

کاربرد مدل های شبکه عصبی مصنوعی در تخمین نمایه های خشکسالی SPI و

PDSI در ایستگاه سینوپتیک شهر مشهد

الهام عابدینی^{۱*}، محمد موسوی بایگی و حسین انصاری

دانشجوی کارشناسی ارشد هواشناسی کشاورزی، دانشگاه فردوسی مشهد، مشهد، ایران.

ElhamAbedini@gmail.com

استاد گروه مهندسی آب، دانشگاه فردوسی مشهد، مشهد، ایران.

mousavi500@yahoo.com

استادیار گروه مهندسی آب، دانشگاه فردوسی مشهد، مشهد، ایران.

Ansariran@gmail.com

چکیده

خشکسالی در بین بلایای طبیعی از نظر شدت، مدت و خسارت در رتبه اول قرار دارد. برای تخمین خشکسالی به دلیل دینامیک پیچیده حاکم بر آن لازم است از مدل های دینامیکی که در آن فرآیندهای حاکم بر پدیده خشکسالی در نظر گرفته می شود، استفاده کرد. مدل های شبکه عصبی مصنوعی از جمله این مدل ها می باشند که قادرند روابط میان ورودی ها و خروجی های یک سامانه فیزیکی را که توسط شبکه ای از گره ها که همگی با هم متصل هستند، تعیین نمایند. این پژوهش برای پیش بینی پدیده خشکسالی در ایستگاه سینوپتیک شهر مشهد با استفاده از مدل های پرسپترون و گرادیان نزولی با الگوریتم های آموزش مومنتوم و گرادیان نزولی انجام شد. متغیرهای ورودی مدل برای نمایه SPI شامل بارندگی، نمایه بزرگ مقیاس اقلیمی SOI و NAO در فاصله زمانی ۱۹۵۱ الی ۲۰۰۷ و خروجی شبکه نیز نمایه SPI در تاخیرهای زمانی و متغیرهای ورودی برای نمایه PDSI شامل بارندگی، SOI، NAO و دما در فاصله زمانی ۱۹۵۱ الی ۲۰۰۷ و خروجی شبکه نمایه PDSI در تاخیرهای زمانی متفاوت می باشد. برای مدل نمودن نمایه SPI از داده های ۵۷ سال بارندگی ایستگاه سینوپتیک شهر مشهد استفاده شد که ۴۶ سال آن برای آموزش شبکه و مابقی (۱۱ سال) برای آزمون شبکه مورد استفاده قرار گرفت و برای مدل کردن نمایه PDSI از ۵۲ سال داده آماری، ۳۳ سال داده برای آموزش شبکه، ۹ سال برای اعتبار سنجی و ۱۰ سال باقیمانده نیز برای آزمون شبکه با استفاده از نرم افزار Nero Solutions5 انجام شد. همچنین به منظور بررسی ارتباط ENSO با بارش های ایستگاه سینوپتیک مشهد از روش رگرسیون استفاده شد. بررسی نتایج نشان داد مقادیر نوسانات جنوبی تاثیر اندک و مقادیر نوسانات اطلس شمالی دارای عدم تاثیر روی بارندگی های ایستگاه سینوپتیک مشهد هستند. وقوع پدیده انسوی قوی در جهان بر روی بارندگی های ایستگاه سینوپتیک مشهد تاثیر گذاشته، لایننا باعث خشکسالی در سال بعد از وقوع آن و موجب کاهش بارندگی در این ایستگاه شده و وقوع فاز گرم انسو موجب افزایش بارندگی در فصل زمستان و کاهش بارندگی در دیگر فصول می گردد. به علت زیاد بودن دامنه تغییرات بارندگی در مقیاسهای ۱، ۲ و ۳ ماهه دقت نتایج پیش بینی شده توسط این سری های زمانی بسیار کم است و با افزایش مقیاس زمانی نمایه، دامنه تغییرات بارندگی نیز کاهش می یابد و بر دقت نتایج افزوده می شود. همچنین مدل های پرسپترون و پیشخور عمومی دارای عملکرد خوبی در پیش بینی خشکسالی هستند، به طوری که معیارهای عملکرد $R^2 = 0.78$ برای پیش بینی SPI ۱۸ ماهه و $R^2 = 0.76$ برای پیش بینی PDSI گویای این مطلب می باشند.

واژه های کلیدی: مدل پرسپترون، مدل گرادیان نزولی.

^۱ - آدرس نویسنده مسئول: بیرجند خیابان معلم، معلم ۱۸، پلاک ۲۵ - طبقه ۴

* دریافت: شهریور ۱۳۹۱ و پذیرش: آبان ۱۳۹۲

دقت بالاتری ($R^2=0/94$ نسبت به $R^2=0/92$) مقادیر SPI را پیش بینی می کند.

در پژوهشی دیگر، میسرا و همکاران (۲۰۰۶) برای تخمین خشکسالی از نمایه SPI در حوضه رودخانه کانزاباکی در غرب بنگال از مدل های شبکه های عصبی چندگانه برگشتی (RMSNN)، مدل های شبکه عصبی چندگانه مستقیم ($DMSNN^2$) و مدل های تصادفی خطی ($ARIMA/SARIMA^3$) استفاده کردند. نتایج آنها نشان می دهد که مدل های آماری نتایج خوبی از نظر پیش بینی کوتاه مدت خشکسالی تا ۲ ماه دارد و مدل های شبکه های عصبی در مقایسه با مدل های آماری کارایی بیشتری دارند.

واسیلیدس و لوکاس (۲۰۰۶) برای ارزیابی توانایی شبکه های عصبی در پیش بینی خشکسالی ماهانه با کمک نمایه SPI در حوضه رودخانه پینیوس^۴ کشور یونان از مدل های شبکه عصبی مصنوعی استفاده کردند. آنها برای بررسی خشکسالی ترکیبی از مدل های شبکه عصبی و تکنیک اثرات آئروگرافیکی غیرخطی در مقیاس های مکانی مختلف استفاده کردند. آنها قبلا در مطالعات خود متوجه شده بودند که مقادیر SPI شش ماهه برای بررسی خشکسالی هیدرولوژی مناسب است. نتایج آنها حاکی از آن است که تکنیک استفاده شده برای دورن یابی مکانی خشکسالی قابل قبول بوده و می توان برای پیش بینی و پایش خشکسالی از آن استفاده کرد.

برای پیش بینی خشکسالی در شرایط آبی مرید و همکاران (۲۰۰۷) نیز از تکنیک شبکه های عصبی مصنوعی از نوع پرسپترون سه لایه و نمایه های خشکسالی SPI و EDI در استان تهران استفاده کردند. نتایج حاکی از آن است که روش بکار رفته تا حدود ۸۰ درصد وضعیت خشکسالی شش ماه آینده را به درستی

خشکسالی برخلاف خشکی، که یک خصوصیت دائمی اقلیم است و به مناطق با بارندگی کم محدود می شود، یک نابهنجاری موقتی است و همچنین با دیگر خطرات طبیعی از قبیل سیل، چرخندهای حاره ای و زلزله تفاوت دارد. دقت پیش بینی خطرات طبیعی بسیار متغیر است و مخصوصا در مورد خشکسالی از اهمیت خاصی برخوردار است. محققان در گذشته برای پیش بینی فرایندهای هواشناسی و هیدرولوژیکی از جمله خشکسالی از مدل های مختلفی مانند سری های زمانی تجربی و مدل های فیزیکی استفاده می کردند.

با توجه به استفاده گسترده از این مدل های آماری، اینها دارای معایبی از قبیل نیاز به حجم داده های آماری زیاد و عدم توانایی در پیش بینی رفتار دینامیکی پدیده های جوی می باشند که امروزه استفاده از آنها را کاهش داده است (بیرکنس، ۱۹۹۸). در دو دهه اخیر، مدل های دینامیکی غیر خطی مانند تکنیک شبکه های عصبی مصنوعی و منطق فازی به طور گسترده ای جایگزین مدل های آماری شده است، (مایر و دندی، ۲۰۰۰)، (الن و همکاران، ۲۰۰۷). این شبکه ها قادرند رابطه میان ورودی ها و خروجی های یک سامانه فیزیکی را با استفاده از شبکه ای از گره ها که همگی با هم متصل هستند، تعیین نمایند. در این رابطه میزان فعالیت هر یک از این پیوست ها به وسیله اطلاعات تاریخی تنظیم شده و سرانجام مدل قادر خواهد بود قوانین مرتبط میان ورودی ها و خروجی ها را کشف کند.

عیوضی و همکاران (۱۳۸۸) به منظور پیش بینی شاخص خشکسالی^۱ SPI در دوره های زمانی ۱، ۳، ۶ و ۹ ماهه از مدل های شبکه عصبی مصنوعی MLP و تابع پایه ای شعاعی RBF در حوضه آب خیز گرگان رود استفاده کردند. نتایج نشان داد مدل های شبکه عصبی مصنوعی MLP نسبت به شبکه عصبی مصنوعی RBF با

² - Direct Multi-Step Neural Network

³ - Linear Stochastic Models

⁴ - Pinios

¹ - Standard Precipitation Index

در پژوهشی، گابلس (۲۰۰۶) به بررسی اثرات انسو و تغییرات دمای آب اقیانوس آرام بر روی بارندگی زمستانه در کشور هند در طول سال های ۱۹۲۸ تا ۱۹۹۸ پرداخت. وی برای بررسی ارتباط این پدیده ها با بارندگی هند، از آنالیز همبستگی استفاده کرد که نتایج نشان دهنده ارتباط منفی بین بارندگی زمستانه و نمایه انسو بود.

نتایج پژوهش های محققان دنیا نشان می دهد که شاخص های بزرگ مقیاس جوی بر روی آب و هوای کل دنیا تاثیر می گذارند. وقوع پدیده النینو باعث ایجاد خشکسالی های بزرگی در منطقه خاورمیانه می شود. از طرفی یافته های این محققان نشان می دهد که مدل های عصبی هم قادرند شاخص های خشکسالی را حداکثر تا ۱۲ ماه آینده با دقت خوبی تخمین بزنند.

لذا در این پژوهش سعی بر آن شد تا در ابتدا ارتباط شاخص های بزرگ مقیاس جوی با مقدار بارش های مشهد بررسی و سپس پس از یافتن ارتباط از این شاخص ها نیز به عنوان ورودی های مدل شبکه عصبی در این پژوهش استفاده شود.

به علت خشکسالی های اخیر و کاهش نزولات جوی در مشهد در این پژوهش شاخص های خشکسالی SPI و PDSI با استفاده از شبکه های عصبی مصنوعی پیش بینی و اثر علائم بزرگ مقیاس هواشناسی بر روی بارش های ایستگاه سینوپتیک مشهد بررسی شد تا با یافتن راه حل زمان وقوع خشکسالی، نتایج این پژوهش به مدیران و برنامه ریزان کشور کمک بیشتری در زمینه بررسی و تلاش برای مقابله با این بلای طبیعی به منظور برنامه ریزیهای درازمدت کند.

مواد و روش ها

ایستگاه مورد مطالعه در این پژوهش، ایستگاه سینوپتیک شهر مشهد با طول جغرافیایی ۵۹ درجه و ۳۸ دقیقه شرقی، عرض جغرافیایی ۳۶ درجه و ۱۶ دقیقه شمالی و ارتفاع ۹۹۹/۲ متر از سطح دریا می باشد.

پیش بینی می کند. این مقدار برای دوره های ۹ و ۱۲ ماهه به ترتیب ۶۸ و ۶۰ درصد می باشد.

علائم بزرگ مقیاس اقلیمی به عنوان ابزارهای مناسبی برای بررسی و پیش بینی تغییرات بلند مدت رفتار بارندگی ها هستند. این علائم معمولاً با استفاده از نمایه هایی که بر اساس فشار هوا و دمای سطح آب اقیانوس ها محاسبه می شوند، به صورت کمی بیان می گردند. برخی از این علائم عبارتند از: پدیده انسو، النینو، لائینا، نوسانات جنوبی^۴ و نوسانات اطلس شمالی^۵. در این رابطه ناظم السادات و کوردری (۲۰۰۰) و همچنین ناظم السادات (۱۳۷۹) تأثیر انسو را بر بارش ۴۱ ایستگاه واقع در ایران بررسی نمودند. برای این پژوهش نوسانات جنوبی را به عنوان یک شاخص به منظور پیش بینی بارش فصلی در نظر گرفتند.

نتایج حاصله از مطالعات آن ها نشان می دهد که ارتباط معنی داری بین بارندگی پاییزه و SOI در سواحل جنوبی ایران وجود ندارد، در حالی که بارندگی پاییزه مناطق شمال غرب بیشتر تحت تأثیر SOI قرار دارد. در نواحی شمال شرقی ایران، همبستگی بین بارش پاییزه ایستگاه های مشهد و سبزوار با SOI ضعیف، در حالی که این همبستگی برای ایستگاه های نیشابور و بیرجند قابل توجه می باشد.

در تحقیقی، کوره پزان (۱۳۸۲) به بررسی تاثیر علائم هواشناسی بزرگ مقیاسی چون ENSO، SST^۶ و NAO بر پیش بینی تغییرات بارش مناطق جنوبی ایران پرداخت. تحلیل های اولیه وی که با استفاده از ماتریس های احتمال و تحلیل همبستگی صورت گرفت، نشان دادند این مناطق در فازهای گرم ENSO و NAO و فاز سرد SST با پربارشی و در فازهای سرد ENSO و NAO و فاز گرم SST با کم بارشی مواجه هستند.

- 1- EL Nino Southern Oscillation
- 2- EL Nino
- 3- La Nina
- 4- Southern Oscillation Index
- 5- Northern Atlantic Oscillation
- 6- Sea Surface Temperature

بدین صورت که باتوجه به فرضیات پالمر، رطوبت موجود در حالت ظرفیت زراعی در لایه سطحی ۲۵ میلی - متر در نظر گرفته شده و تغییرات رطوبتی در هر یک از دو لایه نیز متأثر از میزان رطوبت موجود در هر یک از لایه ها و تغییرات آنها بوده است. همچنین فرض شده که هدررفت آب از لایه زیرین به حجم رطوبت اولیه که خود نیز به تبخیر و تعرق پتانسیل (PE) و حجم رطوبت در دسترس (AWC) وابسته است، مربوط می شود. در محاسبات حاضر، باتوجه به مشخصات خاک منطقه مقادیر AWC معادل ۱۶۰ میلی متر فرض شد. همچنین فرض شد که رواناب تنها زمانی به وقوع خواهد پیوست که هر دو لایه ظرفیت رطوبتی خود را دریافت دارند.

علاوه بر تبخیر و تعرق پتانسیل، سه ترم دیگر پتانسیلی نیز محاسبه شده، که عبارتند از: تغذیه پتانسیل (PR)، میزان رطوبت مورد نیاز برای رساندن رطوبت به حد ظرفیت زراعی، هدررفت پتانسیل، مقدار رطوبتی که می تواند به وسیله تبخیر و تعرق از خاک از دست برود، زمانی که بارندگی صفر است و رواناب پتانسیل (PRO)، که تفاوت بین بارندگی پتانسیل و تغذیه پتانسیل است.

گام ۲) محاسبه ضرایب اقلیمی:

این بخش از محاسبات با شبیه سازی بیلان آبی برای دوره ای که داده های هواشناسی موجود است، قابل انجام می باشد. ضرایب ماهانه از نسبت های بین متوسط های اقلیمی واقعی در مقابل مقادیر پتانسیلی تبخیر و تعرق، تغذیه، رواناب و هدر رفت، به دست می آید.

گام ۳) محاسبه مقادیر CAFEC (شرایط مناسب اقلیمی برای شرایط موجود):

در این مرحله، ضرایب مذکور برای تعیین مقدار بارندگی (PC) مورد نیاز برای شرایط CAFEC محاسبه شد.

از داده های دما و بارش روزانه برای محاسبه نمایه های خشکسالی و همچنین از مقادیر شاخص های SOI و NAO نیز که از سایت NOAA استخراج شده است. برای بررسی اثر سیگنال های بزرگ مقیاس بر روی نتایج خروجی مدل ها و تاثیر آنها بر روی بارش و دمای مشهد، استفاده شد و کلیه داده ها در بازه صفر و یک با استفاده از فرمول (۱) نرمال شدند. سپس، با استفاده از ضریب همبستگی ارتباط بین مقادیر بارندگی و دمای نرمال شده و نمایه SOI و NAO در طول دوره آماری ۵۷ ساله در مقیاس فصلی و ماهانه با استفاده از نرم افزار آماری SPSS محاسبه شد.


$$X_n = 0.5 \times \left[\frac{X - \bar{X}}{X_{\max} - X_{\min}} \right] + 0.5$$

که در آن: X_n : مقدار نرمال شده پارامتر، X : مقدار واقعی هر پارامتر، \bar{X} : میانگین پارامتر مورد نظر، X_{\max} : بیش ترین مقدار پارامتر مورد نظر، و X_{\min} : کمترین مقدار پارامتر مورد نظر می باشند.

از نرم افزار SPI-SL6 و از داده های بارش روزانه در فاصله زمانی ۱۹۵۱ الی ۲۰۰۷ (۱۳۸۶-۱۳۳۰) برای تولید شاخص خشکسالی SPI در مقیاس های زمانی مختلف و از داده های دما و بارش روزانه طی همین بازه و با استفاده از نرم افزار PDSI به منظور محاسبه شاخص PDSI استفاده شد. برای محاسبه شاخص خشکسالی PDSI پنج گام محاسباتی انجام شد.

گام ۱) محاسبات هیدرولوژیکی:

در اولین گام محاسباتی این شاخص، بیلان آبی با استفاده از داده های طولانی مدت درجه حرارت، بارندگی و رطوبت خاک به عنوان اطلاعات ورودی مدنظر قرار گرفته است. اما از آنجایی که، داده های رطوبت خاک برای دوره آماری ۳۴ ساله در اختیار نمی باشد، لذا یک روش تجربی برای محاسبه رطوبت ذخیره شده در خاک با تقسیم خاک به دو لایه مشخص استفاده شد.



شکل ۱- مدل یک نرون چند ورودی

ورودی خالص net_j و خروجی y_j ، مطابق روابط (۲) و (۳) محاسبه می‌شوند.

$$net_j = \sum_{k=0}^k P_k W_{jk} + b \quad (3)$$

$$y_j = g(net_j) \quad (4)$$

که در آن ها: p_1, p_2, \dots, p_k : سیگنال‌های ورودی، $w_{j1}, w_{j2}, \dots, w_{jk}$: وزن‌های سیناپسی جمع شونده به یک نرون، net_j : تاثیر تجمعی همه نرون‌های متصل به نرون j و آستانه داخلی نرون j : تابع فعالیت، b : آستانه خارجی که از آن به عنوان بایاس^۱ یاد می‌شود و در مقدار ثابت یک ضرب می‌شود، و y_j : سیگنال خروجی نرون، می‌باشند (جورابیان و هوشمند، ۲۰۰۳).

برای طراحی شبکه عصبی مصنوعی MLP و GFF به منظور تخمین سری زمانی نمایه SPI، از داده های بارش ماهیانه و مقادیر نمایه های سیگنال‌های بزرگ مقیاس جوی SOI و NAO که بر روی الگوهای بارندگی جهان تاثیر گذار هستند، با شش گام زمانی پیشین در طی سال‌های ۱۹۵۱ الی ۲۰۰۷ (۱۳۸۶-۱۳۳۰) استفاده شد و برای طراحی این شبکه ها به منظور تخمین نمایه PDSI نیز از داده های بارش ماهیانه، مقادیر نمایه های سیگنال های بزرگ مقیاس جوی SOI و NAO و مقادیر ماهیانه متوسط دما با ۱۲ گام زمانی پیشین استفاده شد.

برای طراحی ساختار شبکه های MLP و GFF برای مدل کردن نمایه SPI، از ۵۷ سال داده آماری ۳۵ سال داده برای آموزش شبکه، ۱۱ سال برای اعتبار سنجی و ۱۱ سال باقیمانده نیز برای تست شبکه و برای مدل کردن نمایه PDSI از ۵۲ سال داده آماری ۳۳ سال داده برای

گام ۴) محاسبه شاخص آنومالی رطوبت:

در هر ماه، تفاوت بین بارندگی واقعی (P) و بارندگی در شرایط CAFEC (پارامتر PC) به عنوان یک شاخصی از کمبود یا افزایش رطوبت برای منطقه مورد مطالعه ($D = P - PC$) محاسبه شد. سپس انحرافات مذکور به شاخص‌هایی از آنومالی رطوبت به صورت $Z = K_j.D$ تبدیل شوند که K_j یک فاکتور وزنی برای ماه j ام است که تغییرپذیری مکانی انحرافات D را در محاسبات وارد می‌کند.

گام ۵) محاسبه شدت خشکسالی:

در گام نهایی، سریهای زمانی شاخص Z برای ایجاد یک معیار برای تعیین شروع و خاتمه خشکسالی و ارائه یک فرمول برای تعیین شدت آن مورد بررسی قرار گرفت. در این گام، برای تعیین شدت خشکسالی از عبارت تجربی ارائه شده توسط پالمر به صورت زیر استفاده شد:

$$X_j = 0.897X_{j-1} + \frac{Z_j}{3} \quad (2)$$

در این رابطه، مقادیر X_j همان مقادیر PDSI برای ماه j ام است.

شبکه های عصبی مصنوعی

نحوه محاسبات در شبکه های عصبی بدین صورت است که مجموعه‌ای از داده‌ها به عنوان ورودی نرون (که شاید خروجی‌های نرون‌های دیگر باشند) در وزن های متناظرشان ضرب می‌شود و بعد همه ورودی-های وزن‌دار شده، به منظور تعیین سطح فعالیت نرون، با هم جمع می‌شوند (مهدی زاده، ۱۳۸۳). شکل (۱) مدل یک نرون چند ورودی را نشان می‌دهد.

^۱ - Bias

$$R^2 = \frac{\sum_{i=1}^n (y_{act} - \bar{y}_{act})(y_{est} - \bar{y}_{est})^2}{\sum_{i=1}^n (y_{act} - \bar{y}_{act})^2 (y_{est} - \bar{y}_{est})^2} \quad (5)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_{est} - y_{act})^2}{n}} \quad (6)$$

$$MAE = \frac{\sum_{i=1}^n |y_{est} - y_{act}|}{n} \quad (7)$$

آموزش شبکه، ۹ سال برای اعتبار سنجی و ۱۰ سال باقیمانده نیز برای تست شبکه با استفاده از نرم افزار Nero Solutions 5 انتخاب شده و در فاز یادگیری از الگوریتم های مومنتوم و گرادیان نزولی برای آموزش شبکه استفاده شد. همچنین، برای ارزیابی عملکرد شبکه های عصبی سه معیار ضریب رگرسیون R^2 و ریشه میانگین مجذور خطا RMSE و متوسط قدرمطلق خطا MAE بکار گرفته شد.

جدول ۱- حالت های مختلف در نظر گرفته شده برای هر یک از معماری های مختلف

لایه پنهان		لایه خروجی	
تابع انتقال	الگوریتم آموزشی	تابع انتقال	الگوریتم آموزشی
حالت اول	سیگموئید	خطی	مومنتوم
حالت دوم	سیگموئید	خطی	گرادیان نزولی

مورد نظر نرمال شدند تا بررسی حالت های تر، نرمال و خشک راحت تر انجام شود. به طور کلی، در طی دوره آماری ۵۷ ساله مورد مطالعه (۲۰۰۷-۱۹۵۱)، ۱۸ رویداد انسو وجود داشته است. جدول (۲) سال های وقوع فاز گرم یا النینو و فاز سرد یا لانینا که در سطح جهان رخ داده است را نشان می دهد.


که در آن ؛ y_{act} : مقادیر مشاهده شده (واقعی)، \bar{y}_{act} : میانگین مقادیر مشاهده شده (واقعی)، y_{est} : مقادیر تخمینی (خروجی مدل) و \bar{y}_{est} : میانگین مقادیر تخمینی (خروجی مدل) و n : تعداد داده ها می باشد.

نتایج


به منظور بررسی ارتباط ENSO و بارندگی و دمای سالانه ایستگاه مشهد، داده های بارندگی

جدول ۲- سال های وقوع رویداد انسو (فاز گرم یا النینو و فاز سرد یا لانینا) در طی دوره آماری ۱۹۵۱-۲۰۰۷

سال وقوع	۱۹۵۴	۱۹۶۵	۱۹۶۸	۱۹۷۸	۱۹۸۲	۱۹۸۶	۱۹۹۱	۱۹۹۴	۱۹۹۷	۲۰۰۲	۲۰۰۴	
فاز گرم انسو(ال نینو)												
سال وقوع	۱۹۵۷	۱۹۷۲	۱۹۷۶	۱۹۸۸	۱۹۹۹	۲۰۰۰	۲۰۰۶	فاز سرد انسو(لانینا)				



شکل ۲- وضعیت بارندگی نرمال شده در سال های وقوع فاز گرم انسو، سال بعد و دو سال بعد از آن



شکل ۳- وضعیت بارندگی نرمال شده در سال های وقوع فاز سرد انسو، سال بعد و دو سال بعد از آن

محدوده به عنوان محدوده نرمال در نظر گرفته شد. تعداد وضعیت های تر، نرمال و خشک برای سال های مورد بررسی در جدول (۳) آمده است.

برای بررسی ارتباط SOI و NAO با بارندگی و دمای ایستگاه سینوپتیک مشهد در طول دوره آماری ۵۷ ساله، معادله رگرسیونی بین آنها محاسبه شد. همچنین به منظور بررسی ارتباط SOI و NAO با بارندگی و دمای فصلی نیز داده های ماهیانه SOI و NAO با محاسبه میانگین سه ماه متوالی به فصلی تبدیل شدند و ضرایب همبستگی بین سری زمانی فصلی آنها و بارندگی و دما برای بررسی وجود ارتباط معنی دار بین آنها محاسبه گشت. نتایج نشان دهنده ارتباط ضعیف میان بارندگی ها و مقادیر نمایه SOI در طول آماری ۵۷ سال است، ۰.۰۳۳.

به علت این که در اکثر پژوهش های هیدرولوژی محدود به ۲۰ درصد صفر بارندگی را به عنوان محدوده نرمال در نظر می گیرند (باقرزاده، ۱۳۸۴)، در این پژوهش نیز این


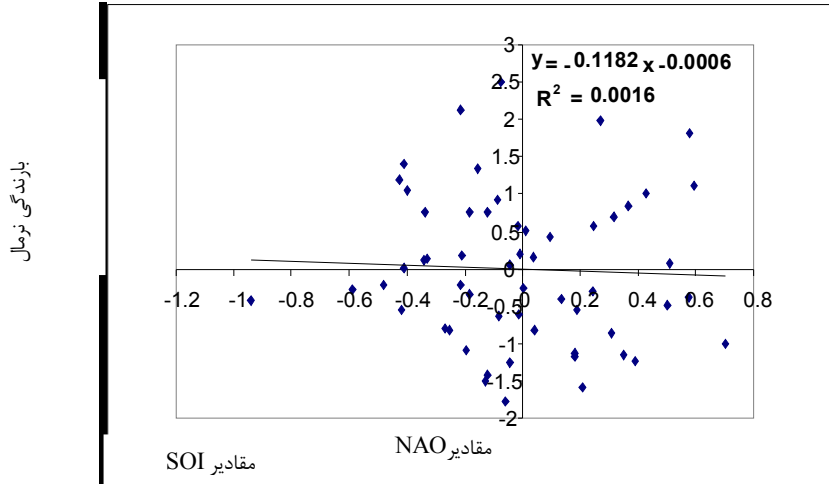
جدول ۳- تعداد وضعیت تر، نرمال و خشک برای سال های

مورد بررسی			
وضعیت اعلام شده	سال وقوع	یک سال بعد	دو سال بعد
ال نینو	تر	۶	۴
	نرمال	۱	۱
خشک	تر	۴	۶
	نرمال	۱	۳
لاتینا	تر	۱	۲
	خشک	۳	۴

بارندگی های سال ۱۹۵۷ در دیگر سال ها هیچ ارتباط معنی داری میان بارندگی های ایستگاه سینوپتیک مشهد و مقادیر شاخص NAO در سطح معنی دار پنج درصد وجود ندارد.

$R^2 =$ در میان سال هایی که در آنها انسورخ داده است، میان داده های بارندگی ایستگاه سینوپتیک مشهد و مقادیر SOI جهانی در سال های ۱۹۵۷، ۱۹۶۵، ۱۹۸۲، ۱۹۸۶، ۱۹۸۸ و ۲۰۰۰ در سطح پنج درصد و سال ۲۰۰۶ در سطح یک درصد اختلافات معنی داری وجود دارد. به جز

(الف)




(ب)

شکل ۴- الف وب ارتباط SOI و NAO با بارندگی های سالانه ایستگاه سینوپتیک مشهد



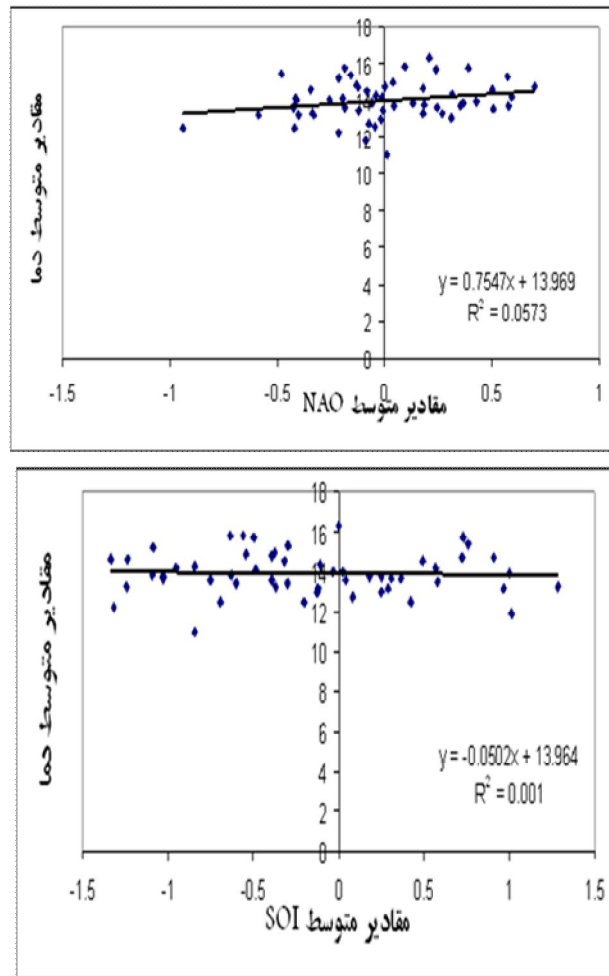
(الف)



(ب)

شکل ۵- الف وب ارتباط SOI و NAO با بارندگی های فصلی ایستگاه سینوپتیک مشهد

(الف)




(ب)

شکل ۶- الف وب ارتباط SOI و NAO با دمای سالانه ایستگاه سینوپتیک مشهد

که ال نینو و لائینای قوی ای در جهان رخ می داده است این مسئله بر روی دماهای ثبت شده در ایستگاه سینوپتیک مشهد اثرگذار بوده است.

در سال های ۱۹۷۲، ۱۹۷۶ و ۱۹۹۹ ارتباط معنی داری بین مقادیر دما و بارندگی در سطح ۱٪ و در سال های ۱۹۶۵، ۱۹۹۷ و ۲۰۰۰ در سطح ۵٪ وجود داشته است که این مسئله نشان می دهد که در اکثر سال هایی




(الف)

(ب)

شکل ۵- الف وب ارتباط SOI و NAO با دمای فصلی ایستگاه سینوپتیک مشهد

سینوپتیک مشهد، نسبت مقادیر REI/Ra محاسبه گشت در آن میانه بارندگی و Ra میانه بارندگی در درازمدت است.

در مقیاس فصلی هیچ ارتباط معنی داری میان داده های دمای متوسط فصل ها با مقادیر SOI و NAO وجود ندارد. برای بررسی تاثیر فاز گرم و فاز سرد انسو بر روی بارندگی های بهاره، تابستانه، پاییزه و زمستانه ایستگاه



شکل ۶- الف و ب: نسبت میانه بارندگی به میانه درازمدت آن در فصول مختلف در شرایط ال نینو و لانینا برای ایستگاه سینوپتیک مشهد

شکل (۶) الف و ب نشان می دهد که نسبت REI/Ra برای فصل زمستان بیشتر از یک و در دیگر فصول کمتر از یک می باشد که این مسئله نشان دهنده افزایش بارندگی در فصل زمستان به علت وقوع فاز گرم انسو و کاهش بارندگی در دیگر فصول، در این ایستگاه است. همچنین

برای فاز سرد انسو در تمامی فصول مقدار این نسبت کمتر از واحد است و در نتیجه وقوع فاز سرد انسو (لانینا) موجب کاهش بارندگی در این منطقه می شود. پس از بررسی عوامل تاثیرگذار بر روی بارندگی و دمای ایستگاه سینوپتیک مشهد ورودی های مختلفی برای طراحی مدل های شبکه عصبی مصنوعی استفاده شد.

$$SPI_{(t+1)} = f(R_i, NAO_i, SOI_i, SPI_i) \quad i = (t, t-1, t-2, t-3, \dots, t-5) \quad (۸)$$

$$PDSI_{(t+1)} = f(PDSI_i, TEM_i, R_i, SOI_i)$$

$$i = (t, t-1, t-2, t-3, t-4, t-5, t-6, t-7, t-8, t-9, t-10, t-11)$$

چند ماه بعد این شاخص ها در ایستگاه سینوپتیک مشهد مورد ارزیابی قرار گرفت.

جدول (۴) بهترین ساختار های بدست آمده از شبکه های پرسپترون و پیشخور عمومی با الگوریتم های مومنتوم و گرادیان نزولی برای پیش بینی شاخص های خشکسالی را نشان می دهد.

(۹)

در این حالت ها اندیس $(t+1)$ بیانگر زمان آینده و $t, (t-1), (t-2), (t-3), (t-4), (t-5)$ و ... بیان کننده زمان های قبل تر می باشند. همچنین ترکیبات مختلفی از گام های زمانی ورودی های مختلف با یکدیگر نیز امتحان شدند. پس از آن که حالت های مختلف ورودی ها تهیه گشت نحوه عملکرد آنها برای پیش بینی

جدول ۴- طراحی ساختار شبکه های پرسپترون، پیشخور عمومی در مقیاس های زمانی مختلف برای نمایه های خشکسالی SPI و PDSI

طراحی مدل پیشخور عمومی		طراحی مدل پرسپترون		نمایه خشکسالی
الگوریتم مونتوم	الگوریتم گرادیان نزولی	مدل پرسپترون الگوریتم مونتوم	الگوریتم گرادیان نزولی	
۱۰-۱۳-۱	۸-۲-۱	۱۵-۲۱-۱	۸-۱۶-۱	SPI یک ماهه
۱۵-۴-۱	۱۳-۱۶-۱	۱۲-۱۱-۱	۱۳-۱۹-۱	SPI دو ماهه
۱۵-۴-۱	۱۲-۹-۱	۱۲-۱۶-۱	۱۵-۱۹-۱	SPI شش ماهه
۱۲-۱۶-۱	۱۱-۱۹-۱	۱۵-۱۶-۱	۱۰-۲۱-۱	SPI نه ماهه
۱۲-۱۰-۱	۱۲-۱۵-۱	۱۲-۱۸-۱	۱۲-۴-۱	SPI دوازده ماهه
۱۳-۲۱-۱	۱۲-۳-۱	۱۲-۱۳-۱	۱۲-۱۳-۱	SPI هجده ماهه
۱۱-۱۵-۱	۱۲-۳-۱	۱۱-۱۴-۱	۱۱-۳-۱	SPI بیست و چهار ماهه
۹-۱۱-۱	۱۱-۲-۱	۱۰-۳-۱	۱۱-۴-۱	SPI چهل و هشت ماهه
۴۸-۱۰-۱	۱۹-۸-۱	۴۷-۱۱-۱	۲۴-۶-۱	PDSI

جدول ۵- مقایسه عملکرد مدل های طراحی شده برای نمایه های SPI و PDSI در مرحله آزمون شبکه

مرحله تست شبکه												نمایه
MAE				RMSE				R2				
پیشخور عمومی		پرسپترون		پیشخور عمومی		پرسپترون		پیشخور عمومی		پرسپترون		
مونتوم	گرادیان نزولی	مونتوم	گرادیان نزولی	مونتوم	گرادیان نزولی	مونتوم	گرادیان نزولی	مونتوم	گرادیان نزولی	مونتوم	گرادیان نزولی	
۰.۰۳۵	۰.۰۴۵	۰.۰۳۵	۰.۰۳۷	۰.۰۴۸	۰.۰۵۷	۰.۰۴۸	۰.۰۵	۰.۱۴۹	۰.۰۹	۰.۱۷	۰.۰۹۲	SPI-۱
۰.۰۳۲	۰.۰۳۲	۰.۰۳۲	۰.۳	۰.۰۴۳	۰.۰۴۲	۰.۰۴۳	۰.۰۴۱	۰.۳۴۶	۰.۳۷۱	۰.۳۳۶	۰.۳۹۴	SPI-۲
۰.۰۲۳	۰.۰۲۳	۰.۰۲۴	۰.۰۲۳	۰.۰۳	۰.۰۳	۰.۰۲۶	۰.۰۳	۰.۶۱	۰.۶۱	۰.۶۱	۰.۶۴	SPI-۳
۰.۰۱	۰.۰۱	۰.۰۱	۰.۰۱	۰.۰۳	۰.۰۳	۰.۰۲۶	۰.۰۳	۰.۷	۰.۷	۰.۷	۰.۶۹	SPI-۹
۰.۰۱	۰.۰۱	۰.۰۱	۰.۰۱	۰.۰۳	۰.۰۳	۰.۰۳	۰.۰۳	۰.۸۶	۰.۸۵	۰.۸۵	۰.۸۵	SPI-۱۲
۰.۰۱	۰.۰۱	۰.۰۱	۰.۰۱	۰.۰۳	۰.۰۳	۰.۰۳	۰.۰۳	۰.۸۸	۰.۸۸	۰.۸۷	۰.۸۸	SPI-۱۸
۰.۰۱	۰.۰۱	۰.۰۱	۰.۰۱	۰.۰۵	۰.۰۵	۰.۰۵	۰.۰۵	۰.۷۳	۰.۷۶	۰.۷۳	۰.۷۳	SPI-۲۴
۰.۰۱	۰.۰۱	۰.۰۱	۰.۰۱	۰.۰۳	۰.۰۳	۰.۰۳	۰.۰۳	۰.۸۴	۰.۸۴	۰.۸۴	۰.۸۳	SPI-۴۸
۰/۰۱۷	۰/۰۱۶	۰/۰۱۶	۰/۰۱۸	۰/۰۲۴	۰/۰۲۳	۰/۰۲۳	۰/۰۲۴	۰/۸۸	۰/۸۹	۰/۸۹	۰/۸۹	PDSI

ولی مقادیر NAO هیچ گونه تاثیری بر روی این بارندگی ها نداشته است.

به طور کلی وقوع رخداد ال نینو موجب افزایش بارندگی ها در ایستگاه سینوپتیک مشهد شده، ولی وقوع لانینا تاثیر مشخصی (افزایش یا کاهش بارندگی) روی بارندگی ها نداشته، فقط با توجه به مشاهدات می توان گفت که لانینا موجب کاهش بارندگی های سال بعد از وقوع خود می شود. در مقیاس فصلی نیز مقادیر این علائم هیچ گونه تاثیری بر روی بارندگی های ایستگاه

بحث و نتیجه گیری

در تحقیق حاضر به بررسی تاثیرات علائم هواشناسی SOI و NAO بر بارندگی و دمای ایستگاه سینوپتیک مشهد پرداخته شد که نتایج ارزیابی مقادیر نمایه SOI نشان می دهد که در مقیاس سالانه در سال هایی که انسوی خیلی شدیدی رخ می داده است، بارندگی همان سال ایستگاه سینوپتیک مشهد تحت تاثیر قرار می گرفته،

NAO بر روی خشکسالی های جهان اثرات زیادی دارند، در این پژوهش نیز از این دو شاخص به همراه شاخص های خشکسالی به عنوان ورودی مدل استفاده شد، ولی نتایج به دست آمده نشان می دهد که مقدار این دو شاخص بر روی شاخص های خشکسالی شبیه سازی شده در مشهد تاثیر چندانی نداشته که نتایج بدست آمده با نتایج پژوهش های ناظم السادات و کوردری نیز مطابقت دارد. در مورد SPI های یک ماهه و سه ماهه به علت کم بودن مقادیر R2 پیش بینی میسر نیست.

سینوپتیک مشهد نداشته اند. در مورد مقادیر دمای متوسط و ارتباط آن با نمایه های SOI و NAO چه در مقیاس فصلی و چه در مقیاس سالانه هیچ گونه ارتباط قابل توجه ای بین آنها مشاهده نشد. همچنین نتایج بررسی اثر فاز گرم و سرد انسو بر روی بارندگی های مشهد نشان داد که به طور کلی وقوع فاز گرم انسو موجب کاهش بارندگی در فصل های بهار، تابستان و پاییز، افزایش بارندگی در زمستان و وقوع فاز سرد انسو موجب کاهش بارندگی در تمامی فصل های سال در این ایستگاه می گردد. از آنجایی که میزان شدت نمایه های SOI و

جدول ۶- پیش بینی سری زمانی های SPI و PDSI برای یک ماه آینده

شاخص	شبکه	الگوریتم	R ²	RMSE	MAE
SPI ۶ ماهه	پرسپترون	گرادیان نزولی	۰/۳۶۴	۰/۰۶۵	۰/۰۳۵
SPI ۹ ماهه	پرسپترون	مومنتوم	۰/۵۷۲	۰/۰۶۹	۰/۰۳
SPI ۱۲ ماهه	پیشخور عمومی	مومنتوم	۰/۷۷۱	۰/۰۴۱	۰/۰۲
SPI ۱۸ ماهه	پیشخور عمومی	گرادیان نزولی	۰/۷۷۸	۰/۰۴۲	۰/۰۲۱
SPI ۲۴ ماهه	پیشخور عمومی	گرادیان نزولی	۰/۶۲۸	۰/۰۶۳	۰/۰۲۴
SPI ۴۸ ماهه	پیشخور عمومی	مومنتوم	۰/۷۶	۰/۰۳۸	۰/۰۱۴
PDSI	پرسپترون	مومنتوم	۰/۷۶۳	۰/۰۳۵	۰/۰۲۴

جدول ۷- پیش بینی سری زمانی SPI برای سه ماه آینده

نمایه	شبکه	الگوریتم	R ²	RMSE	MAE
SPI ۱۲ ماهه	پیشخور عمومی	مومنتوم	۰/۵	۰/۰۷۱	۰/۰۳۶
SPI ۱۸ ماهه	پیشخور عمومی	گرادیان نزولی	۰/۵۸	۰/۰۵۹	۰/۰۳۳
SPI ۲۴ ماهه	پیشخور عمومی	گرادیان نزولی	۰/۴۲	۰/۰۷۷	۰/۰۴۲
PDSI	پرسپترون	مومنتوم	۰/۵۲	۰/۰۵۲	۰/۰۳۹

آینده می باشند. همچنین نمایه PDSI نیز با $R^2=0/52$ قادر به پیش بینی PDSI برای سه ماه آینده می باشد. به طور کلی، کلیه شبکه ها از تعداد نرون کمی در تمامی لایه های خود استفاده می کنند و استفاده از معماری سبک در شبکه، یعنی تعداد نرون های کمی در لایه پنهان نتایج

بیشترین عملکرد را برای پیش بینی یک ماهه در میان SPI ها با گام های زمانی مختلف نمایه SPI ۱۸ ماهه با ضریب $R^2=0/778$ دارا می باشد. سری های زمانی SPI ۱۲ و ۱۸ ماهه با ضریب $R^2=0/585$ و $R^2=0/503$ دارای بالاترین عملکرد در پیش بینی نمایه SPI برای سه ماهه

میان دو مدل شبکه عصبی بکاررفته هر دو مدل نتایج مشابهی را نشان می دهند. در هنگام استفاده از نرم افزار Nero Solutions 5 الگوریتم مومنتوم دارای سرعت عمل بالاتری نسبت به الگوریتم گرادینان نزولی می باشد و داده های ورودی را با سرعت بالاتری از لحاظ زمانی پردازش می کرد.

خوبی را برای کلیه مدل ها ارایه کرد. با افزایش مقیاس زمانی نمایه SPI، دقت مدل افزایش می یابد. SPI های ۱، ۲، ۳ و ۶ ماهه دارای نتایج تخمین بسیار ضعیفی هستند که این مسئله به علت تغییرات شدید بارندگی در مقیاس های زمانی کم می باشد که این نتیجه با نتایج بدست آمده از تحقیقات میسرا و دسای نیز کاملاً هماهنگی دارد. در

فهرست منابع

۱. باقرزاده، ک. ۱۳۸۴. ارزیابی سیگنالهای بزرگ مقیاس جوی و پیش بینی سری های زمانی SPI و EDI در استان تهران. پایان نامه دوره کارشناسی ارشد، دانشگاه تربیت مدرس تهران.
۲. عیوضی، م، مساعدی، ا. و دهقانی، ا. ح. ۱۳۸۸. مقایسه روش های مختلف پیش بینی شاخص خشکسالی SPI. مجله پژوهش های حفاظت آب و خاک. ۱۶(۲): ۱۴۵-۱۶۷.
۳. کوره پزان دزفولی، ا. ۱۳۸۲. تأثیر سیگنال های هواشناسی در پیش بینی تغییرات بارش. پایان نامه کارشناسی ارشد، دانشگاه امیرکبیر.
۴. ناظم السادات، س. م. ج. ۱۳۷۹. خشکسالی و بارندگی مازاد پاییزه استان های فارس و خوزستان و ارتباط آن با پدیده النینو- نوسانات جنوبی. مجله تخصصی بررسی مسائل خشکسالی استان فارس. ۱۵-۲۶.
5. Allen, D., Schuurman, N., and Zhang, Q. 2007. Using fuzzy logic for modeling aquifer architecture. *Journal Geograph System*, 9:289-310.
6. Bierkens, M.F.P. 1998. Modeling water table fluctuations by means of a stochastic differential equation. *Water Resour*, 34(10): 2485-2499.
7. Gables, C. 2006. The Impacts of ENSO, PDO, and Local SSTs on Winter Precipitation in India. Department of Geography and Regional Studies University of Miami, Florida 33124.
8. Joorabian, M., and Hooshmand, R. 2003. Fuzzy logic and neural networks. Shahid Chamran University, Ahvaz. Iran.
9. Maier, H.R., and Dandy, G.C. 2000. Neural networks for the prediction and forecasting of water resources variables: a review of modeling issues and applications. *Environmental Modeling and Software*, 15:101-124.
10. Mehdizadeh, M. 1383. Neural network and its application in civil engineering. Ebadi publications.
11. Mishra, A., and Desai, K. 2006. Drought forecasting using feed-forward recursive neural network. *Ecological Modeling*, 198:127-138.
12. Morid, S., Smakhtin, V., and Bagherzadeh, K. 2007. Drought forecasting using artificial neural networks and time series of drought indices. *International Journal of Climatology*, 27(15): 2103-2111.
13. Nazemosadat, M.J., and Cordery, I. 2000. On the relationship between ENSO and autumn rainfall in Iran. *Journal of Climatology*, 1: 47-62.
14. Vasiliades, L., and A. Loukas. 2006. Artificial Neural Network Spatiotemporal Drought Interpolation. *Geophysical Research Abstracts* 8:04491.