودی
۲	SLP اقیانوس اطلس	۸	SLP خلیج عدن	۱۲	SLP شرق مدیترانه	فوریه	مدل ۱
۴	SLP خلیج عدن	۷	SST دریای سیاه	۵	SST دریای سیاه	مارس	
۸	SST دریای سیاه	۹	SST دریای سیاه	۸	SST دریای سیاه	آوریل	
۴	SLP دریای سیاه	۹	SLP اقیانوس اطلس	۴	SLP دریای سیاه	اوت	
۲	SLP اقیانوس اطلس	۸	SLP خلیج عدن	۱۲	SLP شرق مدیترانه	فوریه	مدل ۲
۶	SST گرینلند	۹	SLP دریای سیاه	۱۰	SLP شرق مدیترانه		
۷	SST گرینلند	۱۱	SST شبکه سوران	۱	SLP خلیج عدن		

	مارس	SST دریای سیاه	۵	SST دریای سیاه	۷	SLP خلیج عدن	۴
		SST گرینلند	۲	SST دریای خزر	۹	SLP غرب مدیترانه	۱
		SST شرق مدیترانه	۳	SST جنوب خلیج فارس	۸	SLP خلیج عدن	۲
	آوریل	SST دریای سیاه	۸	SST دریای سیاه	۹	SST دریای سیاه	۸
		SST دریای سیاه	۷	SST دریای سیاه	۷	SST دریای سیاه	۹
		SST دریای خزر	۸	SST دریای خزر	۸	SST جنوب خلیج فارس	۸
	اوت	SLP دریای سیاه	۴	SLP اقیانوس اطلس	۹	SLP دریای سیاه	۴
		SLP دریای خزر	۴	SLP اقیانوس اطلس	۶	SLP دریای سیاه	۳
		SLP دریای سیاه	۴	SLP اقیانوس اطلس	۹	SLP دریای سیاه	۴
	مدل ۳	SLP شرق مدیترانه	۱۲	SLP دریای سیاه	۲	SLP اقیانوس اطلس	۳
		SLP شرق مدیترانه	۱۰	SLP دریای سیاه	۹	SST گرینلند	۶
		SLP خلیج عدن	۱	SST شبکه سوران	۱۱	SST گرینلند	۷
		SST دریای سیاه	۳	SST اقیانوس اطلس	۱۲	SLP شرق مدیترانه	۱۰
		SST گرینلند	۶	SST گرینلند	۱۲	SLP اقیانوس اطلس	۱۰
		-	-	SST دریای خزر	۱۱	SST شبکه سوران	۱۱

		-	SST گرینلند	۶	SLP شرق مدیترانه	۱۲
مارس	SST دریای سیاه	۵	SLP خلیج عدن	۸	SLP غرب مدیترانه	۱
	SST گرینلند	۱	SST جنوب خلیج فارس	۹	SST گرینلند	۲
	SST گرینلند	۲	SST شرق مدیترانه	۹	SLP دریای سیاه	۴
	SST شرق مدیترانه	۳	SST دریای خزر	۹	SLP خلیج عدن	۴
	SST دریای خزر	۵	SST جنوب خلیج فارس	۸	SST شرق مدیترانه	۵
	SST شرق مدیترانه	۵	SST دریای خزر	۸	SST دریای سیاه	۵
	SST جنوب خلیج فارس	۵	SST دریای سیاه	۷	SLP دریای سیاه	۶
آوریل	SST دریای سیاه	۷	SST دریای سیاه	۶	SST جنوب خلیج فارس	۱۰
	SST دریای خزر	۸	SST دریای سیاه	۷	SST جنوب خلیج فارس	۹
	SST دریای سیاه	۸	SST دریای خزر	۸	SST دریای سیاه	۹
	SST جنوب خلیج فارس	۸	SST دریای سیاه	۸	SST جنوب خلیج فارس	۸
	SST دریای خزر	۹	SST دریای خزر	۹	SST دریای سیاه	۸
	SST دریای سیاه	۹	SST شرق مدیترانه	۹	SST دریای خزر	۸

۷	SST دریای سیاه	۹	SST دریای سیاه	۹	SST جنوب خلیج فارس	
۱	SST اقیانوس اطلس	۵	SLP اقیانوس اطلس	۳	SST شرق مدیترانه	اوت
۳	SLP دریای سیاه	۶	SLP اقیانوس اطلس	۳	SLP دریای سیاه	
۴	SLP دریای سیاه	۹	SLP اقیانوس اطلس	۴	SLP دریای خزر	
۵	SLP دریای خزر	۱۱	SST دریای خزر	۴	SLP دریای سیاه	
۶	SLP دریای خزر	۱۱	SLP اقیانوس اطلس	۵	SLP دریای خزر	
۷	SLP دریای خزر	۱۲	SST گرینلند	۸	SLP دریای خزر	
۸	SLP دریای خزر	۱۰	SST گرینلند	۱۲	SLP دریای خزر	

۱-۲-۲-۵ پیش‌بینی دبی حداکثر ماهانه با یک سیگنال:

در این مرحله از سیگنالی که بیشترین همبستگی را با مقادیر دبی حدی ماهانه داشت استفاده شد. از این سیگنال که دارای بیشترین همبستگی بود به‌عنوان ورودی و دبی حداکثر ماهانه ماه‌های فوریه، مارس، آوریل و اوت به‌عنوان توابع هدف استفاده شد. نتایج برای سه ایستگاه مختلف مورد مطالعه در ماه‌های مختلف در جدول زیر نشان داده شده است. مطابق جدول (۵-۱۱) برای دبی ایستگاه تنگراه بهترین مقادیر R ، $RMSE$ و CNS به ترتیب برابر با ۰/۰۰۱، ۰/۹۹۴ و ۰/۹۹۳ در مرحله آموزش و در ماه اوت و ۰/۰۳، ۰/۸۴۱ و ۰/۶۹۵ در مرحله آزمون و برای ماه آوریل به دست آمد. برای دبی ایستگاه تمر بهترین مقادیر R ، $RMSE$ و CNS به ترتیب برابر با ۰/۰۰۹، ۰/۹۹۸ و ۰/۹۹۷ در مرحله آموزش در ماه فوریه و ۰/۰۵۶، ۰/۹۳۹ و ۰/۸۷۲ در مرحله آزمون و برای ماه مارس به دست آمد. برای دبی

ایستگاه گالیکش بهترین مقادیر R, RMSE و CNS به ترتیب برابر با ۰/۰۱، ۰/۹۹۸ و ۰/۹۹۷ در مرحله آموزش و ۰/۰۱۵، ۰/۹۱۱ و ۰/۸۵۵ در مرحله آزمون و برای ماه اوت به دست آمد.

جدول ۵-۱۱: نتایج آنالیز شبکه عصبی برای پیش‌بینی با یک سیگنال

ایستگاه	ماه	آموزش				آزمون			
		RMSE	MAE	R	CNS	RMSE	MAE	R	CNS
تنگراه	فوریه	۰/۰۳۶	۰/۰۲	۰/۹۸۴	۰/۹۶۶	۰/۰۵۶	۰/۰۴۷	۰/۸۳۷	۰/۶۸۷
	مارس	۰/۱۱۱	۰/۰۶	۰/۹۰۳	۰/۸۱۴	۰/۱۶۳	۰/۱۳۴	۰/۷۵۷	۰/۶۵۷
	آوریل	۰/۰۰۸	۰/۰۰۶	۰/۹۹۷	۰/۹۹۵	۰/۰۳	۰/۰۶۳	۰/۸۴۱	۰/۶۹۵
	اوت	۰/۰۰۱	۰/۰۰۷	۰/۹۹۴	۰/۹۹۳	۰/۰۳۹	۰/۰۲۷	۰/۷۷۷	۰/۶۷۷
تمر	فوریه	۰/۰۰۹	۰/۰۰۵	۰/۹۹۸	۰/۹۹۷	۰/۱۲۵	۰/۰۹۹	۰/۷۴۵	۰/۷۲
	مارس	۰/۰۸۴	۰/۰۵۹	۰/۹۱	۰/۸۲۸	۰/۰۵۶	۰/۰۴۶	۰/۹۳۹	۰/۸۷۲
	آوریل	۰/۰۷۹	۰/۰۵۳	۰/۹۱	۰/۸۲۹	۰/۰۸۳	۰/۰۷۵	۰/۷۷۱	۰/۶۷۱
	اوت	۰/۰۳۹	۰/۰۱۷	۰/۹۳۲	۰/۸۶۴	۰/۱۳۹	۰/۱۵۷	۰/۸۵۲	۰/۷۱۷
گالیکش	فوریه	۰/۰۴۸	۰/۰۲۴	۰/۹۶۶	۰/۹۳۴	۰/۰۸۱	۰/۰۶۳	۰/۸۳۷	۰/۷۰۴
	مارس	۰/۱۲۲	۰/۰۶۸	۰/۸۳۴	۰/۶۹	۰/۳۳۲	۰/۲۷۵	۰/۶۴۸	۰/۵۸۲
	آوریل	۰/۰۱۳	۰/۰۰۹	۰/۹۹۷	۰/۹۹۵	۰/۰۳۶	۰/۰۲۵	۰/۷۳۲	۰/۶۶۱
	اوت	۰/۰۱	۰/۰۰۶	۰/۹۹۸	۰/۹۹۷	۰/۰۱۵	۰/۰۰۹	۰/۹۱۱	۰/۸۵۵

۵-۲-۲-۲ پیش‌بینی دبی حداکثر ماهانه با سه سیگنال:

در این مرحله از سه سیگنال اولی که بیشترین همبستگی را با دبی حداکثر ماهانه ایستگاه‌های مطالعاتی داشتند استفاده شد. مطابق جدول (۵-۱۲) برای دبی ایستگاه تنگراه بهترین مقادیر R, RMSE و CNS به ترتیب برابر با ۰/۰۰۱، ۰/۹۹۹ و ۰/۹۹۹ در مرحله آموزش در ماه اوت و ۰/۰۳۳، ۰/۸۸۶ و ۰/۸۱۴ در مرحله آزمون و برای ماه آوریل به دست آمد. برای دبی ایستگاه تمر بهترین مقادیر R, RMSE و CNS، به ترتیب برابر با ۰/۰۰۲، ۰/۹۹۹ و ۰/۹۹۹ در مرحله آموزش در ماه فوریه و ۰/۰۴۹، ۰/۹۴۵ و ۰/۸۸۶ در مرحله آزمون و برای ماه مارس به دست آمد. برای دبی ایستگاه گالیکش بهترین مقادیر R, RMSE و CNS به ترتیب برابر با ۰/۰۰۶، ۰/۹۹۹ و ۰/۹۹۸ در مرحله آموزش و ۰/۰۳۴، ۰/۹۳ و ۰/۸۶۵ در مرحله آزمون و برای ماه اوت به دست آمد.

جدول ۵-۱۲: نتایج آنالیز شبکه عصبی برای پیش‌بینی با سه سیگنال

ایستگاه	ماه	آموزش				آزمون			
		RMSE	MAE	R	CNS	RMSE	MAE	R	CNS
تنگراه	فوریه	۰/۰۳۹	۰/۰۲۴	۰/۹۸۲	۰/۹۶۲	۰/۰۳۲	۰/۰۲۶	۰/۸۵۲	۰/۷۷۱
	مارس	۰/۰۱	۰/۰۶۳	۰/۹۲۱	۰/۸۴۵	۰/۱۵۷	۰/۱۳۴	۰/۸۴۵	۰/۷۲۱
	آوریل	۰/۰۰۷	۰/۰۰۵	۰/۹۹۹	۰/۹۹۸	۰/۰۳۳	۰/۰۱۹	۰/۸۸۶	۰/۸۱۴
	اوت	۰/۰۰۱	۰/۰۰۱	۰/۹۹۹	۰/۹۹۹	۰/۰۳۴	۰/۰۱۸	۰/۷۸۶	۰/۷۴۱
تمر	فوریه	۰/۰۰۲	۰/۰۰۱	۰/۹۹۹	۰/۹۹۹	۰/۱۰۲	۰/۰۸۵	۰/۸۵۷	۰/۷۱۷
	مارس	۰/۰۸۱	۰/۰۵۳	۰/۹۱۷	۰/۸۴	۰/۰۴۹	۰/۰۳۹	۰/۹۴۵	۰/۸۸۶
	آوریل	۰/۰۸۱	۰/۰۵۲	۰/۹۱۲	۰/۸۲۷	۰/۰۴۸	۰/۰۳۵	۰/۸۲۵	۰/۷۸۶
	اوت	۰/۰۴۶	۰/۰۲۵	۰/۹۰۹	۰/۸۱۳	۰/۰۷۸	۰/۰۶۲	۰/۹۷۷	۰/۹۴۷
گالیکش	فوریه	۰/۰۱۸	۰/۰۱۲	۰/۹۹۵	۰/۹۹	۰/۰۶۶	۰/۰۵۳	۰/۸۹۵	۰/۸۴۷
	مارس	۰/۰۸۸	۰/۰۵	۰/۹۱۹	۰/۸۴	۰/۱۳۲	۰/۰۱۲	۰/۷۴۶	۰/۶۴۵
	آوریل	۰/۰۱۴	۰/۰۱	۰/۹۹۷	۰/۹۹۴	۰/۰۲	۰/۰۱۷	۰/۸۸	۰/۷۹۹
	اوت	۰/۰۰۶	۰/۰۰۴	۰/۹۹۹	۰/۹۹۸	۰/۰۳۴	۰/۰۱۹	۰/۹۳	۰/۸۶۵


۵-۲-۳ پیش‌بینی دبی حداکثر ماهانه با بهترین سیگنال‌ها:

همان‌طور که در بخش مواد و روش‌ها توضیح داده‌شده در مدل ۳ از همه سیگنال‌هایی که دارای همبستگی معنی‌داری با دبی حداکثر ماه‌های موردبررسی دارند؛ استفاده شد. مطابق جدول (۱۰) برای دبی ایستگاه تنگراه بهترین مقادیر $R, RMSE$ و CNS به ترتیب برابر با $0/0006$ ، $0/999$ و $0/999$ در مرحله آموزش در ماه اوت و $0/012$ ، $0/911$ و $0/86$ در مرحله آزمون و برای ماه آوریل به دست آمد. برای دبی ایستگاه تمر بهترین مقادیر $R, RMSE$ و CNS به ترتیب برابر با $0/006$ ، $0/998$ و $0/996$ در مرحله آموزش و $0/078$ ، $0/989$ و $0/958$ در مرحله آزمون و برای ماه اوت به دست آمد. برای دبی ایستگاه گالیکش بهترین مقادیر $R, RMSE$ و CNS به ترتیب برابر با $0/006$ ، $0/999$ و $0/99$ در مرحله آموزش و $0/011$ ، $0/941$ و $0/872$ در مرحله آزمون و برای ماه اوت به دست آمد. با توجه به موارد فوق، نتایج به‌دست‌آمده نشان می‌دهد که بهترین حالت جواب شبکه با در نظر گرفتن همه‌ی سیگنال‌ها به‌عنوان ورودی حاصل‌شده است. با رسم نمودار پراکندگی بهترین نتایج به‌دست‌آمده همبستگی مقادیر دبی حداکثر ماهانه شبیه‌سازی‌شده و مشاهداتی مقادیری قابل‌توجه است. نمودار دبی حداکثر ماهانه به ترتیب برای ایستگاه‌های تنگراه، تمر و گالیکش در شکل‌های (۵-۱۴) تا (۵-۱۶) برای روش شبکه عصبی MLP در ماه‌های مختلف نشان داده‌شده است. در این نمودارها محور عمودی دبی پیش‌بینی‌شده و محور افقی دبی مشاهداتی می‌باشد. شکل (۵-۱۴) نشان‌دهنده مقادیر حداکثر دبی پیش‌بینی‌شده توسط شبکه عصبی مصنوعی و مقادیر واقعی برای داده‌های مرحله آزمون است. این نمودارها نیز بیانگر دقت نسبتاً خوب شبکه‌ها با معماری‌های مختلف در پیش‌بینی مقادیر حدی دبی است. مقایسه نتایج آماری حاصل از پیش‌بینی نشان داد که با تأخیرهای مختلف و در نظر گرفتن همه‌ی سیگنال‌ها به‌عنوان ورودی پیش‌بینی‌ها در ماه‌های فوریه، مارس، آوریل و اوت از دقت نسبتاً خوبی برخوردار است.


همچنین با توجه به اینکه در سال‌های ۱۳۸۰ و ۱۳۸۴ سیل‌های مخربی در ایستگاه‌های مطالعاتی رخ داده است می‌توان گفت شبکه حاصل از نتایج با دقت خوبی می‌تواند وقایع دبی حداکثر ماه‌های مورد مطالعه در این تحقیق را با دقت نسبتاً خوب پیش‌بینی کند.

جدول ۵-۱۳: نتایج آنالیز شبکه عصبی برای پیش‌بینی با بهترین سیگنال‌ها


ایستگاه	ماه	آموزش				آزمون			
		RMSE	MAE	R	CNS	RMSE	MAE	R	CNS
تنگراه	فوریه	۰/۰۳۹	۰/۰۲۹	۰/۹۸۲	۰/۹۶۱	۰/۰۴۶	۰/۰۳۸	۰/۹۱۳	۰/۸۳
	مارس	۰/۰۰۸	۰/۰۵۶	۰/۹۵۱	۰/۹۰۳	۰/۰۰۸	۰/۰۰۶	۰/۸۸۷	۰/۷۷۱
	آوریل	۰/۰۰۷	۰/۰۰۶	۰/۹۹۹	۰/۹۹۸	۰/۰۱۲	۰/۰۱۱	۰/۹۱۱	۰/۸۶
	اوت	۰/۰۰۰۶	۰/۰۰۰۵	۰/۹۹۹	۰/۹۹۹	۰/۰۴۶	۰/۰۳۴	۰/۷۹۳	۰/۷۵۱
تمر	فوریه	۰/۰۰۸	۰/۰۰۵	۰/۹۹۹	۰/۹۹۸	۰/۰۰۵	۰/۰۰۴	۰/۹۵۵	۰/۹۰۶
	مارس	۰/۰۷۹	۰/۰۴۸	۰/۹۲۱	۰/۸۴۹	۰/۰۵۲	۰/۰۴۱	۰/۹۴۸	۰/۸۸۲
	آوریل	۰/۰۳۹	۰/۰۲۴	۰/۹۷۹	۰/۹۵۹	۰/۰۲۳	۰/۰۱۸	۰/۸۷۲	۰/۷۹۵
	اوت	۰/۰۰۶	۰/۰۰۳	۰/۹۹۸	۰/۹۹۶	۰/۰۷۸	۰/۰۷۱	۰/۹۸۹	۰/۹۵۸
گالیکش	فوریه	۰/۰۱۲	۰/۰۰۸	۰/۹۹۹	۰/۹۹۵	۰/۰۵۸	۰/۰۴۷	۰/۹۰۲	۰/۸۵۱
	مارس	۰/۰۸۴	۰/۰۷۱	۰/۹۶۱	۰/۸۲۷	۰/۰۹۲	۰/۰۰۸	۰/۸۷۸	۰/۷۲۸
	آوریل	۰/۰۱۱	۰/۰۰۹	۰/۹۹۸	۰/۹۹۶	۰/۰۱۷	۰/۰۱۴	۰/۹۰۸	۰/۸۶۴
	اوت	۰/۰۰۶	۰/۰۰۴	۰/۹۹۹	۰/۹۹	۰/۰۱۱	۰/۰۰۶	۰/۹۴۱	۰/۸۷۲




شکل ۵-۱۱: خط رگرسیون بین مقادیر مشاهداتی و پیش بینی شده دبی ایستگاه تنگراه



شکل ۵-۱۲: خط رگرسیون بین مقادیر مشاهداتی و پیش بینی شده دبی ایستگاه تمر



شکل ۵-۱۳: خط رگرسیون بین مقادیر مشاهده‌ای و پیش‌بینی شده دبی ایستگاه گالیکش



شکل ۵-۱۴: مقایسه نتایج به دست آمده دبی پیش بینی شده ANN و دبی مشاهداتی ماه های مختلف ایستگاه های مطالعاتی

۵-۲-۳ جمع‌بندی

در این فصل نقش سیگنال‌های بزرگ‌مقیاس اقلیمی در میزان بارش و دبی ماهانه حوضه آبریز مادرسو واقع در بالادست سد گلستان برای ۳ ایستگاه باران‌سنجی و ۳ ایستگاه هیدرومتری مهم در منطقه بررسی شد. برای این منظور سیگنال‌های مختلف اقلیمی و همچنین دما و فشار سطح دریا‌های نقاط مختلف کره‌ی زمین برای این مطالعه در نظر گرفته شدند. انجام تحلیل همبستگی و به دست آوردن ضرایب همبستگی، ارتباط بین این سیگنال‌های اقلیمی و دبی و دبی ماهانه در حوضه مطالعاتی را تأیید می‌نماید. مقادیر همبستگی هم برای داده‌های ماهانه و هم برای داده‌های حداکثر مجموع دبی و میانگین دبی ماهانه به دست آمد.

در مرحله دوم از سیگنال یا سیگنال‌هایی که بیشترین همبستگی را با مقادیر بارش و دبی حدی ماهانه را داشتند برای پیش‌بینی مقادیر حدی از ماه‌های دوم، سوم، چهارم و هشتم (فوریه، مارس، آوریل و اوت) سال به‌عنوان ماه‌های پر بارش و ماه هشتم که سیل‌های مهیبی در آن رخ داده است به روش شبکه عصبی مصنوعی استفاده شد. با استفاده از این نتایج و همچنین شبکه‌های به‌دست‌آمده از هر سری زمانی در ماه‌های مختلف می‌توان وقایع حدی بارش در ماه‌های فوریه، مارس، آوریل و اوت را با دقت نسبتاً خوبی پیش‌بینی کرد. به‌عنوان مثال، شاخص‌های عملکرد از جمله ریشه میانگین مربعات خطا، ضریب همبستگی و ضریب ناش-ساتکلیف برای حداکثر برای بارش ایستگاه باران‌سنجی تنگراه ۰/۰۶۷، ۰/۹۵ و ۰/۹۴۵ در ماه اوت و دبی ماهانه برای ایستگاه هیدرومتری تمر ۰/۰۷۸، ۰/۹۸۹ و ۰/۹۵۸ در ماه اوت، برای دوره آزمون به دست آمد. نتایج ارائه‌شده، به‌صورت شبکه‌های عصبی در این تحقیق، می‌تواند به‌صورت کارایی برای پیش‌بینی مقادیر ماهانه بارش و دبی حداکثر ایستگاه‌های مورد استفاده واقع شود.

۵-۲-۴ پیش‌بینی بارش و سیل اخیر مرداد ۱۳۹۳:

با توجه به گزارش شرکت آب منطقه‌ای استان گلستان در سال ۱۳۹۳ بارندگی در چند منطقه به‌صورت رگباری شدید رخ داده که دو مورد از این بارش‌های شدید در مردادماه و در ایستگاه‌های مطالعاتی تنگراه و تمر می‌باشد. این بارندگی‌های شدید مولد سیلاب در حوضه مورد مطالعه و ایستگاه‌های تنگراه و تمر شده است. با توجه به اهمیت ماه مرداد (شمسی) یا همان ماه اوت (میلادی) و اینکه سیل‌های سال ۱۳۸۰ و ۱۳۸۴ در این ماه رخ داده است از روش استفاده‌شده در این تحقیق، برای پیش‌بینی مقادیر حداکثر بارش و دبی ماه اوت از طریق شبکه‌های ذخیره‌شده پیش‌بینی بارش و دبی در سال ۱۳۹۳ برای بررسی میزان دقت شبکه‌ها و صحت‌سنجی استفاده شد. جداول (۵-۱۴) و (۵-۱۵) به ترتیب نشان‌دهنده‌ی مقادیر واقعی و پیش‌بینی‌شده بارش و دبی حداکثر ماه اوت با استفاده از شبکه عصبی مصنوعی استفاده‌شده در این تحقیق می‌باشد.

جدول ۵-۱۴: مقادیر مشاهداتی و پیش‌بینی‌شده بارش منجر به سیلاب مرداد ۱۳۹۳

ایستگاه مطالعاتی	بارندگی مولد سیلاب (میلی‌متر)	بارندگی پیش‌بینی‌شده (میلی‌متر)
تنگراه	۳۷/۵	۳۱/۶
تمر	۴۹	۴۶/۳

جدول ۵-۱۵: مقادیر مشاهداتی و پیش‌بینی‌شده دبی سیلاب مرداد ۱۳۹۳

ایستگاه مطالعاتی	حداکثر دبی سیلاب (مترمکعب بر ثانیه)	دبی پیش‌بینی‌شده (مترمکعب بر ثانیه)
تنگراه	۶۶	۷۴
تمر	۱۹۱	۱۷۳/۵

با توجه به جداول بالا و مقادیر پیش‌بینی‌شده بارش و دبی می‌توان نتیجه گرفت که شبکه‌های ذخیره‌شده حاصل از این تحقیق می‌تواند با دقت خوبی مقادیر بارش و دبی حداکثر ماهانه (به‌خصوص در ماه اوت) را پیش‌بینی کند.

فصل

۶

نتیجه‌گیری و پیشنهادات

۶-۱ نتیجه‌گیری:

در مناطق مختلف جهان به‌ویژه مناطق خشک و نیمه‌خشک تقاضا برای آب در همه‌ی بخش‌های خانگی، کشاورزی و صنعتی در حال افزایش است و تأمین آب در این مناطق با مشکل جدی روبه‌روست. با توجه به اینکه پیش‌بینی و پیش‌آگاهی میزان بارش و آب‌های سطحی در زندگی انسان و در برنامه‌های مدیریتی نقش اساسی و قابل‌توجهی دارد، مطالعه آن در نقاط مختلف ضروری است. در سال‌های اخیر بررسی برهم‌کنش بین عوامل آب و هوایی در خشکی، اقیانوس و جو موردتوجه بسیاری از دانشمندان علوم هواشناسی و اقلیم‌شناسی و هیدرولوژی قرار گرفته است. یکی از عوامل اصلی مؤثر بر نوسانات اقلیمی سالانه کره‌ی زمین سیگنال‌های هواشناسی پیوند از دور در مقیاس جهانی و ناحیه‌ای است که از مهم‌ترین آن‌ها می‌توان به پدیده‌ی النینو نوسانات جنوبی (ENSO)، نوسان اصلی شمالی (NAO)، نوسان قطبی (AO)، نوسان دهه‌ای اقیانوس آرام (PDO)، نوسان جنوبی (SOI)، اشاره نمود. از دیگر روش‌های پیش‌بینی آب و هوایی، استفاده از علامت‌ها و پدیده‌های مشخصی از قبیل تغییرات دوره‌ای فشار سطح دریا (SLP) و تغییرات دوره‌ای دمای سطح دریا (SST) و مانند این‌ها است که از آن‌ها بانام سیگنال‌های بزرگ‌مقیاس اقلیمی یاد می‌شود.

همان‌طور که مطالعات پژوهشگران نشان داد سیگنال‌های اقلیمی به‌عنوان متغیر پیش‌بینی‌کننده در بارش، خشک‌سالی، سیل و ... مورد استفاده قرار می‌گیرند و تأثیر این سیگنال‌ها در مناطق مختلف متفاوت است. تاکنون تأثیر این سیگنال‌ها در حوزه آبریز بالادست سد گلستان مورد مطالعه جدی قرار نگرفته و از طرفی پیش‌آگاهی بارش با روش‌های نوین و پیشرفته در این منطقه به‌خاطر کمبود منابع آب و اینکه مسئله تأمین آب با بحران جدی روبه‌روست و نیاز به مدیریت بهینه دارد امری ضروری و بااهمیت است. از این‌رو هدف اصلی این پژوهش بررسی میزان تأثیر سیگنال‌های بزرگ‌مقیاس اقلیمی بر بارش و دبی حوزه آبریز مطالعاتی و درنهایت ارائه مدل پیش‌بینی بارش و دبی با استفاده از سیگنال‌های بزرگ‌مقیاس اقلیمی و روش‌های هوش محاسباتی می‌باشد.

در این مطالعه نقش سیگنال‌های بزرگ‌مقیاس اقلیمی در میزان بارش و دبی ماهانه حوضه آبریز مادرسو واقع در بالادست سد گلستان برای ۳ ایستگاه باران‌سنجی و ۳ ایستگاه هیدرومتری مهم در منطقه بررسی شد. برای این منظور سیگنال‌های مختلف اقلیمی شامل Nino 1+2 و غیره و همچنین دما و فشار سطح دریاهای نقاط مختلف کره‌ی زمین برای این مطالعه در نظر گرفته شدند. انجام تحلیل همبستگی و به دست آوردن ضرایب همبستگی، ارتباط بین این سیگنال‌های اقلیمی و بارش و دبی ماهانه در حوضه مطالعاتی را تأیید می‌نماید. مقادیر همبستگی هم برای داده‌های ماهانه و هم برای داده‌های حداکثر مجموع بارش و میانگین دبی ماهانه به دست آمد.

در مقیاس ماهانه، حداکثر همبستگی مجموع بارش و میانگین دبی ایستگاه‌های مطالعاتی برای سیگنال‌های اقلیمی با شاخص Nino 1+2 و برای داده‌های دمای سطح دریاهای گرینلند، شمال و جنوب خلیج فارس، جنوب دریای سرخ و شبکه سوران و با فشار سطح دریا خزر به دست آمد و این بدان معنا است که این شاخص بیش‌ترین تأثیر را بر بارش و دبی ماهانه حوضه‌ی آبریز مطالعاتی دارد. حداکثر میزان همبستگی شاخص Nino 1+2 با داده‌های ماهانه ایستگاه باران‌سنجی و هیدرومتری گالیکش به ترتیب ۰/۴۰ و ۰/۵۱ با تأخیر ۱۱ و ۱۳ ماه می‌باشد. با انجام تحلیل روی داده‌های دمای سطح دریا نیز بیش‌ترین ضریب همبستگی برای داده‌های بارش ۰/۴۵۵، ۰/۴۷۸ و ۰/۴۴ با تأخیرهای ۶ و ۳ و ۹ ماهه و برای داده‌های دبی نیز ۰/۴۴۲، ۰/۵۷۶ و ۰/۵۵۲ با تأخیرهای ۲ و ۷ و ۱۵ ماهه به دست آمده است. همچنین با انجام بررسی روی داده‌های فشار سطح دریا نیز بیش‌ترین ضریب همبستگی برای بارش و ۰/۴۲۵ با تأخیرهای ۷ و ۹ و ۹ ماهه و برای داده‌های دبی نیز ۰/۵۹۴، ۰/۴۳۳ و ۰/۶۱ با تأخیر ۹ ماهه به دست آمده است. در کل ارتباط قوی میان بارش ایستگاه‌های تنگراه و تمر با SLP دریای خزر و گالیکش با SST دریای خزر و دبی ایستگاه‌های تنگراه و SLP دریای خزر و ایستگاه تمر با SST منطقه گرینلند وجود دارد.

بیشترین میزان همبستگی حداکثر بارش ماهانه ایستگاه تنگراه در ماه می برابر با ۰/۶۴۱ با SST شرق مدیترانه با تأخیر ۷ ماه، برای ایستگاه تمر در ماه اکتبر برابر با ۰/۵۳۷ با SLP غرب دریای مدیترانه با تأخیر ۱۱ ماهه و برای ایستگاه گالیکش در ماه اوت برابر با ۰/۴۹۵ با SLP اقیانوس اطلس با تأخیر ۴ ماهه به دست آمد. بیشترین میزان همبستگی دبی ایستگاه‌های تنگراه، تمر و گالیکش با ماه آوریل به ترتیب برابر با ۰/۹۳۷، ۰/۷۸۲ و ۰/۹۲۶ با تأخیر ۸ ماهه و با SLP خلیج عدن به دست آمد. همچنین بررسی معنی‌داری این ضرایب به‌دست‌آمده از طریق P-Value نشان‌دهنده معنی‌دار بودن همه‌ی این ضرایب می‌باشد. همچنین برای پیش‌بینی بارش و دبی حداکثر ماهانه ایستگاه‌های مطالعاتی از داده‌های سیگنال‌هایی که دارای بیشترین همبستگی با مقادیر بارش و دبی حداکثر ماهانه هستند استفاده شد.

در مرحله پیش‌بینی از هرکدام از این سیگنال‌ها برای پیش‌بینی بارش و دبی حداکثر ماهانه در ماه‌های دوم، سوم و چهارم میلادی سال به‌عنوان ماه‌های پربارش و همچنین ماه هشتم سال میلادی به‌عنوان ماهی که سیل‌های بزرگی مانند سیل‌های سال ۱۳۸۰ و ۱۳۸۴ در آن رخ داده استفاده شد. برای پیش‌بینی از روش شبکه‌های عصبی مصنوعی چندلایه طبق موارد توضیح داده‌شده در بخش مواد و روش‌ها استفاده شد. همچنین با انتخاب یک شبکه پرسپترون چندلایه و الگوریتم پس انتشار خطا، مقادیر بارش و دبی حداکثر ماهانه شبیه‌سازی شد. شبکه‌های استفاده‌شده در مطالعه حاضر دارای ۳ لایه است. لایه‌ی اول ورودی، لایه دوم به‌عنوان لایه پنهان و لایه سوم به‌عنوان خروجی در نظر گرفته شدند. همچنین تعداد نورون‌های لایه میانی با سعی و خطا بین ۱ تا ۲۰ نورون به دست آمد. در این بررسی از الگوریتم لونبرگ-مارکوات برای آموزش شبکه و همچنین تابع انتقال سیگموئیدی در لایه مخفی و تابع انتقال خطی در لایه‌ی خروجی استفاده‌شده است این شبکه‌ها دارای یک یا چند ورودی به‌عنوان سیگنال‌هایی که بیشترین همبستگی را با مقادیر بارش و دبی حداکثر ماهانه در بررسی همبستگی دارا بود و یک خروجی به‌عنوان مدل پیش‌بینی می‌باشد.

با استفاده از این نتایج و همچنین شبکه‌های به‌دست‌آمده از هر سری زمانی در ماه‌های مختلف می‌توان وقایع حدی بارش و دبی در ماه‌های فوریه، مارس، آوریل و اوت را با دقت نسبتاً خوبی پیش‌بینی کرد. به‌عنوان مثال، شاخص‌های عملکرد از جمله ریشه میانگین مربعات خطا، ضریب همبستگی و ضریب ناش- ساتکلیف برای حداکثر بارش ایستگاه باران‌سنجی تنگراه ۰/۰۶۷، ۰/۹۵ و ۰/۹۴۵ در ماه اوت و دبی ماهانه برای ایستگاه هیدرومتری تمر ۰/۰۷۸، ۰/۹۸۹ و ۰/۹۵۸ در ماه اوت، برای دوره آزمون به دست آمد. درنهایت شبکه‌های عصبی ذخیره‌شده برای پیش‌بینی بارش و دبی سیلاب مرداد اخیر ۱۳۹۳ مورد استفاده قرار گرفته و نتایج قابل‌قبولی به دست آمد.

۲-۶ پیشنهادات:

- ۱- استفاده از سایر روش‌های هوش محاسباتی مانند ANFIS, SVM, Wavelet-ANN و ...
- ۲- استفاده از شبکه‌های بیزین برای پیش‌بینی بارش و دبی
- ۳- با توجه به نتایج رضایت‌بخش استفاده از سیگنال‌های پیوند از دور در پیش‌بینی بارش و دبی ماهانه در منطقه تحقیق استفاده از این سیگنال‌ها برای پیش‌بینی بارش و دبی در سایر مناطق کشور

فصل

٧

منابع و مأخذ

۱. اژدری مقدم. م، خسروی. م، حسین پور نیکنام. ح، جعفری ندوشن. ا. ۱۳۹۱. "پیش‌بینی خشک‌سالی با استفاده از مدل فازی-عصبی، شاخص‌های اقلیمی، بارندگی و شاخص خشک‌سالی (مطالعه موردی: زاهدان)". جغرافیا و توسعه ۲۶: ۶۲-۷۲.
۲. اسفندیاری درآباد، فریبا، حسینی، اسعد، آزادی مبارکی، محمد و زهرا حجازی زاده (۱۳۸۹)، پیش‌بینی میانگین دمای ماهانه ایستگاه سینوپتیک سنندج با استفاده از مدل شبکه‌ی عصبی مصنوعی پرسپترون چندلایه، مجله جغرافیا، سال هشتم، شماره ۲۷
۳. اصغری مقدم، اصغر، نورانی، وحید و عطاالله ندیری ۱۳۸۷، مدل‌سازی دبی دشت تبریز با استفاده از شبکه‌های عصبی مصنوعی، مجله دانش کشاورزی، جلد ۱۸، شماره ۱
۴. البرزی. م. ۱۳۸۳. آشنایی با شبکه‌های عصبی. چاپ دوم. موسسه انتشارات علمی دانشگاه صنعتی شریف
۵. پوستی زاده. ن، محمدولی سامانی. ج، کوره‌پزان دزفولی. ا. ۱۳۸۷. "پیش‌بینی جریان رودخانه با استفاده از سیستم استنتاج فازی". تحقیقات منابع آب ایران ۴: ۲۳-۳۴.
۶. حجازی زاده. ز، فتاحی. ا، سلیقه. م، ارسلانی. ف. ۱۳۹۲. "بررسی تأثیر سیگنال‌های اقلیمی بر بارش ناحیه مرکزی ایران با استفاده از شبکه عصبی مصنوعی". فصلنامه تحقیقات کاربردی علوم جغرافیایی ۲۹: ۷۶-۸۹.
۷. خسروی. م، غیور. ح.ع. ۱۳۸۰. "تأثیرات پدیده انسو روی ناهنجاری‌های بارش تابستانه و پاییزه جنوب ایران". فصلنامه تحقیقات جغرافیایی ۶۲: ۱۴۱-۷۴.
۸. خلیلی، نجمه، خداشناس، سعید رضا، داوری، کامران و محمد موسوی بایگی (۱۳۸۷)، پیش‌بینی دبی ماهانه با استفاده از شبکه‌های عصبی مصنوعی، مجله علوم و صنایع کشاورزی، ویژه آب‌و‌خاک، جلد ۲۲، شماره ۱

۹. ز. ابیانہ ورکشی. م، مطالعه تأثیر پذیری تعداد روزهای بارانی از پدیده انسو در ایران، مجله پژوهش‌های حفاظت آب و خاک. ۱۳۹۱، ۱۹: ۲۱-۳۹
۱۰. فلاح قاله‌ری. غ، ۱۳۸۹، ارزیابی نقش تغییرات سیگنال‌های اقلیمی بر نوسان‌های دبی بهاره استان خراسان رضوی، مجله فیزیک زمین و فضا، دوره، ۳: ۱۷۱-۱۵۵
۱۱. صداقت کردار. ع، فتاحی. ا. ۱۳۸۷. "شاخص‌های پیش‌آگاهی خشک‌سالی در ایران." نشریه جغرافیا و توسعه ۱۱: ۵۹-۷۶.
۱۲. عبقری. ه. ۱۳۸۴. "کاربردهای شبکه عصبی مصنوعی در مدیریت منابع آب." سمینار دوره‌ی دکتری رشته آب‌خیزداری، دانشکده منابع طبیعی، دانشگاه تهران.
۱۳. عراقی نژاد. ش، کارآموز. م. ۱۳۸۴. "پیش‌بینی بلندمدت رواناب با استفاده از شبکه‌های عصبی مصنوعی و سیستم استنتاج فازی." فصلنامه تحقیقات منابع آب ایران ۲: ۲۹-۴۱.
۱۴. عزیزی. غ. ج، یاراحمدی. ع. ۱۳۸۶. "بررسی تحلیلی ارتباط بین بارش فصلی و شاخص آب و هوایی." تحقیقات علوم جغرافیایی ۶۲: ۱۶۱-۱۷۴.
۱۵. فاتحی مرج. ا، مهدیان. م. خ. ۱۳۸۸. "پیش‌بینی بارش پاییزه با استفاده از شاخص‌های انسو به روش شبکه عصبی در حوضه دریاچه ارومیه." پژوهش‌های آب‌خیزداری ۸۴: ۵۲-۴۳.
۱۶. فتاحی. ا، دلاور. م، نوحی. ک. ۱۳۹۱. "پیش‌بینی جریان رودخانه‌های کارون شمالی با استفاده از شبکه عصبی مصنوعی." فصلنامه تحقیقات جغرافیایی ۱: ۵۱-۷۸.
۱۷. فلاح قاله‌ری. غ. ۱۳۸۵. "پیش‌بینی بارش فصلی بر اساس الگوهای سینوپتیکی با استفاده از تئوری مجموعه‌های فازی." دانشگاه فردوسی مشهد.

۱۸. فلاح قاله‌ری. غ، موسوی بایگی. م، حبیبی نو خندان. م. ۱۳۸۸. "پیش‌بینی بارش فصلی بر اساس الگوهای سینوپتیکی با استفاده از سیستم استنباط فازی - عصبی تطبیقی (ANFIS). پژوهش‌های جغرافیای طبیعی ۶۶: ۱۲۱-۱۴۹.
۱۹. قاله‌ری. غ، فلاح. ۱۳۹۰. "ارزیابی نقش تغییرات سیگنال‌های اقلیمی بر نوسان‌های بارش بهاره استان خراسان رضوی." مجله فیزیک زمین و فضا ۳: ۱۷۱-۱۵۵.
۲۰. مدرس پور. ع. ۱۳۷۶. "تأثیر پدیده انسو روی بارش و دمای ایران." مجله نیاور ۳۳: ۶۷-۷۷.
۲۱. معتمدی. م، احترامیان. ک، شهاب فر. ا.ح. ۱۳۸۶. "مطالعه ارتباط بین پدیده انسو در نقش سیگنال‌های هواشناسی و نوسانات بارش و دمای استان خراسان." پژوهش‌های محیط‌زیست ۴: ۷۵-۹۰.
۲۲. منه‌اج. م.ب. ۱۳۸۴. مبانی شبکه‌های عصبی مصنوعی. مرکز نشر دانشگاه صنعتی امیرکبیر.
۲۳. ناظم السادات. م.ج، قاسمی. ا.ر. ۱۳۸۳. "تأثیر نوسان‌های دمای سطح آب دریای خزر بر بارش فصول زمستان و بهار نواحی شمالی و جنوب غربی ایران." علوم و فنون کشاورزی و منابع طبیعی ۴: ۱-۱۴.
۲۴. نبی زاده. م، مساعدی. ا، حسام. م، دهقانی. ا.ا. ۱۳۹۱. "مقایسه عملکرد مدل‌های مبتنی بر منطق فازی در پیش‌بینی آبدهی روزانه رودخانه ليقوان." پژوهش‌های حفاظت آب‌و خاک ۱۹: ۱۱۷-۱۳۴.
۲۵. نوری. م. ۱۳۸۵. "شبیه‌سازی فرآیند بارندگی- رواناب حوضه آبریز هلیل رود و غازان چای با استفاده از شبکه‌های عصبی- موجکی." دانشگاه شهید باهنر کرمان.

26. Acharya, N. Kar, S. C, Mohanty, U. C, Kulkarni, M. A, & Dash, S. K. (2011). Performance of GCMs for seasonal prediction over India—a case study for 2009 monsoon. *Theoretical and Applied Climatology*, 105(3-4), 505–520.
27. Alexander, David E. 1999. Rhodes Whitmore Fairbridge. *Encyclopedia of environmental science*.
28. Angell, J. K. 1981. “Comparison of Variations in Atmospheric Quantities with Sea Surface Temperature Variations in the Equatorial Eastern Pacific.” *Monthly Weather Review* 109(2): 230–43.
29. Aqil, Muhammad, Ichiro Kita, Akira Yano, and Soichi Nishiyama. 2007. “Analysis and Prediction of Flow from Local Source in a River Basin Using a Neuro-Fuzzy Modeling Tool.” *Journal of Environmental Management* 85: 215–23.
30. Baratti, R. B. Cannas, A. Fanni, M. Pintus, G.M. Sechi, and N. Toreno. 2003. “River Flow Forecast for Reservoir Management through Neural Networks.” *Neurocomputing* 55(3-4): 421–37.
31. Barnston, Anthony G. and Robert E. Livezey. 1987. “Classification, Seasonality and Persistence of Low-Frequency Atmospheric Circulation Patterns.” *Monthly Weather Review* 115(6): 1083–1126.
32. Biondi, Franco, Alexander Gershunov, and Daniel R. Cayan. 2001. “North Pacific Decadal Climate Variability since 1661.” *Journal of Climate* 14(1): 5–10.
33. Chen, Ge, Chengcheng Qian, and Caiyun Zhang. 2012. “New Insights into Annual and Semiannual Cycles of Sea Level Pressure.” *Monthly Weather Review* 140(4): 1347–55.
34. Coulibaly, P. F. Anctil, and B. Bobée. 2000. “Daily Reservoir Inflow Forecasting Using Artificial Neural Networks with Stopped Training Approach.” *Journal of Hydrology* 230(3-4): 244–57.
35. Dawson DW, Wilby R. 1998. “An Artificial Neural Network Approach to Rainfall Runoff Modeling.” *Hydrological Sciences Journal* 43: 47–66.

36. Demuth, H. Beale, M. 2000. Neural Network Toolbox Users Guide. By The Math Works.
37. Dibike, Y.B. and D.P. Solomatine. 2001. "River Flow Forecasting Using Artificial Neural Networks." *Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere* 26(1): 1–7.
38. Farokhnia, Ashkan, Saeed Morid, and Hi-Ryong Byun. 2010. "Application of Global SST and SLP Data for Drought Forecasting on Tehran Plain Using Data Mining and ANFIS Techniques." *Theoretical and Applied Climatology* 104(1-2): 71–81.
39. Fausett, Laurene V. 1993. *Fundamentals of Neural Networks: Architectures, Algorithms and Applications* [Paperback]. Pearson; 1 edition.
40. Gámiz-Fortis, S.R. M.J. Esteban-Parra, R.M. Trigo, and Y. Castro-Díez. 2010. "Potential Predictability of an Iberian River Flow Based on Its Relationship with Previous Winter Global SST." *Journal of Hydrology* 385(1-4): 143–49.
41. Ghalkhani, Hossein, Saeed Golian, Bahram Saghafian, Ashkan Farokhnia, and Asaad Shamseldin. 2013. "Application of Surrogate Artificial Intelligent Models for Real-Time Flood Routing." *Water and Environment Journal* 27(4): 535–48.
42. Grimm, Alice M. Simone E. T. Ferraz, and Júlio Gomes. 1998. "Precipitation Anomalies in Southern Brazil Associated with El Niño and La Niña Events." *Journal of Climate* 11(11): 2863–80.
43. Haltiner, G. A. and Williams. 1980. *Numerical Prediction and Dynamic Meteorology* [Hardcover]. Wiley; 2 edition.
44. Hansen, James, and Sergej Lebedeff. 1987. "Global Trends of Measured Surface Air Temperature." *Journal of Geophysical Research* 92(D11): 13345.
45. Haykin.S. 1994. "Neural Networks: A Comprehensive Foundation." In *Neural Networks: A Comprehensive Foundation*, 1st edition.
46. Hodges, G. 2000. "The New Cold War. Stalking Arctic Climate Change by Submarine." *National Geographic* 11: 30–41.

47. Hurrell, J W. 1995. "Decadal Trends in the North Atlantic Oscillation: Regional Temperatures and Precipitation." *Science* (New York, N.Y.) 269(5224): 676–79.
48. Hughes, B.L. and A.M. Saunders. 2001. Seasonal prediction of European spring, prediction from ENSO and local SST-International. *J. Climatol.* 14:1-23.
49. Jochen, S. and Wolfgang, J. 2007. "Forecasting the Flood-Pulse in Central Amazonia by ENSO-Indices." *Journal of Hydrology* 335(1-2): 124–32.
50. K. A. Browning, Robert J. Gurney. 1999. "Global Energy and Water Cycles." Cambridge University.
51. Kahya, Ercan, and John A. Dracup. 1993. "U.S. Streamflow Patterns in Relation to the El Niño/Southern Oscillation." *Water Resources Research* 29(8): 2491–2503.
52. Karabork, M. and E Kahya. 2003. "The Teleconnections between the Extreme Phases of the Southern Oscillation and Precipitation Patterns over Turkey." *International Journal of Climatology* 23(13): 1607–25.
53. Kisi, Ozgur, and H. Kerem Cigizoglu. 2007. "Comparison of Different ANN Techniques in River Flow Prediction." *Civil Engineering and Environmental Systems* 24(3): 211–31.
54. RAO, P. W. L. SMITH, and R. KOFFLER. 1972. "Global Sea-Surface Temperature Distribution Determined From an Environmental Satellite." *Monthly Weather Review* 100(1): 10–14.
55. Lorenz, Edward N. 1951. "SEASONAL AND IRREGULAR VARIATIONS OF THE NORTHERN HEMISPHERE SEA-LEVEL PRESSURE PROFILE." *Journal of Meteorology* 8(1): 52–59.
56. Mantua, Nathan J. Steven R. Hare, Yuan Zhang, John M. Wallace, and Robert C. Francis. 1997. "A Pacific Interdecadal Climate Oscillation with Impacts on Salmon Production." *Bulletin of the American Meteorological Society* 78(6): 1069–79.

57. Marshall, John, Yochanan Kushnir, David Battisti, Ping Chang, Arnaud Czaja, Robert Dickson, James Hurrell, Michael McCartney, R. Saravanan, and Martin Visbeck. 2001. "North Atlantic Climate Variability: Phenomena, Impacts and Mechanisms." *International Journal of Climatology* 21(15): 1863–98.
58. Modarres, R. 2009. "Multi-Criteria Validation of Artificial Neural Network Discharge-Runoff Modeling." *Hydrol. Earth Syst* 13: 411–21.
59. Mukerji, Aditya, Chandranath Chatterjee, and Narendra Singh Raghuwanshi. 2009. "Flood Forecasting Using ANN, Neuro-Fuzzy, and Neuro-GA Models." *Journal of Hydrologic Engineering* 14(6): 647–52.
60. Nash, J.E. and J.V. Sutcliffe. 1970. "River Flow Forecasting through Conceptual Models Part I — A Discussion of Principles." *Journal of Hydrology* 10(3): 282–90.
61. Nazemosadat, M.J. and I. Cordery. 2000. "On the Relationships between ENSO and Autumn Rainfall in Iran." *International Journal of Climatology* 20(1): 47–61.
62. Nicholls, Neville. 1989. "Sea Surface Temperatures and Australian Winter Rainfall." *Journal of Climate* 2(9): 965–73.
63. Nicholson, Sharon E. Dorcas Leposo, and Jeremy Grist. 2001. "The Relationship between El Niño and Drought over Botswana." *Journal of Climate* 14(3): 323–35.
64. Partal, Turgay, and Özgür Kişi. 2007. "Wavelet and Neuro-Fuzzy Conjunction Model for Precipitation Forecasting." *Journal of Hydrology* 342(1-2): 199–212.
65. PERALTA-HERNÁNDEZ, A. R. Jr. R. C. BALLING, and L. R. BARBA-MARTÍNEZ. "Comparative Analysis of Indices of Extreme Rainfall Events: Variations and Trends from Southern México." *Atmósfera* 22(2): 219–28.
66. Revadekar, J. V. and Ashwini Kulkarni. 2008. "The El Nino-Southern Oscillation and Winter Precipitation Extremes over India." *International Journal of Climatology* 28(11): 1445–52.

67. Rogers, Jefery C. and Harry Van Loon. 1979. "The Seesaw in Winter Temperatures between Greenland and Northern Europe. Part II: Some Oceanic and Atmospheric Effects in Middle and High Latitudes." *Monthly Weather Review* 107(5): 509–19.
68. Simon Haykin. 1999. *Neural Networks: A Comprehensive Foundation*. Second. Prentice Hall International Editions Series.
69. Sun, Ranhao, Liding Chen, and Bojie Fu. 2011. "Predicting Monthly Precipitation with Multivariate Regression Methods Using Geographic and Topographic Information." *Physical Geography* 32(3): 269–85.
70. Thompson, David W. J. and John M. Wallace. 1998. "The Arctic Oscillation Signature in the Wintertime Geopotential Height and Temperature Fields." *Geophysical Research Letters* 25(9): 1297–1300.
71. Trenberth, K. E. 1996. *El Niño - Southern Oscillation*. John Wiley & Sons Ltd.
72. Trenberth, Kevin E. 1984. "Signal versus Noise in the Southern Oscillation." *Monthly Weather Review* 112(2): 326–32.
73. Trenberth, Kevin E. and Timothy J. Hoar. 1996. "The 1990-1995 El Niño-Southern Oscillation Event: Longest on Record." *Geophysical Research Letters* 23(1): 57–60.
74. Trenberth, Kevin E. and David P. Stepaniak. 2001. "Indices of El Niño Evolution." *Journal of Climate* 14(8): 1697–1701.
75. Walker, G.T. and E. W. Bliss. 1932. "Southern Oscillation (SO) Index." *World weather V. Mem. Roy. Meteorol* 4: 53 – 84.
76. Wallace, John M. and David S. Gutzler. 1981. "Teleconnections in the Geopotential Height Field during the Northern Hemisphere Winter." *Monthly Weather Review* 109(4): 784–812.
77. Wei, Shouke, Hong Yang, Jinxi Song, Karim Abbaspour, and Zongxue Xu. 2013. "A Wavelet-Neural Network Hybrid Modelling Approach for Estimating

and Predicting River Monthly Flows.” *Hydrological Sciences Journal* 58(2): 374–89.

78. WMO/UNEP. 1998. *Scientific Assessment of Ozone Depletion*.

79. Wolter, Klaus. 1987. “The Southern Oscillation in Surface Circulation and Climate over the Tropical Atlantic, Eastern Pacific, and Indian Oceans as Captured by Cluster Analysis.” *Journal of Climate and Applied Meteorology* 26(4): 540–58.

Abstract:

In the present research, the effect of large scale climate signals including Nino1+2, Nino3, Nino4, and Nino3, 4, MEI, TNI, AO, NAO, SOI, and PDO, SST and SLP on precipitation and discharge of Madarsoo watershed at upstream of Golestan dam was investigated. For this purpose, three raingauges and hydrometric stations with 40 and 38 years of daily rainfall and discharge data were selected. The correlation coefficients were calculated for total and maximum monthly precipitation and also average and maximum monthly discharge data. Based on results of correlation analysis, different models with various combination of inputs are used for rainfall forecasting. These models are all based on ANN technique. For Galikesh raingauge and hydrometric station, the maximum correlation coefficients between monthly rainfall and discharge data with Nino1+2 index calculated to be 0.4 and 0.51 with 11 and 13 months lag, respectively. Analyzing SST data, maximum correlation coefficients for precipitation data of Tangrah, Tamer and Galikesh raingauges equaled to 0.455, 0.478 and 0.44 with 6, 3 and 9 months lag, respectively and for discharge data of Tangrah, Tamer and Galikesh hydrometric stations the correlation values were 0.442, 0.576 and 0.552 with lag of 2, 7 and 15 months, respectively. Analyzing SLP data showed that the maximum correlation coefficients for total precipitation data of Tangrah, Tamer and Galikesh raingauges equaled to 0.487, 0.487 and 0.425 with 7, 9 and 9 months of lag, respectively; For discharge data of Tangrah, Tamer and Galikesh hydrometric stations the correlation values were 0.594, 0.433 and 0.61, respectively all with 9 months lag. The highest correlations were obtained for maximum monthly precipitation of Tangrah, is 0.641 with a lag of 7 months at May with Eastern Mediterranean SST, for Tamer, 0.537 with a lag of 11 months at October with SLP of West Meditterian sea and for Galikesh, is 0.495 with a lag of 11 months at July with Atlas ocean SLP. For maximum monthly discharges, the highest correlation coefficients were calculated as 0.937, 0.782 and 0.926 for Tangrah, Tamer and Galikesh stations, respectively with a lag of 8 months (with SLP of Adan Gulf) at April. With regard to the results, the utilization of these signals, especially SLP and SST can be suggested as proper predictors to forecast the maximum and mean monthly precipitation and discharge over this region.

In the second part, climate signal(s) with highest correlation coefficients were used as input variables of ANN model to predict the value of maximum monthly rainfall values at February, March, April, and August. Results showed the ability of MLP neural network with Levenberg-Marquardt training algorithm to predict the maximum monthly rainfall values. Comparison of observed and simulated data clearly indicated that the performance of the ANN Model 3 which uses all signals with significant correlation coefficients was very good with regards to the selected performance criteria, i.e. root mean square error, mean absolute error, correlation coefficient and Nash-Sutcliffe coefficient. For instance, the performance indices including root mean square error, correlation coefficient and Nash-Sutcliffe coefficient for maximum monthly rainfall of Tangrah rain gauge at August, was found to be 0.067, 0.95 and 0.945, respectively, for the test period. As the best results, for for Tangrah hydrometric station at August, the performance indices including RMSE, R and CNS for Tamer hydrometric station at August equaled to 0.0006, 0.999 and 0.999, respectively for the training period and equaled 0.078, 0.989 and 0.958 in the test period.

Keywords: Climatic signals, Sea Surface Temperature, Sea Level Pressure, Precipitation, Discharge, Artificial Neural Network, Correlation



Shahrood University of Technology

Faculty of Civil Engineering

**Rainfall and Discharge forecasting using Climatic Signals in the
upstream of Golestan Dam**

Hossein Ruigar

Supervisor(s): Dr. Saeed Golian

September 2014