

پیش‌بینی بارش ماهانه با استفاده از الگوهای پیوند از دور و شبکه عصبی مصنوعی (مطالعه موردی: حوزه فلات مرکزی ایران)

هدی قاسمیه^۱، ام‌البین بذرافشان^{۲*} و کبری بخشایش‌منش^۳

۱. استادیار، گروه مرتع و آبخیزداری، دانشکده منابع طبیعی و علوم زمین دانشگاه کاشان، کاشان، ایران
۲. استادیار، گروه مرتع و آبخیزداری، دانشکده کشاورزی و منابع طبیعی، دانشگاه هرمزگان، بندرعباس، ایران
۳. کارشناس ارشد آبخیزداری، دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان، کاشان، ایران

(دریافت: ۹۴/۱۲/۵، پذیرش نهایی: ۹۵/۷/۲۷)

چکیده

تحقیق حاضر با هدف بررسی تأثیر شاخص‌های پیوند از دور بر رخداد بارش ماهانه و پیش‌بینی بارندگی در حوزه آبخیز فلات مرکزی ایران با استفاده از مدل شبکه عصبی مصنوعی چندگامی مستقیم (DMSNN) با پارامترهای مذکور است. براین مینا مقادیر بارش طی دوره مشترک آماری ۱۹۸۱-۲۰۱۴ در ۲۰ ایستگاه سینوپتیک منطقه مورد مطالعه انتخاب شد، به طوری که دوره آماری ۱۹۸۱-۲۰۰۴ برای توسعه مدل و سال‌های ۲۰۰۴-۲۰۱۴ جهت صحت‌سنجی مدل به منظور پیش‌بینی شش ماه آینده در مقیاس ماهانه استفاده شد. جهت بررسی میزان دقت مدل، مقادیر مشاهده‌ای و پیش‌بینی شده بارندگی با استفاده از آزمون‌های F و Z مقایسه شدند و به منظور بررسی کارایی مدل، معیارهای $RMSE$ ، R^2 و MAE استفاده شدند. نتایج نشان‌دهنده تأثیر قوی شاخص SOI و MEI بر بارش منطقه است. نتایج مدل DMSNN نشان داد که بالاترین کارایی طی یک ماه آینده به بخش جنوبی فلات مرکزی با ضریب همبستگی $0/81$ و ضعیف‌ترین نتایج به غرب حوزه با ضریب همبستگی $0/4$ مربوط است. براساس نتایج به‌دست‌آمده، شبکه عصبی مصنوعی ابزار مفیدی برای پیش‌بینی بارش ماهانه و برنامه‌ریزی مدیریت منابع آب طی شش ماه آتی خواهد بود.

واژه‌های کلیدی: الگوهای پیوند از دور، بارندگی، حوزه فلات مرکزی، شبکه عصبی چندگامی مستقیم.

۱. مقدمه

بسیاری از محققان در دنیا سعی در اثبات تأثیر بین سیگنال‌های بزرگ مقیاس اقلیمی بر بارش در مقیاس زمانی روزانه، ماهانه و فصلی با اعمال تأخیر زمانی دارند (هارتمن و همکاران، ۲۰۰۸). بسیاری از مطالعات در ایران با هدف بررسی تأثیر سیگنال‌های بزرگ مقیاس اقلیمی بر جنوب کشور (ناظم‌السادات و شیروانی، ۱۳۸۵؛ نیکزاد، ۱۳۸۹؛ نصیری، ۱۳۸۹)، شمال (موسوی بایگی و همکاران، ۱۳۸۷)، غرب (فاتحی‌مرج و همکاران، ۱۳۸۵؛ جلیلی و همکاران، ۱۳۹۰؛ بذرافشان، ۱۳۹۱)، جنوب غرب (کوره‌پزان دزفولی، ۱۳۸۲)، جنوب شرق ایران (غیور و خسروی، ۱۳۸۰؛ ناظم‌السادات و قاسمی، ۱۳۸۱) و کل ایران (صداقت‌کردار و فاتحی، ۱۳۸۷؛ فلاح‌قاله‌ری و همکاران، ۱۳۸۸؛ زارع ایبانه و بیات ورکشی، ۱۳۹۱) صورت پذیرفته که تأثیر تأخیری شاخص‌های مذکور را در پیش‌بینی و مدل‌سازی لحاظ نکرده‌اند. کوره‌پزان

بارش نتیجه پدیده‌های پیچیده اتمسفری و اقیانوسی است و پیش‌بینی آن یکی از چالش‌های حیاتی طی دهه حاضر است. صحت پیش‌بینی بارش در چند ماه آینده جهت مدیریت منابع آب، امنیت غذایی و مدیریت ریسک سیلاب بسیار ضروری است (مکانیک و همکاران، ۲۰۱۳). یکی از عوامل تأثیرگذار بر بارندگی مناطق مختلف سیگنال‌های اقلیمی است. بررسی نتایج تحقیقات در سطح جهان نشان می‌دهد که ارتباط بارندگی مناطقی در جهان با پدیده‌های اقلیمی مشخص شده است. این پدیده‌ها به صورت شاخص‌های عددی مانند شاخص نوسانات جنوبی (SOI: Southern Oscillation Index)، شاخص نوسانات اطلس شمالی (NAO: North Atlantic Oscillation) و شاخص نوسان دهه‌ای اقیانوس آرام (PDO: Pacific Decadal Oscillation) تعریف شده‌اند (چانگ و همکاران، ۱۹۹۷؛ لو و وانگ، ۲۰۰۱؛ شوکلا و همکاران، ۲۰۱۱).

ایالت ویکتوریای استرالیا پرداختند. آن‌ها با کمک مدل شبکه عصبی مصنوعی به وجود رابطه همبستگی معنادار تأخیری بین بارش با شاخص‌های فوق پی‌بردند. نتایج نشان داد همبستگی بین مقادیر مشاهده‌ای و پیش‌بینی شده، با وارد کردن شاخص‌های فوق از ۰/۳ به ۰/۹۹ افزایش می‌یابد. دئو و ساهین (۲۰۱۵) به پیش‌بینی شاخص تبخیر و تعرق - بارش استاندارد شده ماهانه با استفاده از شبکه عصبی مصنوعی، شاخص‌های اقلیمی و پارامترهای اقلیمی در شرق استرالیا پرداختند. آن‌ها مؤثرترین شاخص‌ها بر منطقه را شاخص IOD، SOI و PDO معرفی کردند؛ به طوری که ورود این شاخص‌ها بر مدل سبب افزایش کارایی مدل شده است. مطالعات متعدد ثابت می‌نمایند که شاخص‌های اقلیمی بر نوسانات بارش در ماه‌های مختلف مؤثر است، اما اینکه این تغییرات چگونه می‌تواند در آینده تأثیرگذار باشد، مشخص نیست. مقدار بارندگی در فلات مرکزی ایران از ۵۸ میلی‌متر در دشت بم در کفه مرکزی ایران با ارتفاع ۱۰۶۶ متر تا ۳۳۱ میلی‌متر در همدان با ارتفاع ۱۷۶۹ متر در نوسان است؛ از نظر پراکنش مکانی بسیار نامنظم است و اغلب بارش‌ها در فصول سرد سال رخ می‌دهد (بخشایش منش، ۱۳۹۲)؛ بنابراین تعیین عوامل اقلیمی مؤثر بر بارش آن گام مهمی در برنامه‌ریزی و مدیریت منابع آب به شمار می‌آید. تحقیق فوق به بررسی تأثیر شاخص‌های اقلیمی تأثیرگذار بر بارش فلات مرکزی ایران می‌پردازد و علاوه بر اینکه تأثیرات پیچیده شاخص‌های اقلیمی را با استفاده از تکنیک تابع همبستگی متقاطع بر الگوی بارش کشف می‌کند، با استفاده از شبکه عصبی مصنوعی چندگامی مستقیم (DMSNN) به پیش‌بینی بارش طی ۶ ماه آینده می‌پردازد.

۲. منطقه مورد مطالعه

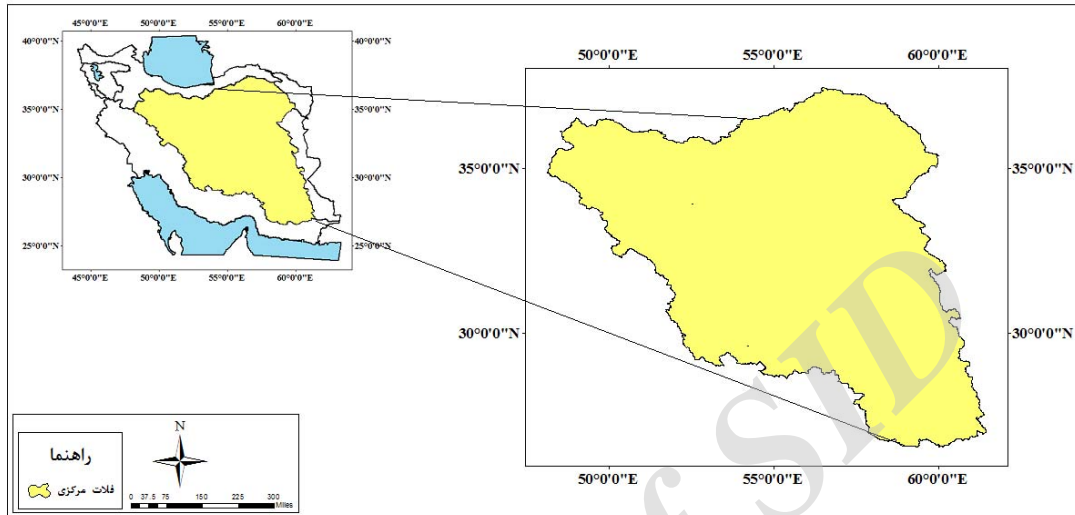
حوزه آبخیز فلات مرکزی ایران با ۹ حوزه آبریز درجه ۲ و ۲۳۳ محدوده مطالعاتی، بیشترین مساحت و مهم‌ترین محدوده‌های مطالعاتی را در خود جای داده است. این حوضه با مساحتی بالغ بر ۸۲۴۳۵۶

دزفولی (۱۳۸۲) از مقادیر شاخص‌های MEI (Multivariate Enso Index)، SOI و NAO برای پیش‌بینی باران در جنوب غرب ایران استفاده کرد. فاتحی‌مرج و همکاران (۱۳۸۵) شاخص‌های مؤثر بر بارش حوزه آبخیز دریاچه ارومیه را SOI، MEI، NAO و PDO معرفی کردند. ناظم‌السادات و همکاران (۱۳۸۶) تأثیر قوی شاخص انسو را بر بارش جنوب ایران تأیید کردند. صداقت‌کردار و فاتحی (۱۳۸۷) مهم‌ترین سیگنال‌های مؤثر در بارش‌های ایران را با استفاده از روش رگرسیون چندمتغیره، شاخص‌های ENSO (El Niño Southern Oscillation) و NAO معرفی کردند. نیکزاد (۱۳۸۹) شاخص‌های مؤثر بر خشکسالی استان خوزستان را SOI، PDO، MEI معرفی نمود. بذرافشان (۱۳۹۱) شاخص‌های مؤثر بر بارش حوزه آبخیز کرخه را SOI، MEI، PDO و AMO معرفی نمود. زراع ابیانه و بیات ورکشی (۱۳۹۱) سیگنال‌های مؤثر بر ایران را SOI، NOI، NINO و PNA معرفی کردند. فرخ‌نیا و همکاران (۲۰۱۱) با استفاده از تکنیک داده کاوی به بررسی اثر دما و فشار سطح دریای خزر بر وقوع خشکسالی در استان تهران پرداختند.

در این زمینه مطالعات متعددی نیز در سایر نقاط دنیا بر تأثیر قوی سیگنال‌های اقلیمی با اعمال تأخیر زمانی بر بارندگی تأکید دارند. پزو و همکاران (۲۰۰۵) و پنکراز و همکاران (۲۰۰۶) اثر شاخص ENSO را بر بخش‌های مرکزی و غربی اروپا تأیید کردند. آبت و ماریسی (۲۰۱۲) شاخص‌های SOI، PDO، NINO3,4 و DMI (Dipole Model Index) را به عنوان شاخص‌های مؤثر بر بارش استرالیا معرفی کردند که عمدتاً با تأخیر یک تا دو ماهه بر بارش تأثیرگذار است. بارا و همکاران (۲۰۱۰) و (۲۰۱۲) از شبکه عصبی Recursive Multi-Step Neural Network (DMSNN) و Direct Multi-Step Neural Network (Step Neural Network) برای پیش‌بینی خشکسالی بهره بردند. نتایج گویای قابلیت مناسب شبکه‌ها در پیش‌بینی دوره‌های خشک و تر است. مکانیک و همکاران (۲۰۱۳) به بررسی اثر شاخص‌های ENSO و IOD (Indian Ocean Dipole) بر بارش ملبورن و اربست در

مقادیر بارش ماهانه از سازمان هواشناسی کشور تهیه شد. تعداد ۲۰ ایستگاه بر مبنای حداقل نقص آماری طی دوره آماری ۳۴ ساله (۱۹۸۱-۲۰۱۴) انتخاب گردید. موقعیت ایستگاه‌های مورد مطالعه در جدول ۱ و شکل ۲ نشان داده شده است.

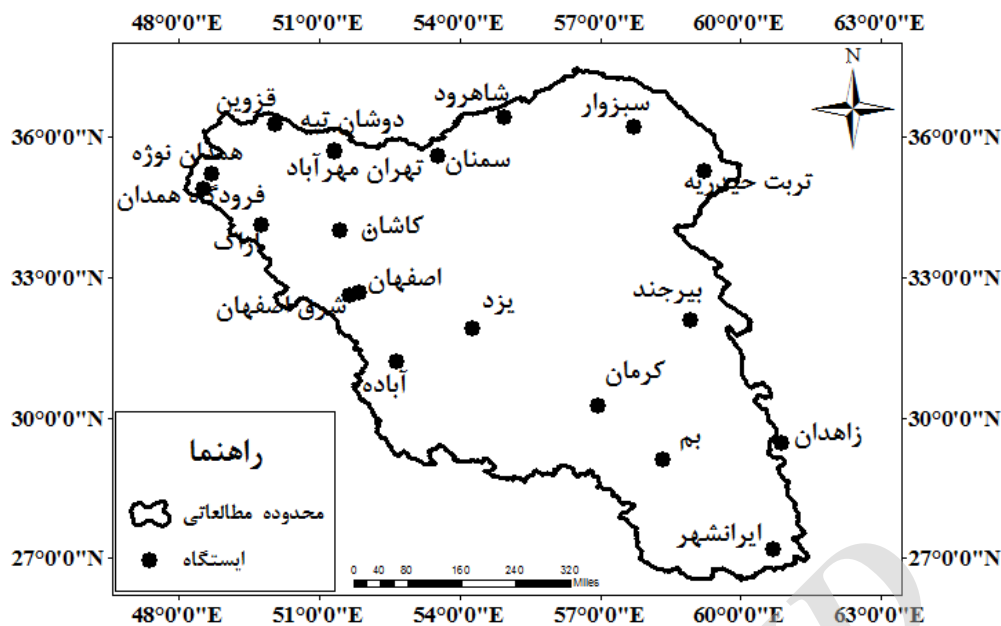
کیلومترمربع، بیش از ۵۱ درصد مساحت ایران را در بر گرفته و در میان حوزه‌های آبخیز درجه اول کشور، به لحاظ وسعت در رتبه نخست قرار می‌گیرد (علوی، ۱۳۸۸). شکل ۱ موقعیت منطقه مورد مطالعه را در ایران نشان می‌دهد.



شکل ۱. موقعیت منطقه مورد مطالعه در ایران (منبع، نگارنده).

جدول ۱. مشخصات ایستگاه‌های منتخب در حوزه آبخیز فلات مرکزی.

منطقه	ایستگاه	عرض جغرافیایی (درجه - دقیقه)	طول جغرافیایی (درجه - دقیقه)	میانگین درازمدت بارش (mm)	ارتفاع از سطح دریا (متر)
غرب	اصفهان	۳۷° ۳۲'	۵۱° ۴۰'	۱۲۵	۱۵۵۰/۴
	کاشان	۳۳° ۵۹'	۵۱° ۲۷'	۱۳۶	۹۸۳
	شرق اصفهان	۳۲° ۴۰'	۵۱° ۵۲'	۱۰۶	۱۵۴۳
	آباده	۳۱° ۱۱'	۵۲° ۴۰'	۱۳۷	۲۰۳۰
	قزوین	۳۶° ۱۵'	۵۰° ۳'	۳۱۵	۱۲۷۹/۲
	اراک	۳۴° ۶'	۴۹° ۴۶'	۳۳۷	۱۷۰۸
شمال	تهران مهرآباد	۳۵° ۴۱'	۵۱° ۱۹'	۲۳۲/۷	۱۱۹۰/۸
	دوشان تپه	۳۵° ۴۲'	۵۱° ۲۰'	۲۶۴/۷	۱۲۰۹/۲
	سمنان	۳۵° ۳۵'	۵۳° ۲۳'	۱۴۰	۱۱۳۰/۸
	شاهرود	۳۶° ۲۵'	۵۴° ۵۷'	۱۵۳	۱۳۴۵/۳
	همدان نوژه	۳۵° ۱۲'	۴۸° ۴۳'	۳۳۱	۱۶۷۹/۷
	فرودگاه همدان	۳۴° ۵۲'	۴۸° ۳۲'	۳۱۷	۱۷۴۱/۵
شرق	سبزوار	۳۶° ۱۲'	۵۷° ۴'	۱۸۶/۶	۹۷۷/۶
	تربت حیدریه	۳۵° ۱۶'	۵۹° ۱۳'	۲۶۷/۷	۱۴۵۰/۸
	بیرجند	۳۲° ۵۲'	۵۹° ۱۲'	۱۶۸	۱۴۹۱
جنوب	یزد	۳۱° ۵۴'	۵۴° ۱۷'	۵۹/۲	۱۲۳۷/۲
	زاهدان	۲۹° ۲۸'	۶۰° ۵۳'	۹۰	۱۳۷۰
	ایرانشهر	۲۷° ۱۲'	۶۰° ۴۲'	۱۱۲	۵۹۱/۱
	کرمان	۳۰° ۱۵'	۵۶° ۵۸'	۱۴۸	۱۷۵۳/۸
	بم	۲۹° ۶'	۵۸° ۲۱'	۵۹	۱۰۶۶/۹



شکل ۲. موقعیت ایستگاه‌های سینوپتیک مورد مطالعه در حوزه آبخیز فلات مرکزی ایران.

تأثیرات انکارناپذیری روی نیمکره شمالی ایجاد می‌کند (والتر و تایملاین، ۱۹۹۳). نوسان دهه‌ای اقیانوس آرام یا PDO الگوی نوسانی تغییرات اقلیمی است که مرکز تغییرات آن روی اقیانوس آرام و شمال آمریکا است و مقادیر (SST) و (SLP) در اقیانوس آرام شمالی (20°N)، در شمال ایالات متحده آمریکا اندازه‌گیری می‌شود (مانتائو و هار، ۲۰۰۲).

داده‌ها به دو دسته تقسیم شد؛ از سال ۱۹۶۸ تا ۲۰۰۴ برای مدل‌سازی و از سال ۲۰۰۴ تا ۲۰۱۴ برای صحت‌سنجی مدل به کار رفت و مقادیر بارش با استفاده از رابطه زیر بین صفر تا یک نرمال‌سازی و سپس استاندارد شد.

$$\bar{x} = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

۳. روش پژوهش

در تحقیق فوق از تابع همبستگی متقاطع و ضریب همبستگی اسپیرمن جهت بررسی ارتباط بین سیگنال‌های بزرگ مقیاس با بارش و شبکه عصبی مصنوعی DMSNN جهت پیش‌بینی بارش استفاده گردید.

۳-۱. تابع همبستگی متقاطع

جهت بررسی ارتباط همزمانی یا عدم همزمانی وقوع

به طور کلی شاخص‌های اقلیمی را به شش دسته تقسیم‌بندی می‌کنند که شامل الگوی پیوند از دور، الگوی اتمسفری (Atmosphere)، بارندگی (Precipitation)، انسو (ENSO)، دمای سطح اقیانوس آرام (SST Pacific) و دمای سطح اقیانوس اطلس (SST Atlantic) است؛ مقادیر فوق به صورت نرمال استاندارد شده موجودند که عناصر هر یک در جدول ۲ ارائه شده است (نوا، ۲۰۱۲). این مقادیر از وب‌سایت نوا تهیه گردید که در ادامه به شرح برخی از مهم‌ترین این عناصر می‌پردازیم.

شاخص انسو با دو شاخص نوسانات جنوبی (SOI)، فشار سطح دریا (SLP: Sea Level Pressure) و دمای سطح دریا (SST: Sea Surface Temperature) در اقیانوس آرام استوایی در ارتباط است که مقدار منفی و مثبت آن بیانگر فازهای سرد و گرم انسو یا شرایط لانینا و النینو است (ریزی و همکاران، ۲۰۰۹). شاخص MEI ترکیبی از شش متغیر اصلی شامل فشار سطح دریا، مؤلفه‌های شمالی-جنوبی و شرقی-غربی بادهای سطحی، دمای سطح آب دریا، دمای سطحی هوا و مجموع مقدار ابرناکی در منطقه انسو می‌باشد که در ناحیه استوایی اقیانوس آرام مشاهده گردید. این شاخص به عنوان یکی از تأثیرگذارترین الگوهای پیوند از دور،

$$R = \frac{\sum_{i=1}^n (x_{(i)} - \bar{x})(y_{(i-d)} - \bar{y})}{\sqrt{\sum_{i=1}^n (x_{(i)} - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_{(i-d)} - \bar{y})^2}} \quad (2)$$

در این رابطه مقادیر \bar{x} و \bar{y} مقدار میانگین هر یک از سری‌های زمانی $X(i)$ و $Y(i)$ هستند. اگر رابطه ۲ برای همه تأخیرهای زمانی مشخص $d=0,1,2,\dots, n-1$ محاسبه شود، در یکی از گام‌های تأخیر بیشترین همبستگی را خواهد داشت (پودا و همکاران، ۲۰۰۱؛ چن و همکاران، ۲۰۰۴).

بارش با شاخص‌های پیوند از دور از روش همبستگی متقاطع در محیط نرم‌افزاری Minitab17 استفاده شد. از مهم‌ترین مزایای روش همبستگی متقاطع علی‌رغم روش همبستگی ساده پیرسون امکان تعیین ضریب همبستگی در گام زمانی مورد نظر اعم از گام‌های مثبت و منفی است (چانگ و همکاران، ۱۹۹۷). همبستگی متقاطع نوعی روش استاندارد برای تعیین درجه همبستگی بین دو سری زمانی است. چنانچه مقدار $X(i)$ و $Y(i)$ با $i=0,1,2,\dots, n$ دو متغیر باشند، مقدار R همبستگی متقاطع آن‌ها به شکل رابطه ۲ است.

جدول ۲. تقسیم‌بندی شاخص‌های اقلیمی (نوا، ۲۰۱۲).

نام الگو	شاخص اقلیمی	توضیحات
پیوند از دور Teleconnections	NAO	نوسانات اطلس شمالی
	EPO	نوسانات آرام شرقی
	PDO	نوسانات دهه‌ای اقیانوس آرام
	WP	شاخص آرام غربی
اتمسفر Atmosphere	SOI	شاخص نوسانات جنوبی
	QBO	نوسانات شبه دوسالانه
انسو ENSO	MEI	شاخص انسوی چندمتغیره
	NINO 1,2	شاخص دمای سطحی شدید بخش شرقی اقیانوس آرام استوایی
	NINO 3	شاخص دمای سطحی بخش شرقی اقیانوس آرام استوایی
	NINO 3,4	شاخص دمای سطحی بخش مرکزی شرق اقیانوس آرام استوایی
	NINO 4	شاخص دمای سطحی بخش مرکزی اقیانوس آرام استوایی
دمای سطح اقیانوس آرام SST: Pacific	BEST	سری زمانی انسو دومتغیره
	NINO 1,2	شاخص دمای سطحی بخش شرقی اقیانوس آرام استوایی
	NINO 3	شاخص دمای سطحی بخش شرقی اقیانوس آرام استوایی
	NINO 3,4	شاخص دمای سطحی بخش شرقی اقیانوس آرام استوایی
	NINO 4	شاخص دمای سطحی بخش مرکزی اقیانوس آرام استوایی
	TNI	شاخص تغییر یافته دمای اقیانوس آرام
دمای سطح اقیانوس اطلس SST: Atlantic	WHWP	استخر گرم نیمکره غربی
	PACWARM	استخر گرم آرام
	TNA	شاخص اطلس شمالی استوایی
	TSA	شاخص اطلس جنوبی خارهای
	WHWP	استخر گرم نیمکره غربی
	AMO	نوسانات چنددهه‌ای اطلس
Precipitation	CAR	شاخص دمای سطح کارائیب
	AMM	شاخص نصف‌النهاری اقیانوس اطلس
	Indian Monsoon	بارندگی در مناطق مرکزی هند
	SWMonsoon	میانگین بارندگی در سواحل آریزونا و نیومکزیکو
Brazil	نوسانات بارندگی بخش شمال شرقی برزیل	
Sahel rainfall	بارش استاندارد شده ساحلی	

۲-۳. ضریب همبستگی اسپیرمن

این ضریب در اوایل دهه ۱۹۰۰ توسط چارلز اسپیرمن ابداع گردید. ضریب همبستگی اسپیرمن که آن را با ρ نمایش می‌دهند همواره بین +۱ و -۱ در نوسان است و از لحاظ سطح سنجش نیز ترتیبی و از نوع مقارن است (بذرافشان و همکاران، ۱۳۹۴).


$$\rho = 1 - \frac{6(\sum d_i^2)}{n(n^2 - 1)} \quad (۳)$$

$$t = \frac{\rho\sqrt{n-2}}{\sqrt{1-\rho}} \quad (۴)$$

که در این رابطه ρ ضریب همبستگی اسپیرمن، n تعداد مشاهده‌ها و $\sum d_i^2$ مجموع مجذور تفاوت دو رتبه است. برای آزمون همبستگی اسپیرمن از رابطه ۴ آماره t محاسبه شده و بعد از مقایسه آن با t جدول با درجه آزادی $n-2$ تصمیم‌گیری می‌شود.

۳-۳. شبکه عصبی مصنوعی چندگامی مستقیم

در این پژوهش، از شبکه عصبی چندگامی مستقیم که یکی از روش‌های شبکه‌های عصبی پرسپترون چندلایه (MLP: Multi-Layer Perceptron) است، به منظور مدل‌سازی و پیش‌بینی در مقیاس ماهانه استفاده گردید (میشرا و دسای، ۲۰۰۶). لازم به ذکر است که شبکه عصبی چندگامی مستقیم بر خلاف مدل‌هایی مانند آرپما و مدل شبکه عصبی بازگشتی، در لایه خروجی دارای چندین نرون است و تعداد نرون خروجی توسط کاربر تعیین می‌شود (دئوو و ساهین، ۲۰۱۵). در این شبکه الگوریتم آموزش مورد استفاده لونیگ-مارکوات (Levenberg-Marquardt algorithm) بر مبنای الگوریتم آموزش پس‌انتشار خطا (Back Propagation) و تابع انتقال لایه میانی و خروجی به ترتیب تابع تانژانت سیگموئید و تابع خطی بودند. تعداد تکرار (Epoch) ۵۰۰ بار تنها یک لایه مخفی در نظر گرفته شد (کیم و والدز، ۲۰۰۳).



شکل ۳. شبکه عصبی چندگامی مستقیم. لایه خروجی لایه مخفی ورودی‌ها

۴-۳. ارزیابی عملکرد و دقت مدل

به منظور مقایسه عملکرد مدل در پیش‌بینی، از معیارهای ارزیابی ریشه میانگین مربعات خطا، میانگین قدرمطلق خطا و ضریب همبستگی استفاده شد که روابط آن‌ها در ادامه می‌آید (میشرا و دسای، ۲۰۰۵).

- ریشه میانگین مربعات خطا (RMSE: Root Mean Square Error)

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - E_i)^2}{n}} \quad (۵)$$

که در رابطه فوق O_i مقادیر مشاهده‌ای و E_i مقادیر پیش‌بینی شده است. کم‌بودن ریشه میانگین مربعات خطا هر مدل نشان‌دهنده عملکرد بهتر آن است.

- میانگین قدر مطلق خطا (MAE: Mean Absolute Error)

$$MAE = \frac{\sum_{i=1}^n |O_i - E_i|}{n} \quad (۶)$$

کم‌بودن قدرمطلق مربعات خطا و ریشه میانگین مربعات خطای هر مدل نشان‌دهنده عملکرد بهتر آن است.

- ضریب تبیین بین مقادیر مشاهده‌ای و پیش‌بینی (R^2)

$$R^2 = \frac{\sum_{i=1}^n (x_i - \bar{x}_i)(\hat{x}_i - \bar{\hat{x}}_i)}{\sqrt{\sum_{i=1}^n (x_i - \bar{x}_i)^2 \sum_{i=1}^n (\hat{x}_i - \bar{\hat{x}}_i)^2}} \quad (۷)$$

در رابطه ۴ مقادیر x_i مربوط به سری مشاهداتی و \bar{x}_i مربوط به سری پیش‌بینی شده است. زیادبودن این ضریب نشان‌دهنده توافق بیشتر بین مقادیر مشاهده‌ای با مقادیر پیش‌بینی شده و عملکرد بهتر مدل است (بذرافشان و همکاران، ۱۳۹۲).

نتایج ارزیابی عملکرد و دقت شبکه عصبی مصنوعی با استفاده از روش تحلیلی کریجینگ توسط کد توسعه‌ای کریجینگ در محیط نرم‌افزار Arc Map 10.2 پهنه‌بندی شد و الگوی تغییرات آن‌ها در پهنه فلات مرکزی ایران تولید شد.

۴. نتایج و بحث

۴-۱. نتایج بررسی رابطه بین پارامتر بارش با شاخص‌های پیوند از دور

جهت بررسی تأثیر پدیده‌های اقلیمی بر بارش در هرکدام از ایستگاه‌های مورد مطالعه در حوزه آبخیز فلات مرکزی، از تابع همبستگی متقاطع استفاده شد. به این صورت که ضرایب همبستگی متقاطع بین بارندگی در زمان t و سیگنال اقلیمی (متغیر مستقل) در زمان $t-k$ با استفاده از نرم‌افزار Minitab محاسبه شد. در نهایت از بین ۲۹ سیگنال اقلیمی (جدول ۲)، دو شاخص با بالاترین ضریب همبستگی معنادار در گام تأخیر مشخص با سطح معناداری ۰/۵٪، به عنوان مؤثرترین شاخص‌های اقلیمی بر بارندگی انتخاب شدند. نتایج ضرایب همبستگی متقاطع بین بارش و سیگنال‌های اقلیمی مؤثر در مقیاس ماهانه به همراه گام تأخیر در جدول ۳ ارائه شده است. بر این اساس، دو شاخص SOI و MEI ارتباط معناداری با بارش در فلات مرکزی ایران دارد. به دلیل کم بودن ضرایب همبستگی حاصل از تابع همبستگی متقاطع، وجود رابطه غیرخطی بین پدیده‌های اقلیمی با بارش، محتمل است؛ بنابراین از ضریب همبستگی اسپیرمن نیز جهت یافتن روابط قطعی‌تر استفاده گردید (علیچانی و قویدل رحیمی، ۱۳۸۴). شایان ذکر است که مقادیر ضریب همبستگی اسپیرمن در گام‌های تأخیر معرفی شده توسط ضریب CCF محاسبه شد.

بر اساس نتایج حاصل از ضرایب همبستگی استفاده شده، شاخص MEI دارای رابطه مستقیم با بارش است؛ بدین صورت که هرگونه نوسانات در فازهای مثبت و منفی شاخص مذکور هرچند با تأخیر اما به صورت رابطه همسو با بارش است. به طوری که در بیشتر موارد، بالاترین ضریب همبستگی بین ایستگاه‌های بخش جنوبی حوزه فلات مرکزی است و غالباً تأخیر یک‌ماهه دارد. یعنی تأثیرات پدیده MEI پس از رخداد، یک‌ماه بعد بر روی بارش بخش‌های جنوبی حوضه مؤثر است. ضرایب همبستگی بخش‌های شرقی و غربی حوضه تفاوت زیادی نداشته و اغلب تأثیرات پدیده مذکور ۶ ماه بعد از رخداد MEI بر بارش مؤثر است. اما در شمال حوزه

این تأخیر به هفت ماه می‌رسد. نتایج تحقیقات کوره‌پزان دزفولی (۱۳۸۲) در جنوب غرب ایران، ناظم‌السادات (۱۳۸۰)، ناظم‌السادات و قاسمی (۱۳۸۱)، ناظم‌السادات و شیروانی (۱۳۸۵)، ناظم‌السادات و همکاران (۱۳۸۶) در جنوب و جنوب شرق ایران، نیکزاد (۱۳۸۹) در استان خوزستان، یاراحمدی و عزیزی (۱۳۸۶) در بررسی بارش فصلی ایران و زارع ایبانه و بیات ورکشی (۱۳۹۱) در ایستگاه‌های همدید کل کشور نیز مؤید این مطلب است؛ به طوری که این محققین مؤثرترین شاخص‌ها بر منطقه را SOI و MEI معرفی کردند. نتایج محققان دیگر در سایر نقاط دنیا مانند پنکراز و همکاران (۲۰۰۶)، یزو و همکاران (۲۰۰۵) در اروپا، مکائیک و همکاران (۲۰۱۳) و دئو و ساهین (۲۰۱۵) در استرالیا نیز مؤید این موضوع است.

در مورد تأثیرات پدیده SOI، تمامی ایستگاه‌ها دارای ارتباط معکوس و غالباً معنادار هستند؛ بدین صورت که کاهش در مقدار SOI سبب افزایش در مقدار بارش می‌گردد و برعکس. بالاترین ضریب تبیین مربوط به ایستگاه‌های واقع در جنوب حوضه بوده که با دو ماه تأخیر اثرگذار است. این در حالی است که با دور شدن از جنوب حوضه، برای سایر نقاط با تأخیر سه ماهه تأثیر خواهد داشت. که با نتایج غیور و خسروی (۱۳۸۰)، قویدل رحیمی و خورشید دوست (۱۳۸۵) و یاراحمدی و عزیزی (۱۳۸۶) همخوانی دارد.

طبق نتایج به دست آمده، به کارگیری ضریب همبستگی اسپیرمن در همه ایستگاه‌ها مناسب‌تر از ضریب همبستگی متقاطع بوده و نشان‌دهنده وجود رابطه غیرخطی بین سیگنال‌های بزرگ مقیاس با بارش در پهنه مرکزی ایران است که با نتایج فلاح قاهره و همکاران (۱۳۸۸) و فاتحی‌مرج و همکاران (۱۳۸۵) مشابهت دارد. باتوجه به نتایج به دست آمده در جدول ۳ در بسیاری از ایستگاه‌ها ضریب همبستگی متقاطع و اسپیرمن بین بارش با پدیده سیگنال‌های بزرگ مقیاس پایین است. فلاح قاهره و همکاران (۱۳۸۸) و فاتحی‌مرج و همکاران (۱۳۸۵) نیز در مطالعات خود به چنین نتایجی اذعان کردند.

جدول ۳. ضرایب همبستگی متقاطع و اسپیرمن بین باران و سیگنال‌های اقلیمی مؤثر در مقیاس ماهانه.

**معناداری در سطح اعتماد ۹۹ درصد *معناداری در سطح اعتماد ۹۵ درصد

SOI			MEI			ایستگاه	منطقه
گام تأخیر	ضریب همبستگی اسپیرمن	ضریب همبستگی متقاطع	گام تأخیر	ضریب همبستگی اسپیرمن	ضریب همبستگی متقاطع		
۳	-۰/۳۱**	-۰/۱۴۳**	۶	۰/۲۹*	۰/۱۳۵**	اصفهان	غرب
۳	-۰/۲۹*	-۰/۱۳۳**	۶	۰/۲۶*	۰/۱۳۹**	کاشان	
۲	-۰/۳۰۱**	-۰/۱۳۴**	۷	۰/۲۷*	۰/۱۱۱*	شرق اصفهان	
۳	-۰/۳۸**	-۰/۱۱۴*	۶	۰/۳۹**	۰/۱۱۳*	آباده	
۳	-۰/۳۴۴**	-۰/۱۴۳**	۶	۰/۴۳**	۰/۱۲۳**	قزوین	
۳	-۰/۲۸۳*	-۰/۱۰۲*	۶	۰/۴۲۳**	۰/۱۲۸**	اراک	
۳	-۰/۳۸۱**	-۰/۱۲۱**	۷	۰/۳۳۱**	۰/۱۴۵**	تهران مهرآباد	شمال
۳	-۰/۳۶**	-۰/۱۳۹**	۷	۰/۴۰۲**	۰/۱۱۲*	دوشان تپه	
۴	-۰/۴۳**	-۰/۱۴۸**	۷	۰/۳۸۲**	۰/۱۲۳**	سمنان	
۴	-۰/۴۹**	-۰/۱۵۹**	۷	۰/۴۲**	۰/۱۰۱*	شاهرود	
۳	-۰/۳۱۳**	-۰/۱۳۹**	۷	۰/۳*	۰/۱۱۸*	همدان نورژه	
۳	-۰/۳۸۶**	-۰/۱۴۴**	۷	۰/۳۸**	۰/۱۱۷*	فرودگاه همدان	
۳	-۰/۴۶**	-۰/۱۲۳**	۷	۰/۲۹۱*	۰/۱۲۲**	سبزوار	شرق
۳	-۰/۳۸۵**	-۰/۱۱۱*	۶	۰/۳۰۴**	۰/۱۴۳**	تربت حیدریه	
۳	-۰/۲۰۵*	-۰/۰۴۴	۶	۰/۳۴۱**	۰/۱۰۷*	بیرجند	
۲	-۰/۲۸۳*	-۰/۱۱۳*	۰	۰/۳۹**	۰/۰۵۸	یزد	جنوب
۲	-۰/۶۲۳**	-۰/۱۷۲**	۰	۰/۵۰۱**	۰/۱۴۹**	زاهدان	
۲	-۰/۵۹**	-۰/۱۷۹**	۱	۰/۴۸**	۰/۱۵۷**	ایرانشهر	
۲	-۰/۴۶۷**	-۰/۱۵۴**	۰	۰/۴۱**	۰/۱۱۳**	کرمان	
۲	-۰/۵۶**	-۰/۱۳۴**	۱	۰/۴۵**	۰/۱۳۴**	بم	

در مقیاس زمانی ماهانه مربوط به سال‌های ۲۰۰۴ تا ۲۰۱۴ در هر یک از ایستگاه‌ها، جهت صحت‌سنجی و پیش‌بینی یک تا ۶ ماه بعد برای مقادیر بارندگی ماهانه به کار گرفته شد. ساختار نرون ورودی، مخفی و خروجی هر یک از مدل‌ها در جدول ۴ ارائه شده است. شکل ۴ به‌عنوان نمونه، مقادیر پیش‌بینی شده و مشاهده‌ای باران در ایستگاه ایرانشهر را نشان می‌دهد.

نتایج مقایسه عملکرد مدل DMSNN در پیش‌بینی بارش

۴-۲. نتایج مدل‌سازی و پیش‌بینی باران با استفاده از

شبکه عصبی مصنوعی DMSNN


شبکه عصبی DMSNN به ازای هر گام زمانی یک نرون دارد، بنابراین در این پژوهش داده‌های بارش همان ماه و مقادیر سیگنال‌های اقلیمی با زمان تأخیر مشخص به‌عنوان داده ورودی و برای لایه خروجی در مقیاس ماهانه ۶ نرون در نظر گرفته شد. سپس به منظور ارزیابی مدل شبکه عصبی مصنوعی DMSNN، سری‌های زمانی

بخش غربی حوضه مورد مطالعه تنها قادر به مدل‌سازی دو ماه بعد است که با افزایش گام زمانی، ضریب همبستگی کاهش و خطا افزایش می‌یابد. شکل ۵ پهنه‌بندی ضرایب کارایی را در پهنه حوضه آبخیز فلات مرکزی نشان می‌دهد.

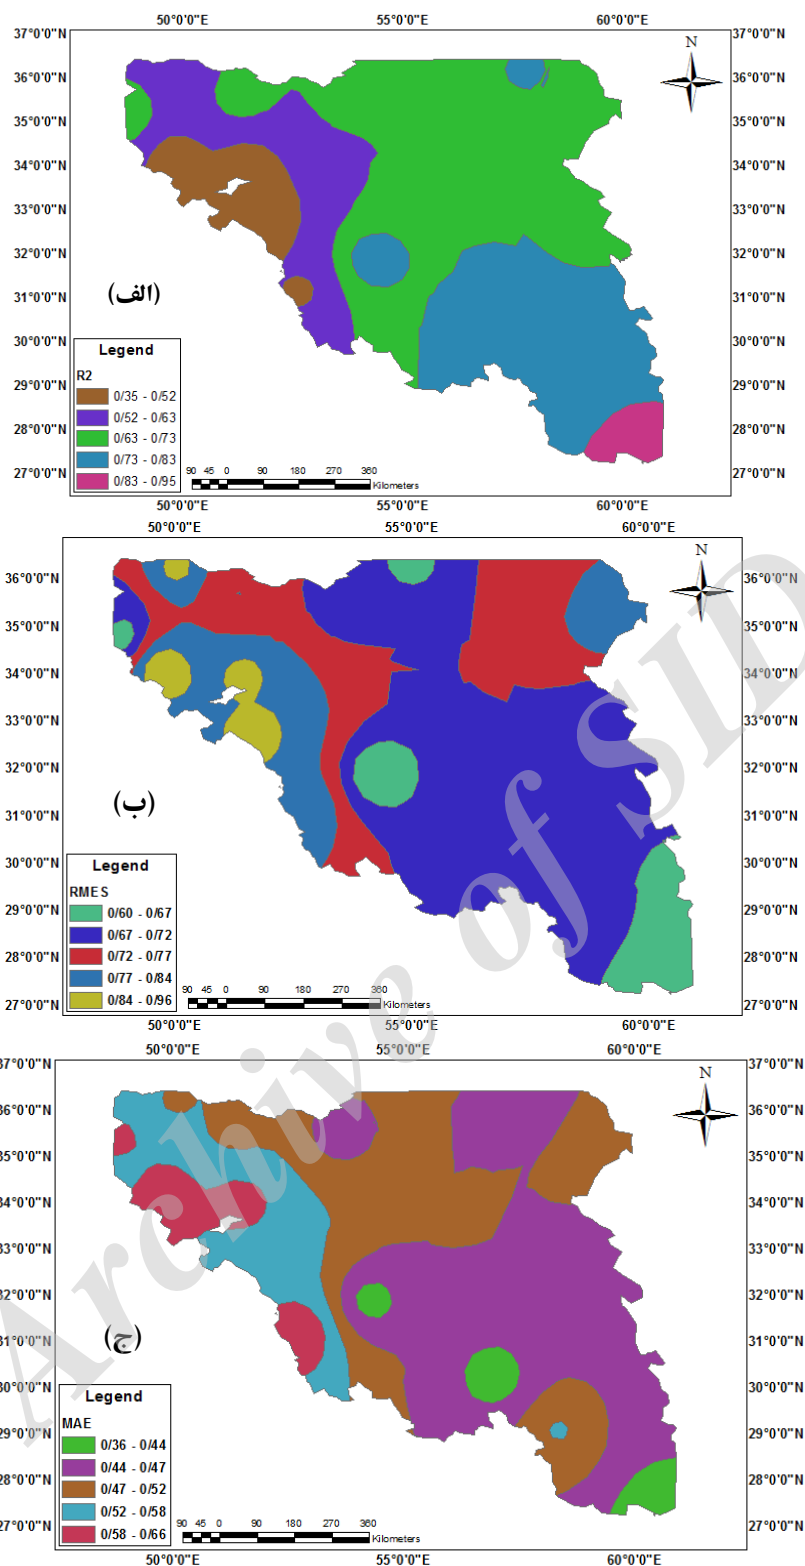
ماهانه نشان داد که مدل مذکور در ایستگاه‌های جنوبی، دارای بالاترین ضریب تبیین ($R^2=0/81$) و ایستگاه‌های غربی دارای کمترین ضریب تبیین ($R^2=0/41$) است. همچنین این مدل در ۷۰٪ ایستگاه‌ها قادر به مدل‌سازی در گام‌های زمانی بیش از پنج ماه و در ایستگاه‌های

جدول ۴. مدل‌های منتخب شبکه عصبی مصنوعی چندگامی مستقیم در مرحله مدل‌سازی.

منطقه	ایستگاه	(نرون ورودی - میانی - خروجی)	ضریب همبستگی مقادیر مشاهده‌ای و پیش‌بینی	منطقه	ایستگاه	(نرون ورودی - میانی - خروجی)	ضریب همبستگی مقادیر مشاهده‌ای و پیش‌بینی	
غرب	اصفهان	(۶-۳-۹)	۰/۸۲	شرق	سبزوار	(۶-۹-۱۲)	۰/۷۹	
	کاشان	(۶-۴-۶)	۰/۷۸		تربت حیدریه	(۶-۵-۱۳)	۰/۷۶	
	شرق اصفهان	(۶-۲-۶)	۰/۸۳		بیرجند	(۶-۶-۸)	۰/۶۹	
	شمال	آباده	(۶-۵-۶)	۰/۶۷	جنوب	یزد	(۶-۵-۳)	۰/۸
		قزوین	(۶-۴-۵)	۰/۷۶		زاهدان	(۶-۵-۳)	۰/۸۴
		اراک	(۶-۵-۱۱)	۰/۸۶		ایرانشهر	(۶-۹-۳)	۰/۹۲
شمال		تهران مهرآباد	(۶-۵-۳)	۰/۹	کرمان	(۶-۴-۲)	۰/۸۹	
		دوشان تپه	(۶-۱۳-۵)	۰/۸۱	بم	(۶-۱۱-۵)	۰/۹۱	
		سمنان	(۶-۲-۱۱)	۰/۷۳	همدان نوژه	(۶-۹-۱۳)	۰/۷۸	
	شاهرود	(۶-۵-۷)	۰/۷	فرودگاه همدان	(۶-۴-۵)	۰/۸۱		



شکل ۴. مقایسه مقادیر مشاهده‌ای و پیش‌بینی شده مدل DMSNN در ایستگاه ایرانشهر.



شکل ۵. پهنه‌بندی عملکرد مدل DMSNN در پیش‌بینی بارندگی در گام زمانی یک‌ماهه در مناطق مختلف حوزه آبخیز فلات مرکزی در مرحله صحت‌سنجی، مقادیر ضریب تبیین (الف)، RMSE (ب) و MAE (ج).

سیگنال‌های مذکور است. نتایج حاصل از دو ضریب همبستگی اسپیرمن و متقاطع نشان می‌دهد که از بین ۲۹ شاخص اقلیمی در طول دوره آماری ۱۹۸۱-۲۰۱۴، روابط معناداری بین شاخص‌های اقلیمی MEI و SOI با

۵. نتیجه‌گیری
مطالعه فوق با هدف بررسی تأثیر سیگنال‌های بزرگ مقیاس اقلیمی بر بارش فلات مرکزی ایران و توسعه مدل DMSNN جهت پیش‌بینی باران با استفاده از

ضعیف کرده و در شمال کشور نیز اثر نوسانات قطبی بر آن غلبه می‌نماید. از طرفی در غرب و شمال حوزه بارش غالب به صورت برف است که به عقیده بارت و همکاران (۱۹۹۹) نابهنجاری‌های پوش برف روی اوراسیا همانند انسو شرایط بازدارنده‌ای را در منطقه حاره‌ای اقیانوس از راه تضعیف موسمی‌های تابستانی و تشدید جریان‌های غربی حاره‌ای به وجود می‌آورد.

پیش‌بینی با شبکه DMSNN به همراه فاکتورهای پیش‌بینی‌کننده MEI و SOI در هر منطقه با گام تأخیر مشخص صورت پذیرفت. شبکه عصبی پرسپترون چندلایه (MLP) براساس تکنیک آموزش لونیگ-مارکوات همواره در مدل‌سازی انواع فرایندهای هیدرولوژیک استفاده می‌شود. نتایج استفاده از مدل DMSNN نشان داد همبستگی بالایی بین مقادیر پیش‌بینی‌شده با مشاهده‌ای وجود دارد که نشان‌دهنده توانایی بالای الگوی مدل است.

نتایج حاصل از صحت‌سنجی نشان‌دهنده کارایی کم مدل در ایستگاه‌های غرب حوضه در مقایسه با سایر مناطق است، به طوری که ضریب همبستگی در بخش جنوبی از گام اول تا ششم بین ۰/۸۱ تا ۰/۴۱، در شمال حوضه از ۰/۷ تا ۰/۱، در شرق حوضه از ۰/۵۵ تا ۰/۱ و در غرب حوضه از ۰/۴ تا ۰/۰۱ تغییر می‌کند. به نظر می‌رسد ضعف بودن اثر سیگنال‌های اقلیمی MEI و SOI در غرب حوضه، بر نتایج شبیه‌سازی مدل نیز مؤثر بوده است. به نظر می‌رسد، عمدتاً غرب ایران تحت تأثیر نوسانات دریای مدیترانه (Med SST) و اقیانوس اطلس شمالی (NAO) بوده و تأثیرات انسو ضعیف‌تر است که این عامل تأییدکننده کم بودن تأثیرات همبستگی بارش با شاخص‌های بزرگ مقیاس در غرب حوزه آبخیز فلات مرکزی است.

به طور کلی چنین استنباط می‌شود که متغیرهای وارد شده به مدل، توانسته‌اند به راحتی و با دقت زیاد، شش ماه آینده را پیش‌بینی نمایند که این مطلب نقش بسیار تعیین‌کننده‌ای در مدیریت و برنامه‌ریزی منابع آب در بخش‌های مختلف در مناطق خشک و نیمه‌خشک ایران ایفا می‌کند و می‌توان با در نظر گرفتن این پیش‌بینی‌ها،

بارندگی حوزه فلات مرکزی ایران در مقیاس ماهانه اما با تأخیر وجود دارد.

نتایج حاصل از ضرایب همبستگی نشان از رابطه معکوس باران در فلات مرکزی با مقدار SOI و رابطه مستقیم با MEI دارد که به ترتیب نشان‌دهنده ارتباط معکوس و مستقیم دو شاخص فوق‌الذکر است. دلیل اثر منفی و مثبت این شاخص‌ها تفاوت بین عرض‌های میانه با محل‌های اندازه‌گیری این شاخص‌ها و جابه‌جایی پرفشار جنب حاره‌ای خاورمیانه به عرض‌های پایین‌تر و امکان نفوذ موج بادهای غربی در دوره سرد سال به منطقه مدیترانه و دریای سرخ است که سبب عملکرد مثبت یا منفی شاخص‌ها شناخته می‌شود. در مورد همبستگی معکوس شاخص SOI با بارش در مناطق جنوب شرق حوزه آبخیز فلات مرکزی، توسعه موسمی بر روی جنوب شرق ایران و دریای عمان است که سبب بارش‌های تابستانه در این مناطق می‌گردد. علاوه بر آن، با وجود تفاوت بین منشأ بارش‌ها در جنوب فلات ایران، همبستگی منفی بین شاخص SOI با بارش، اهمیت شاخص درجه حرارت سطحی اقیانوس آرام را در تعیین فازهای گرم و سرد تأیید می‌کند.

باتوجه به نتایج به دست آمده در بسیاری از ایستگاه‌ها ضریب همبستگی متقاطع و اسپیرمن بین بارش با پدیده سیگنال‌های بزرگ مقیاس اگرچه معنادار است، اما همچنان مقادیر در مقایسه با مطالعات سایر محققان در کشورهایی نظیر آمریکا و استرالیا ارقام پایینی است. مهمترین دلیل کم بودن ضرایب همبستگی شاخص‌های اقلیمی با پارامترهای اقلیمی در ایران دور بودن از منشأ تولیدکننده آن است.

نتایج نشان داد مقادیر ضریب همبستگی از شمال به جنوب و از غرب به شرق فلات مرکزی دارای روند افزایشی است. از طرفی در هر منطقه نیز ایستگاه به ایستگاه ضرایب از نظم خاصی برخوردار نیست که نشان‌دهنده رفتار متفاوت یک شاخص در مناطق مختلف است. رفتار سامانه‌های بزرگ مقیاس نظیر SOI و MEI در نقاط مختلف متفاوت است، به طوری که در غرب کشور اثر جریان‌های غربی و مدیترانه تأثیرات انسو را

سیاست‌های آینده را در جهت بهینه‌سازی صرف هزینه‌ها و امکانات بهره‌وری حداکثر طرح‌ریزی کرد.

مراجع

بخشایش‌منش، ک.، ۱۳۹۲، ارزیابی ارتباط بین الگوهای پیونداز دور با بارش و شاخص SPI (مطالعه موردی: حوزه آبخیز فلات مرکزی)، پایان‌نامه کارشناسی ارشد، دانشگاه کاشان، ۱۷۲ص.

بذرافشان، الف.، ۱۳۹۱، پیش‌بینی خشکسالی هیدرولوژیکی با استفاده از پیونداز دور و مدل‌های هوشمند (مطالعه موردی: حوزه آبخیز کرخه)، رساله دوره دکتری علوم و مهندسی آبخیزداری، دانشگاه تهران، ۲۳۲ص.

بذرافشان، الف.، چشم‌براه، ع.، و حلی‌ساز، الف.، ۱۳۹۴، مطالعه روند تغییرات تبخیر از تشتک در نمونه‌های اقلیمی استان هرمزگان. م. علمی- ترویجی حفاظت و بهره‌برداری از منابع طبیعی، ۴(۲)، ۱۷۱ تا ۱۷۶.

بذرافشان، الف.، سلاجقه، ع.، فاتحی‌مرج، الف.، مهدوی، م.، بذرافشان، ج. و حجایی، س.، ۱۳۹۲، مقایسه کارایی مدل‌های آماری و مفهومی در پیش‌بینی خشک‌سالی هیدرولوژی (مطالعه موردی: حوزه آبخیز کرخه)، م. مرتع و آبخیزداری، ۶(۴)، ۴۹۳-۵۰۸.

جلیلی، ش.، مرید، س.، بناکار، الف. و نامدار قنبری، ر.، ۱۳۹۰، ارزیابی تأثیر شاخص‌های اقلیمی NAO و SOI بر تغییرات تراز دریاچه ارومیه، کاربرد روش‌های آنالیز طیفی سری‌های زمانی، م. آب و خاک (علوم و صنایع کشاورزی)، ۲۵(۱)، ۱۴۰-۱۴۹.

خورشیددوست، ع. م.، قویدل رحیمی، ی.، ۱۳۸۵، ارزیابی اثر پدیده انسو بر تغییرپذیری بارش‌های فصلی استان آذربایجان شرقی با استفاده از شاخص چندمتغیره انسو، م. تحقیقات جغرافیایی، ۵۷، ۱۵-۲۶.

زراع ایبانه، ح.، و بیات ورکشی، م.، ۱۳۹۱، مطالعه تأثیرپذیری تعداد روزهای بارانی از پدیده انسو در ایران، م. پژوهش‌های حفاظت آب و خاک، ۱،

۲۱-۳۹.

صداقت‌کردار، ع.، و فاتحی، الف.، ۱۳۸۷، شاخص‌های پیش‌آگاهی خشکسالی در ایران، م.

جغرافیا و توسعه، ۱۱، ۵۹-۷۶.

علوی، الف.، ۱۳۸۸، حوزه آبریز فلات مرکزی ایران، مدیریت بهم‌پیوسته منابع آب، م. مدیریت پیوسته منابع آب، ۱، ۱-۴.

علیجانی، ب.، و قویدل رحیمی، ی.، ۱۳۸۴، مقایسه و پیش‌بینی تغییرات دمای سالانه تبریز با ناهنجاری‌های دمایی کره زمین با استفاده از روش رگرسیون خطی و شبکه عصبی مصنوعی. م. جغرافیا و توسعه، ۳(۶)، ۲۱-۳۸.

غیور، ح.، و خسروی، م.، ۱۳۸۰، تأثیر پدیده انسو بر ناهنجاری‌های بارش تابستانی و پائیز منطقه جنوب‌شرق ایران. م. تحقیقات جغرافیایی، ۶۲، ۱۴۱-۱۷۴.

فاتحی‌مرج، ا.، برهانی‌داریان، ع. و مهدیان، م.، ۱۳۸۵، پیش‌بینی بارش فصلی با استفاده از پیونداز دور (مطالعه موردی: حوزه آبریز دریاچه ارومیه)، م. علوم و فنون کشاورزی و منابع طبیعی، ۱۰(۳)، ۴۵-۵۷.

فلاح‌قالهری، غ. ع.، موسوی بایگی، س. م.، حبیبی نوخندان، م.، و خوشحال، ج.، ۱۳۸۸، پیش‌بینی بارش سالیانه بر پایه الگوهای سینوپتیک پیونداز دور با بهره‌گیری از مدل‌های آماری، م. منابع طبیعی ایران، نشریه مرتع و آبخیزداری، ۶۲(۱)، ۱۱۱-۱۲۳.

کوره‌پزان دزفولی، الف.، ۱۳۸۲، تأثیر سیگنال‌های هواشناسی در پیش‌بینی تغییرات بارش، پایان‌نامه کارشناسی ارشد عمران آب، دانشگاه امیر کبیر، ۱۲۳ص.

موسوی بایگی، م.، فلاح‌قالهری، غ. و حبیبی نوخندان، م.، ۱۳۸۷، بررسی نشانه‌های پهن‌مقیاس اقلیمی با بارش خراسان. م. علوم کشاورزی و منابع طبیعی، ۱۵(۲)، ۹-۱.

ناظم‌السادات، م.، انصاری بصیر، ا. و پیشوایی، م.، ۱۳۸۶، ارزیابی سطح معناداری برای پیش‌بینی

کنفرانس بررسی راهکارهای مقابله با بحران آب،
۲۴-۳۱.

نصیری، م.، ۱۳۸۹، پیش‌بینی خشک‌سالی با استفاده از شبکه‌های عصبی مصنوعی (مطالعه موردی ایستگاه سینوپتیک شیراز)، پایان‌نامه کارشناسی ارشد اقلیم‌شناسی، دانشگاه سیستان و بلوچستان، ۱۳۴ص.
نیکزاد، ب.، ۱۳۸۹، آشکارسازی وابستگی‌های بین پارامترهای اقیانوسی- اتمسفری و اقلیمی به منظور پیش‌بینی خشک‌سالی استان خوزستان به وسیله روش داده‌کاوی، پایان‌نامه کارشناسی ارشد منابع آب، پردیس ابوریحان، دانشگاه تهران، ۸۹ص.

یاراحمدی، د.، و عزیزی، ق.، ۱۳۸۶، تحلیل چندمتغیره ارتباط میزان بارش فصلی ایران و شاخص‌های اقلیمی، م. تحقیقات جغرافیایی، ۶۲، ۱۶۱-۱۷۴.

- Abbot, J. and Marohasy, J., 2012, Application of artificial neural networks to rainfall forecasting in Queensland, Australia. *Advances in Atmospheric Sciences* 29 (4), 717-730.
- Barnett, T. P., Pierce, D. W., Latif, M., Dommengot, D. and Saravanan, R., 1999, Interdecadal interactions between the tropics and midlatitudes in the Pacific basin. *Geophysical Research Letters*, 26(5), pp.615-618.
- Barua, S., Ng, A. W. M. and Perera, B. J. C., 2012, Artificial neural network-based drought forecasting using a non-linear aggregated drought index. *J. Hydrol. Eng.* 17 (12), 1408-1413.
- Barua, S., Perera, B. J. C. Ng, A. W. M. and Tran, D., 2010, Drought forecasting using an aggregated drought index and artificial neural network. *J. Water Clim. Chang.* 1 (3), 193-206.
- Chang, P., Ji, L. and Li, H., 1997, A decadal climate variation in the tropical Atlantic Ocean from thermodynamic air-sea interactions. *Nature*, 385(6616), 516-518.
- Chen, Z. Grasby, S. and Osadetz, K. G., 2004, Relation between climate variability and groundwater level in the upper carbonate aquifer. South Manitoba, Canada, *Journal of Hydrology*, 290, 43-62.
- Deo, R. C. and Şahin, M., 2015, Application of the Artificial Neural Network model for prediction of monthly Standardized Precipitation and Evapotranspiration Index using hydrometeorological parameters and climate indices in eastern Australia, *Atmospheric Research*, 161, 65-81.

دوران خشک‌سالی و ترسالی فصل پاییز و شش ماهه سرد ایران بر اساس وضعیت فازهای تابستانه ENSO. م. تحقیقات منابع آب ایران، ۳(۱)، ۱۲-۲۳.
ناظم السادات، م. ج.، ۱۳۸۰، بارندگی زمستانه در ایران، برهمکنش با ENSO. م. کشاورزی، ۲۵(۴)، ۷۴۰-۷۸۲.

ناظم السادات، م. ج.، و شیروانی، الف.، ۱۳۸۵، کاربرد مدل تحلیل CCA برای مطالعه تأثیر دمای سطح خلیج فارس بر بارندگی زمستانه مناطق جنوبی ایران، م. کشاورزی دانشگاه شهیدچمران اهواز، ۲۸(۲)، ۷۷-۶۵.

ناظم السادات، م. ج.، و قاسمی، ا.، ۱۳۸۱، خشک‌سالی و بارندگی مازاد در سیستان و بلوچستان و ارتباط آن با نینو - نوسان جنوبی. مجموعه مقالات اولین

- Farokhnia, A., Morid, S. and Byun, H. R., 2011, 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.
- Hartmann, H., Becker, S. and King, L., 2008, Predicting summer rainfall in the Yangtze River basin with neural networks, *International Journal of Climatology* 28 (7), 925-936.
- Kim, T. W. and Valdes, J. B., 2003, Nonlinear model for drought forecasting based on a conjunction of wavelet transforms and neural networks, *Journal of Hydrologic Engineering* 6, 319-328.
- Lau, K. and Weng, H., 2001, Coherent modes of global SST and summer rainfall over China: an assessment of the regional impacts of the 1997-98 El Nino. *Journal of Climate* 14 (6), 1294-1308.
- Mantua, N. J. and Hare, S. R., 2002, The Pacific decadal oscillation. *Journal of oceanography*, 58(1), 35-44.
- Mekanik, F., Imteaz, M. Gato-Trinidad, S. and Elmahdi, A., 2013, Multiple regression and Artificial Neural Network for long-term rainfall forecasting using large scale climate modes, *Journal of Hydrology*, 503, 11-21.
- Mishra, A. K. and Desai, V. R., 2005, Drought forecasting using stochastic models, *Stochastic Environment Research Risk Assessment*, 19, 326-339.
- Mishra, A. K. and Desai, V. R., 2006, Drought Forecasting Using feed-forward recursive neural network, *Journal of Ecological Modeling*, 198: 127-138.
- NOAA, 2012, Climate Diagnostic Center:

- Climate Indices. Available from: <http://www.cdc.noaa.gov/ClimateIndices>.
- Pongracz, R. and Bartholy, J., 2006, Regional Effects of ENSO in Central/Eastern Europe, *Journal of Advances in Geosciences*, 6: 133-137.
- Poveda, G. Jaramillo, A. Gil, M. M. Quiceno, N. and Mantilla, R., 2001, Seasonality in ENSO-related precipitation, river discharges, soil moisture, and vegetation index (NDVI) in Colombia, *Water Resour. Res.*, 37(8), 2169–2178.
- Pozo, D., 2005, El-Nino-Southern Oscillation Events and Associated European Winter Precipitation Anomalies, *International Journal of Climatology*, 17-31.
- Risbey, J. S., Pook, M. J. McIntosh, P. C. Wheeler, M. C. and Hendon, H. H., 2009, On the remote drivers of rainfall variability in Australia, *Monthly Weather Review* 137 (10), 3233–3253.
- Shukla, R. P., Tripathi, K. C. Pandey, A. C. and Das, I. M. L., 2011, Prediction of Indian summer monsoon rainfall using Niño indices: a neural network approach, *Atmospheric Research* 102 (1–2), 99–109.
- Wolter, K. and Timlin, M. S., 1993, Monitoring ENSO in COADS with seasonally adjusted principal component index, in *Proceedings Seventh Annual Climate Diagnostic Workshop*, Norman, Oklahoma, March 1993, 52–57.

Archive of SID

Artificial Neural Network for Monthly Rainfall Forecasting Using Teleconnection Patterns (Case Study: Central Plateau Basin of Iran)

Ghasemieh, H.¹, Bazrafshan, O.^{2*} and Bakhshayesh Manesh, K.³

1. Assistant Professor, Department of Range and Watershed Management, Faculty of Natural Resources and Geoscience, University of Kashan, Kashan, Iran
2. Assistant Professor, Department of Range and Watershed Management, Faculty of Agriculture and Natural Resources, University of Hormozgan, Bandar Abbas, Iran
3. M.Sc. in Watershed Management Engineering, Department of Range and Watershed Management, Faculty of Natural Resources and Geoscience, University of Kashan, Kashan, Iran

(Received: 24 Feb 2016, Accepted: 18 Oct 2016)

Summary

Rainfall is final result of complex global atmospheric phenomena and long-term prediction of rainfall remains a challenge for many years. An accurate long-term rainfall prediction is necessary for water resources management, food production and evaluation flood risks. Several large scale climate phenomena affect the occurrence of rainfall around the world; of these large scale climate modes El Nino southern Oscillation (ENSO) and Multivariate ENSO Index (MEI) are well known. Many studies have tried to establish the relationship between these climate modes for daily, monthly and seasonal rainfall occurrence around the world but the majority of these studies did not consider the effect of lagged climate modes on future monthly rainfall predictions.

This study focuses on investigating the use of combined lagged teleconnection patterns as potential predictors of monthly rainfall. Direct Multi Step Neural Network (DMSNN) approach was used for this purpose. Four regions (east, center and west) of Central Plateau Basin of Iran were chosen as case studies, each having many rainfall stations. Hence, precipitation data in a common statistical period of 1981-2014 in 20 synoptic stations in the study area were selected and that the data during 1981-2004 were considered to develop the model and the data during 2004-2014 were used for validation the model in order to predict the next 6 months in monthly time scale. Based on the cross correlation function (CCF) results, MEI (Multivariate ENSO Index) and SOI (Southern Oscillation Index) had strong impact on precipitation of the region.

Direct Multi Step Neural Network (DMSNN) modelling was also conducted for the 20 stations of Central Plateau Basin of Iran using the combined lagged MEI and SOI. Multilayer Perceptron (MLP) architecture was chosen for this purpose due to its wide use in hydrologic modeling. To determine the best combination of learning algorithms, hidden transfer and output functions of the optimum model, the Levenberg–Marquardt and backpropagation algorithms were utilized to train the network, tangent sigmoid equations used as the activation functions and the linear equations used as the output function.

The values R² (Correlation Coefficient), RMSE (Root Mean Square Error), and MAE (Mean Absolute Error) parameters were used to explore the efficiency of the model.

ANN models generally showed lower errors and are more reliable for prediction purposes. After calibrating and validating the models they were tested on out-of-sample sets. ANN was able to perform out of sample test with correlation coefficient of 0.81 for the South, and 0.4 for West of Central Plateau Basin of Iran. Although the effect of SOI and MEI in the west is quite weak, however with the use of combined lagged SOI–MEI sets Direct Multi Step Neural Network (DMSNN) modeling, long term rainfall forecast can be achieved. Thus, the results showed that the predicted data preserved the basic statistical properties of the observed series.

The results of this research showed that teleconnection indices are suitable inputs for intelligent models for rainfall prediction. Computing the best structure of artificial neural network models showed that DMSNN can predict rainfall most accurately.

Accurate long term rainfall forecasting can contribute significant positive impacts in water resources management. Central Plateau Basin of Iran climate is greatly fluctuating; at times it goes through severe drought years, then suddenly it experiences wet periods and dry. During drought periods, water supply and irrigation sectors are affected severely; proper prediction of such drought period helps water managers and users to have well-planned, coordinated allocation of resources. Also, prediction of the wet years helps flood management authorities to have well-planned flood disaster management. In addition to predicting rainy month in advance, the developed ANN models are also capable of predicting the intensity of seasonal rainfall.

Keywords: Central Plateau Basin, Teleconnection Patterns, Rain fall, Direct Multi Step Neural Network.