

پیش‌بینی بارش ماهانه با استفاده از شاخص‌های اقلیمی پیوند از دور با استفاده از شبکه عصبی مصنوعی و مدل آماری (مطالعه موردی: ایستگاه‌های هم‌جوار ششده و قره‌بلاغ)

سید جواد ساداتی‌نژاد^{۱*}، محمدرضا شکاری^۲، عباسعلی ولی^۳

۱. دانشیار دانشکده علوم و فنون نوین، دانشگاه تهران

۲. دانشجوی دکتری بیابان‌زدایی، دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان

۳. دانشیار دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان

(تاریخ دریافت ۱۳۹۵/۰۵/۰۶؛ تاریخ تصویب ۱۳۹۵/۰۹/۰۵)

چکیده

بسیاری از متغیرهای هواشناسی از جمله بارش به شدت به گردش‌های جوی-اقیانوسی بزرگ مقیاس وابسته‌اند. در پژوهش حاضر تأثیر سیگنال‌های اقلیمی بر میانگین بارش ماهانه ایستگاه‌های مجاور مناطق ششده و قره‌بلاغ طی دوره آماری ۲۵ ساله از ۱۳۶۴ تا ۱۳۸۸ بررسی شده است. شبیه‌سازی بارش با استفاده از مدل‌های آماری و شبکه عصبی انجام شده است. همبستگی سیگنال‌های اقلیمی با بارش در حالت‌های مختلف بدون تأخیر و با تأخیرهای ۳، ۶، ۹، ۱۲ ماهه ارزیابی شد. مهم‌ترین شاخص‌ها از بین ۲۰ شاخص اقلیمی، شاخص‌های NINO1.2، NINO3 و WHWP به ترتیب با ضریب همبستگی ۶۱، ۴۵ و ۳۳ درصد در سطح احتمال ۹۵ درصد انتخاب شدند. نتایج نشان داد بیشترین همبستگی شاخص‌های اقلیمی با بارش تأخیری ۶ ماهه دارد. نتایج شبیه‌سازی مدل‌ها نشان داد شبکه عصبی مصنوعی دقت بیشتری نسبت به مدل آماری دارد. این مدل قادر است میزان بارش را با توجه به نوسانات شاخص‌های انتخابی با ضریب همبستگی ۶۶ درصد و ریشه میانگین مربعات خطای (RMSE) ۱/۳۸ شبیه‌سازی کند. در نهایت، پیش‌بینی با ضریب تبیین ۴۴ درصد به مدت ۵ سال توسط شبکه عصبی مصنوعی انجام پذیرفت. بنابراین، با توجه به اهمیت بارش و بحران جدی آب در منطقه، به منظور مدیریت منابع آب، شناخت پارامترهای مؤثر بر بارش و پیش‌بینی بلندمدت آن لازم و ضروری است.

کلیدواژگان: بارش ماهانه، تحلیل همبستگی پیرسون، شاخص‌های اقلیمی، شبکه عصبی مصنوعی، مدل آماری.

مقدمه

بارش، از الگوهای پیوند از دور اقلیمی، شامل فشار و دما در سطح آزاد دریاها و روش شبکه عصبی مصنوعی به همراه الگوریتم ژنتیک^{۱۳} برای به دست آوردن پارامترهای بهینه استفاده کرده‌اند. سیلورمن^{۱۴} و همکارانش [۸] پیش‌بینی بلندمدت بارش در کالیفرنیا^{۱۵} را با استفاده از شبکه عصبی مصنوعی انجام دادند. نتایج نشان داد امکان پیش‌بینی بارش با یک سال تأخیر شاخص‌های دور پیوندی و انسو در منطقه وجود دارد. اسمیت^{۱۶} و همکارانش [۹] تأثیر ENSO بر الگوهای بارش فصلی در فلوریدا را بررسی کردند. نتایج بررسی نشان داد بیشترین اثرگذاری ال‌نینو و لاینو در فصل زمستان و بخش‌های شمال و جنوب فلوریداست. زوهان لای^{۱۷} و همکارانش [۱۰] در تحقیقی به رابطه بین بارش‌های مرکزی چین^{۱۸} RCC در نخستین پاییز و شاخص NAO فصل تابستان پرداختند. نتایج این مطالعه نشان داده است همبستگی مثبت بین RCC در پاییز و شاخص NAO در تابستان قبل وجود دارد. بنابراین، می‌توان از آن به‌عنوان فاکتوری برای پیش‌بینی بارش پاییزه استفاده کرد. سورش^{۱۹} و همکارانش [۱۱] به مطالعه تأثیر شاخص ENSO SST, SSP^{۲۰} بر شبیه‌سازی بارش ایستگاه‌های باران‌سنجی در یک سیستم هیدرولوژیکی پرداختند. نتایج این تحقیق نشان داد شبیه‌سازی با در نظر گرفتن SST, SSP نتایج مناسب‌تری ارائه می‌دهد و تجزیه و تحلیل بارش فصل زمستان در درجه اول به یک سیگنال قوی ENSO متمرکز بود. هدف پژوهش، ابتدا بهره‌گیری از الگوهای پیوند از دور اقلیمی و انتخاب مناسب‌ترین شاخص‌های تأثیرگذار از بین ۲۰ شاخص توسط رگرسیون گام‌به‌گام و در گام بعد، پیش‌بینی بارش براساس داده‌های پیوند از دور ۶ ماه قبل با استفاده از مدل رگرسیونی و شبکه عصبی است. سپس نتایج شبیه‌سازی و مشاهداتی مقایسه شدند و در نهایت میزان بارش برای ۵ سال پیش‌بینی شده است.

سیگنال‌های هواشناسی که بر اثر تغییرات میدان‌های فشار در مناطق مختلف زمین شناخته شده‌اند، می‌توانند با تغییر توزیع فشار در سطح زمین، الگوهای بارش و دمای سطح زمین را تعیین کنند [۱]. در این زمینه نوسانات بارش ناشی از الگوهای پیوند از دور اهمیت فراوانی دارند. حجازی‌زاده و همکارانش [۲] تأثیر سیگنال‌های اقلیمی NAO^۱, SOI^۲, ENSO^۳, AO^۴ بر بارش ناحیه مرکزی ایران را مطالعه کردند و به این نتیجه رسیدند که شاخص‌های اقلیمی NINO3^۶, NINO1.2^۵ با تأخیر ۳ و ۶ ماهه بر بارش ناحیه مرکزی ایران مؤثرترین شاخص‌ها بودند. علیزاده و همکارانش [۳] تأثیر الگوهای پیوند از دور مؤثر بر پدیده‌های بارش و دمای متوسط ایستگاه سینوپتیک مشهد را توسط مدل‌های رگرسیونی شبیه‌سازی کردند. نتایج نشان داد کارایی این مدل برای شبیه‌سازی و پیش‌بینی ماهانه بیشتر از فصلی است و همچنین مؤثرترین شاخص NINO1.2 انتخاب شد. خورشیددوست و همکارانش [۴] نوسانات بارش فصلی ایستگاه سینوپتیک اهر در ارتباط با الگوهای پیوند از دور را بررسی کردند. نتایج تحقیق بیان می‌کند که رابطه بارش‌های پاییزی با الگوی جو-اقیانوسی (شاخص نوسان جنوبی موسوم به انسو) در فاز گرم یا ال‌نینو موجب افزایش بارش و در فاز سرد یا لاینو موجب خشکسالی می‌شود. ایسری^۷ و همکارانش [۵] پیش‌بینی میان‌مدت بارش در فوکوکای ژاپن را با استفاده از شبکه عصبی مصنوعی مطالعه کردند. ورودی‌ها در این تحقیق شاخص‌های اقلیمی NPI^۸, PDO, SOI^۹ بودند. نتایج نشان داد مدل شبکه عصبی نتایج دقیقی دارد. اموگبای^{۱۰} [۶] بارندگی شمال نیجریه براساس داده‌های دمای سطح دریا^{۱۱} را با روش رگرسیون پیش‌بینی کرده است. ناگش کومار^{۱۲} و همکارانش [۷] برای پیش‌بینی

13. Genetic Algorithm
14. Silverman
15. California
16. Schmidt
17. XU Han-Lie
18. Rainfall Central China
19. Suresh
20. Sea Surface Pressure (SSP)

1. North Atlantic Oscillation
2. Southern Oscillation Index
3. El-Nino/Southern oscillation
4. Antarctic Oscillation.
5. Extreme Eastern Tropical Pacific SST
6. Eastern Tropical Pacific SST
7. Iseri
8. North Pacific Index
9. Pacific Decadal Oscillation
10. Omogbai
11. Sea Surface Temperature (SST)
12. Nagesh Kumar

مواد و روش‌ها

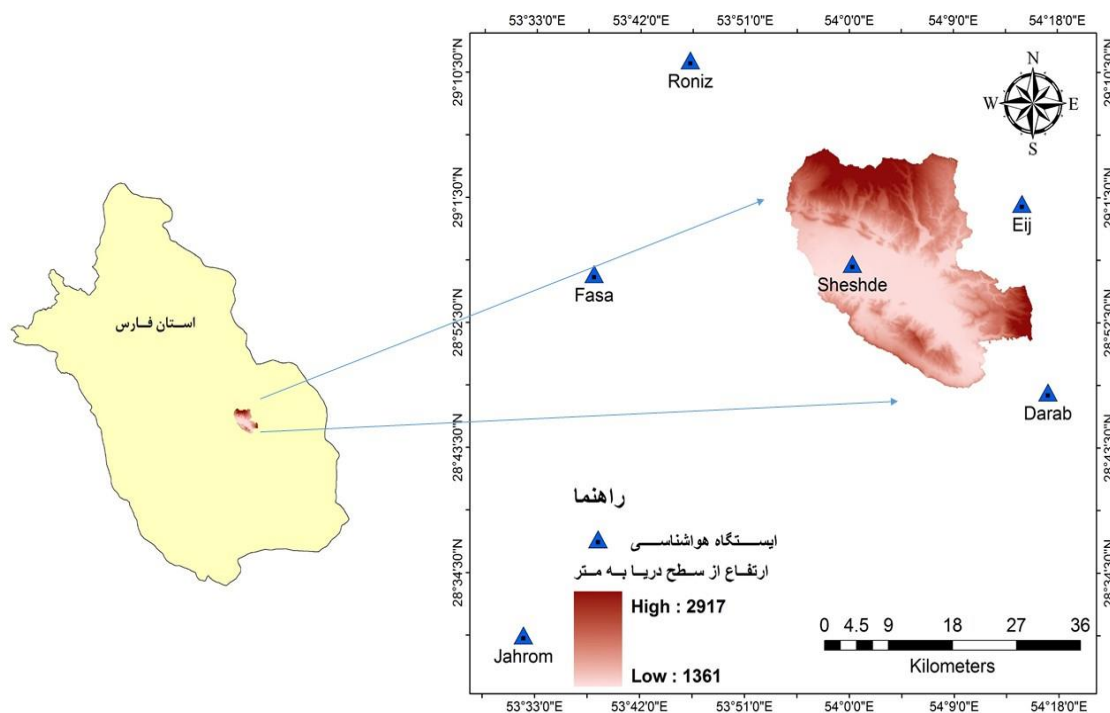
داده‌های تحقیق

برای انجام این تحقیق از داده‌های ماهانه بارش ایستگاه‌های مجاور مناطق ششده و قره‌بلاغ واقع در بخش شرقی استان فارس شامل ایستگاه‌های سینوپتیک و باران‌سنجی ششده، ایچ، فسا، داراب، رونیز استهبان، جهرم استفاده شده است. از بین ۶ ایستگاه، ۳ ایستگاه فسا، داراب و جهرم سینوپتیک و باقی باران‌سنجی هستند. شکل ۱ موقعیت مکانی ایستگاه‌ها و منطقه مطالعاتی در استان فارس را نشان می‌دهد. داده‌های مختص به بارش از سازمان هواشناسی برای دوره زمانی ۲۵ ساله از ۱۳۶۴ تا ۱۳۸۸ میلادی دریافت شده است. به طور کلی، حدود ۳۶ الگو و شاخص اقلیمی در جهان مطالعه و شناسایی شده‌اند که ۱۳ مورد از آنها، در نیم‌کره شمالی شناخته شده است. تأثیر بعضی از آنها سیاره‌ای است، مانند ال‌نینو و انسو. برخی دیگر مانند NAO بعد نیم‌کره‌ای و بعضی مانند MOI و WeMOI، قلمروی منطقه‌ای دارند.

این شاخص‌ها بیشتر با استفاده از نمایه‌هایی که براساس فشار هوا و دمای سطح آب اقیانوس‌ها محاسبه می‌شوند، به صورت کمی بیان می‌شوند. در مجموع، ۲۰ شاخص اقلیمی در این تحقیق استفاده شده است. اطلاعات این سیگنال‌های اقلیمی بهره‌برداری شده در پژوهش از وبسایت نوا^۱ در شبکه‌هایی با توان تفکیک‌پذیری ۲/۵ * ۲/۵ درجه در فاصله سال‌های ۱۳۶۴ تا ۱۳۹۳ اخذ شده است که لیست این شاخص‌های اقلیمی در جدول ۱ آورده شده است.

روش

در این پژوهش برای شبیه‌سازی و پیش‌بینی داده‌های بارش از دو مدل رگرسیونی (آماری) و شبکه عصبی توسط نرم‌افزار SPSS^۲ بهره‌گیری شده است. برای انجام آنالیز دقیق داده‌ها به دلیل زیادبودن سیگنال‌های اقلیمی ابتدا از روش رگرسیون گام‌به‌گام^۳ به منظور انتخاب داده‌های اثرگذارتر بر بارش استفاده شده است.



شکل ۱. منطقه مطالعه شده و موقعیت ایستگاه‌های هواشناسی در استان فارس

1. NOAA
2. Statistical Package for the Social Science
3. Stepwise Regression

جدول ۱. لیست شاخص‌های پیوند از دور استفاده شده

نام مختصر	نام کامل شاخص اقلیمی	معادل فارسی
EPO	Eastern Pacific Oscillation	نوسانات آرام شرقی
NAO	North Atlantic Oscillation	نوسانات اطلس شمالی
WPI	Western Pacific Index	شاخص آرام غربی
SOI	Southern Oscillation Index	شاخص نوسانات جنوبی
QBO	Quasi-Biennial Oscillation	نوسانات شبه دوسالانه
MEI	Multivariate ENSO Index	شاخص انسوی چندمتغیره
NINO 1,2	Extreme Eastern Tropical Pacific SST	شاخص دمای سطحی شدید بخش شرقی اقیانوس آرام استوایی
NINO 3	Eastern Tropical Pacific SST	شاخص دمای سطحی بخش شرقی اقیانوس آرام استوایی
NINO 3,4	East Central Tropical Pacific SST	شاخص دمای سطحی بخش مرکزی شرقی اقیانوس آرام استوایی
NINO 4	Central Tropical Pacific SST	شاخص دمای سطحی بخش مرکزی اقیانوس آرام استوایی
BEST	Bivariate ENSO Time Series	سری زمانی انسوی دومتغیره
TNI	Trans-Niño Index	شاخص تغییر یافته نینوی اقیانوس آرام
TSA	Tropical Southern Atlantic Index	شاخص اطلس جنوبی حاره‌ای
AMO	Atlantic Multidecadal Oscillation	نوسانات چنددهه‌ای اطلس
PDO	Pacific Decadal Oscillation	نوسانات دهه‌ای اقیانوس آرام
AMM	Atlantic Meridional Mode	مد اطلس نصف‌النهار
EA	Eastern Asia	شاخص آسیای شرقی
IOD	Indian Ocean Dipole	شاخص دو قطبی اقیانوس هند
WHWP	Western Hemisphere Warm Pool	استخر گرم نیم‌کره جنوبی
ONI	Oceanic Niño Index	شاخص نینوی اقیانوسی

روش رگرسیونی یا آماری

در روش رگرسیونی چندمتغیره گام به گام در هر گام، متغیر مستقلی (ابتدا فقط مقدار ثابت یا عرض از مبدأ) به مدل اضافه می‌شود به طوری که برای هر مدل رگرسیونی، مقدار آماره f محاسبه شده و هر متغیر مستقلی که f بزرگ‌تری داشته باشد، برای افزوده شدن به مدل کاندید می‌شود. چنانچه F مختص به این متغیر مستقل کاندید شده از $F_{\alpha}(1, n-2)$ بزرگ‌تر باشد، آن گاه متغیر مستقل مختص به آن را به مدل می‌افزاییم، در غیر این صورت افزودن این متغیر به مدل چندان مفید نخواهد بود. سپس چندین مرحله افزودن و یا حذف متغیرهای مستقل براساس محاسبات بر مبنای F انجام می‌شود [۱۲]. مدل رگرسیون چندگانه به کاررفته در این پژوهش به صورت مدل خطی است که در رابطه ۱ نشان داده شده است:

$$y = b_0 + b_1x_1 + b_2x_2 + b_3x_3 + b_4x_4 + \dots + b_nx_n \quad (1)$$

که هر یک از پارامترها عبارت‌اند از:

$$b_0 = \text{ضریب ثابت مدل}$$

$$b_1, b_2, b_3, b_4, \dots, b_n = \text{ضرایب مدل}$$


$$x_1, x_2, x_3, x_4, \dots, x_n = \text{متغیرهای مدل}$$

با توجه به تعداد زیاد داده‌های شاخص اقلیمی در این تحقیق برای جلوگیری از فرابرازش مدل از روش گام به گام برای انتخاب شاخص‌های پیوند از دور مؤثر استفاده شده است. از آنجا که مقادیر سیگنال‌های اقلیمی استاندارد شده است، مقادیر بارش نیز بعد از محاسبه لگاریتم^۱ وارد نرم‌افزار SPSS شده است. همچنین ارتباط شاخص‌های پیوند از دور و بارش با تأخیرهای ۳، ۶، ۹، ۱۲ و بدون تأخیر بررسی و تحقیق شده است.


روش شبکه عصبی مصنوعی ANNs

شبکه عصبی مصنوعی در واقع، مدل ساده شده‌ای از مغز انسان است که توانایی رخ دادن فرایندها و ترکیبات دلخواه غیر خطی برای ارتباط بین ورودی و خروجی‌های هر سیستمی را داراست؛ در ضمن این شبکه با داده‌های موجود طی فرایند یادگیری، آموزش داده می‌شود و به منظور پیش‌بینی در آینده استفاده می‌شود. نورون‌های شبکه عصبی در حقیقت، شکل بسیار ساده از نورون‌های بیولوژیک هستند، ولی توانایی کمتری نسبت به آنها دارند (شکل‌های ۲ و ۳).

1. Logarithm



شکل ۲. ساختار یک نورون مصنوعی



شکل ۳. ساختار یک نورون طبیعی (بیولوژیک)

ورودی، لایه پنهان و لایه خروجی تشکیل شده است. برای معماری شبکه تعدادی نورون در هر لایه در نظر گرفته می‌شود. تعداد نورون‌های لایه ورودی و خروجی بسته به ماهیت مسئله و تعداد نورون لایه پنهان با سعی و خطا در جهت کاهش مقدار خطا توسط طراح مشخص می‌شود [۱۵].

مراحل طراحی و پیاده‌سازی شبکه عصبی به شرح زیر است:

۱. جمع‌آوری و پیش‌پردازش داده‌های مورد نیاز برای شبکه عصبی مد نظر؛
۲. تعیین نوع و ساختار مناسب برای شبکه عصبی و ایجاد شبکه کارآمد؛
۳. آموزش دادن شبکه با قسمتی از داده‌های جمع‌آوری شده (مرحله آموزش)؛
۴. آزمایش شبکه آموزش داده شده با باقی‌مانده داده‌ها (مرحله آزمون)؛
۵. در صورت قابل قبول بودن نتیجه آزمون، ذخیره شبکه و در غیر این صورت، تکرار مرحله ۲ تا ۴.

یکی از دلایل انتخاب شبکه‌های عصبی در تحقیق حاضر این است که این شبکه‌ها، قدرت انعطاف و تصحیح‌پذیری زیادی در انطباق خود با داده‌ها را دارند و می‌توانند براساس بردارهای ورودی، رخداد و بزرگی یک پدیده را پیش‌بینی کنند [۱۳]. همچنین با تکیه بر داده‌ها و برقراری اوزان مختلف به ارتباطات عصبی در جریان فرایند یادگیری قادر است جواب‌گوی مسائل مبهم و پیچیده باشد. انتخاب نوع شبکه نیز به ماهیت مسئله بررسی شده و نوع داده‌های آن وابسته است. شبکه‌های پرسپترون چندلایه^۱ MLP با قابلیت آموزش و یادگیری زیاد به دلیل برگشت‌پذیری و انعطاف زیاد به‌منظور برآورد عناصر جوی در تحقیقات گذشته توصیه شده است [۱۴]. در این تحقیق از روش شبکه عصبی پرسپترون چندلایه برای مدل‌سازی و پیش‌بینی با استفاده از جعبه ابزار شبکه عصبی مصنوعی نرم‌افزار SPSS استفاده شده است. معمولاً الگوریتم آموزشی این شبکه‌ها پس‌انتشار خطا^۲ است. بیشتر ساختار یک شبکه عصبی، از سه لایه شامل لایه

1. Multi Layer Perceptron
2. Back Propagation Error

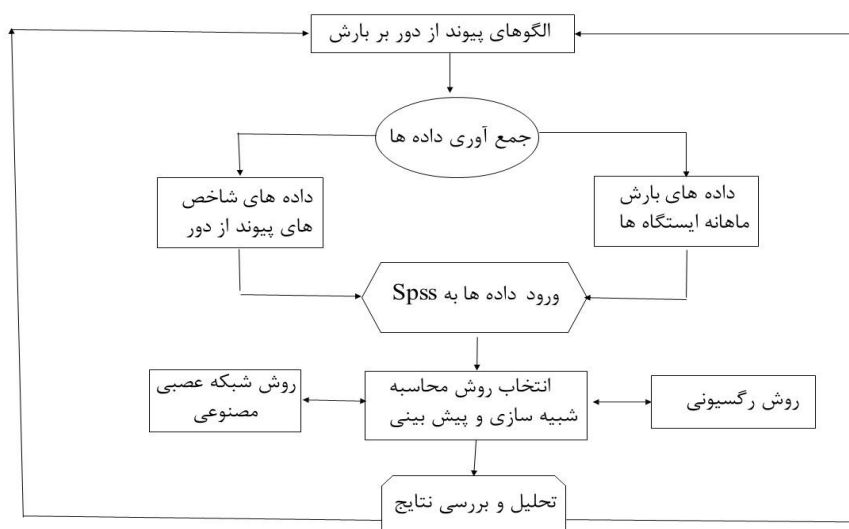
که در روابط ۲ و ۳، O_i مقادیر مشاهده‌ای و E_i مقادیر پیش‌بینی شده است. زیادبودن ضریب همبستگی و کمبودن میزان خطا در هر مدل، نشان‌دهنده عملکرد بهتر آن است. پیاده‌سازی مراحل انجام تحقیق شامل مراحل زیر است که در شکل ۴ آورده شده است:

معیارهای ارزیابی عملکرد مدل‌ها

به‌منظور ارزیابی عملکرد مدل‌ها، از معیارهای ریشه میانگین مربعات خطا (RMSE) و ضریب تبیین R^2 استفاده شده است که فرمول آنها به‌ترتیب به‌صورت روابط زیر است:

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

$$R = 1 - \frac{\sum_{i=1}^n |O_i - E_i|^2}{\sum_{i=1}^n |O_i|^2} \quad (3)$$



شکل ۴. مدل مفهومی روش تحقیق (ترسیم نگارنده)

تأخیر و با تأخیر زمانی از ۳، ۶، ۹، ۱۲ ماه بررسی شده و نتایج آنها در جدول ۲ آمده است. در این پژوهش، شاخص‌هایی که میزان ضریب همبستگی آنان در سطح اطمینان ۵ درصد ($r \geq 0.30$) از لحاظ آماری معنادار بودند، در مدل پیش بهره‌گیری شدند.

نتایج همبستگی پیرسون در جدول ۲ نشان می‌دهد در تمام تأخیرهای مختلف در نظر گرفته‌شده، در تأخیر ۶ ماهه بیشترین میزان همبستگی بین بارش و شاخص‌های پیوند از دور وجود دارد؛ بدین‌معنا که شاخص‌های پیوند از دور با تأخیری ۶ ماهه روی بارش اثر گذاشته‌اند. شاخص‌های ENSO در منطقه NINO1.2، NINO3 و شاخص WHWP دارای بیشترین رابطه معناداری با بارش هستند. کمترین میزان معناداری نیز مختص به شاخص‌های AMM، TSA است. همان‌طور که جدول ۳ ضرایب رگرسیونی مدل آماری را نشان می‌دهد در مدل

یافته‌ها

بررسی رابطه الگوهای پیوند از دور با بارش ماهیانه

برای پیش‌پردازش داده‌های عناصر اقلیمی ورودی به شبکه عصبی و پیش‌بینی بارش از روش رگرسیونی گام‌به‌گام استفاده شده است. نتایج تحلیل رگرسیونی ارتباط الگوهای پیوند از دور با بارش نشان داد از بین ۲۰ الگوی پیوند از دور، ۸ شاخص NINO4^۴، NINO3.4^۳، NINO3^۳، NINO1.2^۴، AMO^۷، AMM^۶، WHWP^۸ معنادار تشخیص داده شدند. سپس در گام بعدی میزان تحلیل همبستگی پیرسون این شاخص‌های انتخابی با بارش تحت شرایط مختلف بدون

1. Root Mean Square Error
2. Coefficient of determination (R²)
3. East Central Tropical Pacific SST
4. Central Tropical Pacific SST
5. Western Hemisphere WarmPool
6. Atlantic Meridional Mode
7. Atlantic Multidecadal Oscillation
8. Tropical Southern Atlantic Index

مبدأ، WHWP، NINO3، NINO 1.2 به‌عنوان متغیرهای مدل و اعداد قبل از متغیرهای مدل به‌عنوان ضرایب متغیرهاست. به‌منظور پاسخ‌گویی به این سؤال که آیا می‌توان از این پارامترها برای پیش‌بینی میزان بارش منطقه استفاده کرد یا خیر، باید معنادار بودن ضرایب رگرسیونی نیز آنالیز شود. با توجه به اطلاعات جدول ۴ آنالیز رگرسیونی و آزمون معنادار بودن رگرسیون، فرض صفر برای شاخص‌های مد نظر در سطح احتمال ۹۵ درصد رد می‌شود. به‌دلیل اینکه سطح معناداری آماره F کمتر از ۰/۰۵ است. چنین نتیجه‌گیری می‌شود که بین بارش و الگوهای پیوند از دور ارتباط معناداری وجود دارد و متغیرهای اقلیمی به‌خوبی تغییر در بارش را تبیین می‌کنند.

نهایی (رابطه ۳)، تأثیر شاخص NINO1.2 ۶۷ درصد و NINO3 ۵۴ درصد و تأثیر شاخص WHWP ۱۲ درصد است، بنابراین ضریب رگرسیونی بزرگ‌تر شاخص NINO1.2 بیانگر آن است که نقش عمده و تعیین‌کننده شاخص یادشده در پیش‌بینی بارش نسبت به دو شاخص دیگر اهمیت بیشتری دارد (جدول ۳).

معادله پیش‌بینی بارش توسط مدل آماری با استفاده از شاخص‌های مؤثر NINO 1.2، NINO3، WHWP با سطح اطمینان ۹۵ درصد به‌صورت رابطه ۴ استخراج شده است:

$$y = 3/095 - 0/67NINO1/2 - 0/54NINO3 + 0/12WHWP \quad (4)$$

در رابطه ۴ که رگرسیونی چندمتغیره است Y میزان بارش قابل پیش‌بینی، ۳/۰۹۵ ضریب ثابت یا عرض از

جدول ۲. تحلیل همبستگی الگوهای پیوند از دور با بارش در شرایط بدون تأخیر و با تأخیر زمانی

TSA	AMO	AMM	WHWP	NINO4	NINO ۳/۴	NINO3	NINO ۱/۲		
۰/۰۱۷	-۰/۲۰**	-۰/۰۸۸	-۰/۲۲**	-۰/۱۴**	-۰/۰۰۴	۰/۲۴**	۰/۴۷**	ضریب همبستگی	بدون تأخیر
۰/۷۴۰	۰/۰۰۰	۰/۰۹۶	۰/۰۰۰	۰/۰۰۰	۰/۹۴	۰/۰۰۰	۰/۰۰۰	سطح معناداری	
-۰/۱۲*	-۰/۱۱**	۰/۱۹**	-۰/۰۱۵	۰/۰۶۵	-۰/۲۱**	-۰/۴۰**	-۰/۳۲**	ضریب همبستگی	تأخیر ۳
۰/۰۱۶	۰/۰۲۹	۰/۰۰۰	۰/۷۷	۰/۲۲	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	سطح معناداری	ماهه
-۰/۱۳*	۰/۱۷**	-۰/۰۰۵	۰/۳۳**	۰/۲۹**	۰/۰۵	-۰/۴۵**	-۰/۶۱**	ضریب همبستگی	تأخیر ۶
۰/۰۱۴	۰/۰۰۷	۰/۹۳	۰/۰۰۰	۰/۰۰۰	۰/۳۴	۰/۰۰۰	۰/۰۰۰	سطح معناداری	ماهه
۰/۰۲۹	-۰/۰۳۹	-۰/۲۹**	-۰/۰۸۵	۰/۰۸۹	۰/۳۱**	۰/۴۰**	۰/۲۷**	ضریب همبستگی	تأخیر ۹
۰/۵۹	۰/۴۶	۰/۰۰۰	۰/۱۱	۰/۰۹۴	۰/۰۰۰	۰/۰۰۰	۰/۰۰۰	سطح معناداری	ماهه
۰/۰۷۴	-۰/۲۰**	-۰/۰۹۷	-۰/۲۵**	-۰/۲۳**	-۰/۰۵۳	۰/۲۲**	۰/۴۹**	ضریب همبستگی	تأخیر
۰/۱۶	۰/۰۰۰	۰/۰۷۲	۰/۰۰۰	۰/۰۰۰	۰/۳۲	۰/۰۰۰	۰/۰۰۰	سطح معناداری	۱۲ ماهه

** سطح معناداری در یک درصد * سطح معناداری در پنج درصد


جدول ۳. ضرایب رگرسیونی مدل‌های آماری

مدل	ضرایب استاندارد نشده	Std.Error	ضرایب استاندارد شده	t	سطح معناداری
۱	ضریب ثابت	۱۱,۹۹۳	-	۱۳,۶۴۳	۰/۰۰۰
	NINO1.2	-۰/۴۴۳	-۰/۵۳۲	-۱۱,۷۸۸	۰/۰۰۰
۲	ضریب ثابت	۱,۶۶۸	-	۰/۹۲۰	۰/۰۳۸
	NINO1.2	-۰/۷۳۱	-۰/۸۷۷	-۱۲,۷۵۷	۰/۰۰۰
	NINO3	-۰/۶۵۵	۰/۴۴۰	۶,۴۰۷	۰/۰۰۰
۳	ضریب ثابت	۳,۰۹۵	-	۱,۶۵۷	۰/۰۵۰
	NINO1.2	-۰/۶۷۶	-۰/۸۱۱	-۱۱,۲۵۵	۰/۰۰۰
	NINO3	-۰/۵۴۷	۰/۳۶۸	۵,۰۴۲	۰/۰۰۰
	WHWP	۰/۱۲۰	۰/۱۲۷	۲,۷۹۱	۰/۰۰۳


جدول ۴. آنالیز مدل رگرسیونی

سطح معناداری	آماره F	میانگین مربعات خطا	درجه آزادی	مجموع مربعات خطا	رگرسیون
.۰۰۰	۱۳۸/۹۶۶	۳۴۹/۰۰۷	۱	۳۴۹/۰۰۷	رگرسیون
		۲/۵۱۱	۳۵۲	۸۸۴/۰۳۵	مانده‌ها
			۳۵۳	۱۲۳۳/۰۴۲	کل
.۰۰۰	۹۷/۹۱۶	۲۲۰/۷۸۹	۲	۴۴۱/۵۷۹	رگرسیون
		۲/۲۵۵	۳۵۱	۷۹۱/۴۶۳	مانده‌ها
			۳۵۳	۱۲۳۳/۰۴۲	کل
.۰۰۰	۶۹/۱۳۶	۱۵۲/۹۳۶	۳	۴۵۸/۸۰۷	رگرسیون
		۲/۲۱۲	۳۵۰	۷۷۴/۲۳۵	مانده‌ها
			۳۵۳	۱۲۳۳/۰۴۲	کل

نمودار مانده‌ها در مقابل برازش شده‌ها



نمودار احتمال نرمال مانده‌ها



شکل ۵. نمودار احتمال نرمال مانده‌ها و نمودار مانده‌ها در مقابل برازش شده

جدول ۵. ضرایب رگرسیونی در رگرسیون گام‌به‌گام


مدل	ضریب همبستگی	ضریب تبیین	ضریب تبیین تعدیل شده	خطای برآورد استاندارد
۱	۰/۵۲	۰/۲۷	۰/۲۷	۱/۶۱
۲	۰/۵۸	۰/۳۴	۰/۳۴	۱/۵۴
۳	۰/۶۰	۰/۳۷	۰/۳۵	۱/۴۶

نتایج انتخاب نهایی متغیرهای مدل تبیین شده است. مشخصات ارزشیابی مدل نهایی شده به کمک آماره‌های ضریب همبستگی، ضریب تبیین، ضریب تبیین تعدیل شده و مجذور میانگین مربعات خطا گزارش شده است. در نهایت، از بین کلیه مدل‌های ارائه شده در مدل ۳ ضریب همبستگی خطی وجود رابطه‌ای نسبتاً قوی را نشان می‌دهد. نتایج مختص به ضریب همبستگی و ضریب تبیین در مدل‌های به دست آمده در جدول ۵ نشان داده شده است.


همچنین نمودار احتمال نرمال مانده‌ها و نمودار مانده‌ها در مقابل مقادیر برازش شده در شکل ۵ رسم شده است. این نمودارها، انحرافی از فرض‌های مدل نشان نمی‌دهند، بنابراین استنتاج‌هایی معتبر هستند که از طریق مدل صورت می‌گیرند. از آنجا که جدول آنالیز رگرسیونی یک آزمون سودمند از توانایی مدل در توضیح تأثیر هر متغیر در متغیر وابسته است، به طور مستقیم به شدت رابطه توجه ندارد. جدول خلاصه مدل شدت رابطه بین مدل‌ها را گزارش می‌کند. در جدول ۵

الگوهای پیوند از دور را تعیین کند. بهترین رابطه برای بارش داده‌های شبیه‌سازی و پیش‌بینی معادله پلی‌نومینال درجه دوم است (شکل ۷). همچنین از سال ۱۳۸۸ تا ۱۳۹۳ به مدت ۵ سال، ۲۰ درصد دوره آماری برای پیش‌بینی بارش استفاده شد. شکل ۶ داده‌های بارش شبیه‌سازی و پیش‌بینی‌شده و مشاهده‌ای توسط مدل آماری را نشان می‌دهد.

شبیه‌سازی و پیش‌بینی بارش با استفاده از مدل رگرسیونی شبیه‌سازی بارش با استفاده از مدل آماری از سال ۱۳۶۴ تا ۱۳۸۸ نشان می‌دهد این مدل می‌تواند میزان بارش را با ضریب همبستگی ۶۰ درصد (که این ضریب همبستگی در سطح اطمینان یک درصد معنادار است) و ضریب تبیین ۳۷ درصد شبیه‌سازی و پیش‌بینی کند. به‌بیانی مدل آماری می‌تواند ۳۷ درصد از کل تغییرات بارش توسط



شکل ۶. داده‌های بارش شبیه‌سازی و پیش‌بینی‌شده توسط مدل آماری با تأخیر ۶ ماهه



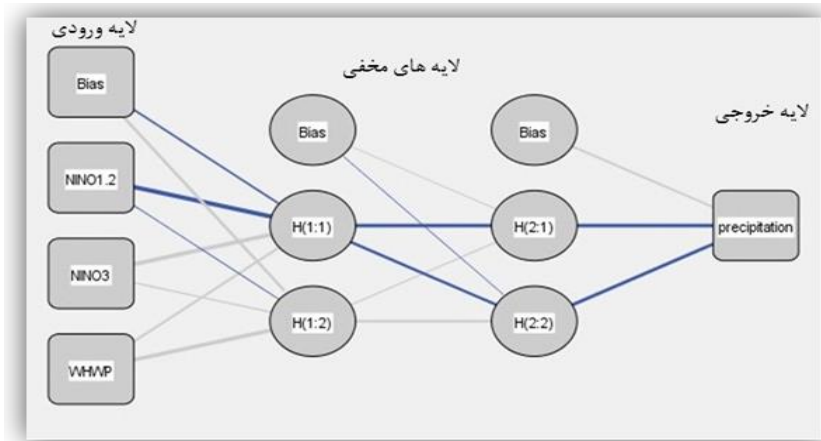
شکل ۷. نمودار پراکنش داده‌های بارش شبیه‌سازی و پیش‌بینی‌شده توسط مدل آماری

میانگین مربعات خطا و ضریب همبستگی هستند. معماری شبکه عصبی شامل یک لایه ورودی که همان ۳ شاخص‌های اقلیمی مؤثر در نظر گرفته شده با ۶ ماه تأخیر هستند. دو لایه میانی یا مخفی که در هر لایه دو نورون وجود دارد و یک لایه خروجی که همان مقدار بارش پیش‌بینی‌شده است. تابع فعال‌ساز برای لایه میانی یا لایه مخفی تانژانت هایپر بولیک و تابع فعال‌ساز لایه خروجی تابع سیگموئید است. ساختار شبکه عصبی مصنوعی طراحی شده در این پژوهش در شکل ۸ نشان داده شده است.

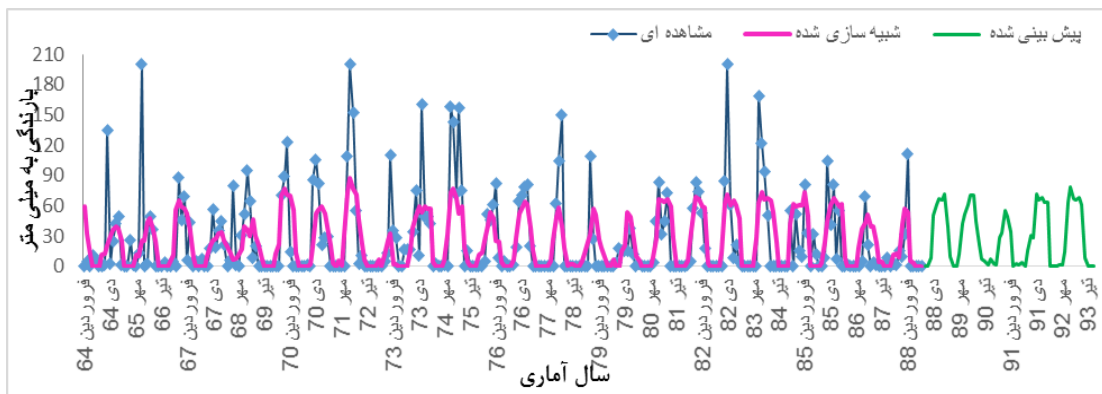
شبیه‌سازی و پیش‌بینی بارش با استفاده از مدل شبکه عصبی مصنوعی تأثیر سیگنال‌های اقلیمی انتخابی به‌علت سطح معناداری و ضرایب استاندارد شده‌ای که هریک از سیگنال‌ها در میزان بارش داشتند به‌عنوان متغیرهای مستقل توسط مدل شبکه عصبی مصنوعی MLP نیز بررسی شده است. برای آموزش و تست شبکه عصبی از بین تعداد سال‌های آماری دو سوم به‌منظور آموزش و یک سوم به‌عنوان تست شبکه در نظر گرفته شده‌اند. در این شبکه‌ها، مبنای عملکرد مدل، ریشه

شبیه‌سازی و پیش‌بینی شده با داده‌های بارش مشاهده‌ای توسط شبکه عصبی را نشان می‌دهد. در روش شبکه عصبی مصنوعی نیز بهترین رابطه‌ای که برای برآزش داده‌های مشاهداتی و پیش‌بینی شده در نظر گرفته شده است معادله پلی نومینال درجه دوم است.


شبیه‌سازی بارش با استفاده از شبکه عصبی در طول دوره آماری تحقیق نشان داد این شبکه عصبی می‌تواند میزان بارش را با همبستگی ۶۶ درصد و ضریب تبیین ۴۴ درصد شبیه‌سازی و پیش‌بینی کند. شایان یادآوری است که همبستگی بین شاخص‌های اقلیمی و بارش در سطح اطمینان یک درصد معنادار است. شکل ۹ داده‌های بارش



شکل ۸. ساختار شبکه عصبی مصنوعی طراحی شده در پژوهش



شکل ۹. داده‌های بارش شبیه‌سازی و پیش‌بینی شده توسط شبکه عصبی مصنوعی با تأخیر ۶ ماهه



شکل ۱۰. نمودار پراکنش داده‌های بارش شبیه‌سازی و پیش‌بینی شده توسط شبکه عصبی مصنوعی

شبکه عصبی مصنوعی به روش رگرسیونی به ترتیب با میزان ضرایب تبیین ۰/۶۶ و ۰/۶۰ و مقادیر خطای برآورد ۱/۳۸ و ۱/۴۶ تعیین می‌شود. در جدول ۶ ضرایب همبستگی و دقت مدل‌ها در هر دو روش گزارش شده است.

همان‌طور که در شکل‌های ۶ و ۹ مشاهده می‌شود، میزان انطباق خروجی بارش توسط شبکه عصبی در مقایسه با مدل آماری بیشتر است که این امر بیان می‌کند که شبکه عصبی کارایی مطلوب‌تری دارد. بنابراین، ارزش رجحانی روش

جدول ۶. نتایج خروجی مدل آماری و شبکه عصبی در شبیه‌سازی

نام مدل	R	R ²	Adjusted R ²	RMSE
مدل آماری	۰/۶۰	۰/۳۷	۰/۳۶	۱,۴۶
شبکه عصبی	۰/۶۶	۰/۴۴	۰/۴۳	۱,۳۸

شاخص‌های اقلیمی با بارش در شرایط تأخیر زمانی ۶ ماهه است که دو شاخص NINO1.2، NINO3 دارای همبستگی منفی و مقدار ارزش آنها به ترتیب ۶۱ درصد و ۴۵ درصد و نیز شاخص WHWP دارای همبستگی مثبت و مقدار ارزش آن ۳۳ درصد است؛ اما شاخص‌های NINO3.4، NINO4، AMO، AMM، TSA نیز در شرایط با تأخیر ۶ ماهه دارای ضریب همبستگی کمتر از ۳۰ درصد در سطح احتمال ۹۵ درصد معنادار هستند که در مدل رگرسیونی، از معادله حذف می‌شوند. شاخص‌های AMM، TSA، کمترین میزان همبستگی را در تأخیرهای مختلف از خود نشان دادند؛ بدین‌معنا که تأثیر چندانی روی بارش منطقه نخواهند داشت. با توجه به ضرایب همبستگی و سطح معناداری سیگنال‌های اقلیمی و بارش طی دوره آماری ۲۵ ساله، شاخص‌های اقلیمی NINO1.2، NINO3، WHWP برای شبیه‌سازی و پیش‌بینی بارش توسط دو مدل آماری و شبکه عصبی صورت گرفت. معماری شبکه عصبی در این پژوهش شامل یک لایه ورودی با سه نورون که در واقع همان پارامترهای ورودی هستند دو لایه میانی که در هر یک دو نورون، تابع انتقال لایه میانی، تانژانت هایپربولیک و یک لایه خروجی با تابع انتقال Identity است. ساختار طراحی شده برای شبکه عصبی مصنوعی در شکل ۶ مشاهده می‌شود. برای آموزش و تست شبکه عصبی از بین تعداد سال‌های آماری ۷۰ درصد دوره یا ۱۸ سال به‌منظور آموزش و ۳۰ درصد دوره یا ۷ سال به‌عنوان تست شبکه در نظر گرفته شد. در این شبکه‌های عصبی، مبنای عملکرد جذر میانگین مربعات خطاست. با بررسی تطابق نمودارهای شبیه‌سازی و مشاهداتی میزان بارش توسط شبکه عصبی مصنوعی MLP این نتیجه به‌دست آمد شبکه عصبی می‌تواند با میزان R² و RMSE به ترتیب برابر ۰/۴۴ و ۱/۳۸ بارش را

بحث و نتیجه‌گیری

تغییرات بسیاری از متغیرهای هواشناسی از جمله بارش به‌شدت به پارامترهای گردش جو، زمین و سطح اقیانوسی بزرگ مقیاس وابسته‌اند. بر همین اساس مطالعه نوسانات بارش به‌عنوان مهم‌ترین پارامتر هواشناسی تحت تأثیر الگوهای پیوند دور از اهمیت به‌سزایی دارد. سیگنال‌های هواشناسی که بر اثر تغییرات میدان‌های فشار در مناطق مختلف زمین شناخته شده‌اند، می‌توانند با تغییر توزیع فشار در سطح زمین، الگوهای بارش و دمای سطح زمین را تعیین کنند [۱]. پژوهش حاضر با هدف ارزیابی تأثیر سیگنال‌های اقلیمی بر متوسط بارش ایستگاه‌های مجاور مناطق مطالعاتی ششده و قره‌بلاغ انجام شد. برای انجام این تحقیق داده‌های ماهانه بارش ایستگاه‌های مجاور مناطق ششده و قره‌بلاغ از سازمان هواشناسی فارس برای دوره زمانی ۲۵ ساله از ۱۳۶۴ تا ۱۳۸۸ میلادی تهیه شده و همچنین داده‌های سیگنال‌های اقلیمی از وب‌سایت اداره ملی اقیانوس و اتمسفر ایالات متحده آمریکا دریافت شده است. در این پژوهش برای شبیه‌سازی و پیش‌بینی داده‌های بارش از دو مدل رگرسیونی و شبکه عصبی توسط نرم‌افزار SPSS بهره‌گیری شده است. برای انجام آنالیز دقیق داده‌ها به‌دلیل زیادبودن سیگنال‌های اقلیمی با استفاده از رگرسیون گام‌به‌گام به‌منظور انتخاب داده‌های اثرگذارتر انجام شد. نتایج نشان داد از ۲۰ شاخص اقلیمی استفاده‌شده، تنها ۸ شاخص NINO 1.2، NINO3، NINO3.4، NINO4، WHWP، AMM، AMO، TSA در مرحله گام‌به‌گام معنادار تشخیص داده شدند. نتایج آنالیز همبستگی پیرسون این شاخص‌ها با بارش در شرایط بدون تأخیر زمانی و با تأخیرهای ۳، ۶، ۹، ۱۲ بررسی و تحقیق شد (جدول ۲). نتایج نشان داد بیشترین میزان همبستگی این

- Irrigation and Drainage. 2011; 5 (2): 185-176. [In Persian]
- [4]. Khorshiddoust AM, Ghavidel Rahimi Y, Abbas-Zadeh K. The application of macro-scale patterns of atmospheric-oceanic in analysis of rainfall fluctuations (Case study: Ahar station). Journal of space geographical. 2010; 10 (29): 128-95. [In Persian]
- [5]. Iseri Y, Dandy G, Maier H, Kawamura A, Jinno K. Medium term forecasting of rainfall using artificial neural Networks. International Congress on Modelling and Simulation (16th: 2005: Melbourne, Victoria). 2005; 1834-1840.
- [6]. Omogbai BE. Prediction of northern Nigeria Rainfall using sea surface temperature. Journal of Human Ecology. 2010 Nov; 32(2):127-33.
- [7]. Nagesh KD, Janga RM, Rajib M. Regional Rainfall Forecasting using Large Scale Climate Teleconnections and Artificial Intelligence Techniques. Journal of Intelligent Systems. 2006; 16(4):307-22.
- [8]. Silverman D, Dracup JA. Artificial neural networks and long-range precipitation prediction in California. Journal of applied meteorology. 2000 Jan; 39(1):57-66.
- [9]. Schmidt N, Lipp EK, Rose JB, Luther ME. ENSO influences on seasonal rainfall and river discharge in Florida. Journal of Climate. 2001 Feb 15; 14(4):615.
- [10]. Han-Lie X, Juan F, Cheng S. Impact of preceding summer North Atlantic Oscillation on early autumn precipitation over central China. Atmospheric and Oceanic Science Letters. 2013 Jan 1; 6(6):417-22.
- [11]. Sharma S, Srivastava P, Fang X, Kalin L. Hydrologic simulation approach for El Niño Southern Oscillation (ENSO)-affected watershed with limited raingauge stations. Hydrological Sciences Journal. 2016 Apr 25; 61(6):991-1000.
- [12]. Larry bazargan A. Practical linear regression. Shiraz. Shiraz University Press. First Edition. 2006; 331. [In Persian]
- [13]. Conrads PA, Roehl EA. Comparing physics-based and neural network models for simulating salinity, temperature, and dissolved-oxygen in a complex, tidally affected river basin. In Proceedings of the South Carolina environmental conference 1999 Mar 15.
- [14]. Hosseini SA. Estimation of maximum temperatures in Ardabil city by using artificial neural network theory. Master's thesis. University of Mohaghegh Ardabili. Department of Natural Geography. 2009; 28. [In Persian]
- شبیه‌سازی کند. به بیانی شبکه عصبی می‌تواند ۴۴ درصد یا تقریباً نیمی از تغییرات بارش توسط سیگنال‌های اقلیمی را تبیین کند (شکل ۷). پیش‌بینی داده‌های بارش براساس دوره زمانی تحقیق از ۱۳۶۴-۱۳۸۸ برای ۵ سال صورت پذیرفت. برای پیش‌بینی داده‌های بارش تعداد داده‌های پیش‌بینی نباید بیش از یک چهارم کل داده‌ها باشد [۱۶]. شبکه عصبی نسبت به مدل رگرسیونی عملکرد مناسب‌تری داشت. همان‌طور که قبلاً بیان شد مؤثرترین شاخص‌ها در شبیه‌سازی و پیش‌بینی بارش مناطق ششده و قره‌بلاغ شاخص‌های اقلیمی NINO1.2، NINO3، WHWP بودند. یافته‌های دیگر محققان گویای اثرگذاری برخی شاخص‌های اقلیمی بر بارش کشور ایران است. در تحقیق حجازی‌زاده و همکارانش [۲] تأثیر سیگنال‌های اقلیمی ENSO، SOI، NAO، AO بر بارش ناحیه مرکزی ایران مطالعه شد و ایشان به این نتیجه رسیدند که شاخص‌های اقلیمی NINO1.2، NINO3 با تأخیر ۳ و ۶ ماهه بر بارش ناحیه مرکزی ایران مؤثرترین شاخص‌ها بودند. همچنین بر مؤثر بودن شاخص NINO1.2 در تحقیق خورشیددوست و همکارانش [۴] بر بارش‌های پاییزه ایستگاه اهر آذربایجان شرقی، علیزاده و انصاری [۳] بر بارش ایستگاه سینوپتیک مشهد تحقیقاتی انجام شده که با نتایج این تحقیق مطابقت دارد. بنابراین، با توجه به اهمیت متغیر بارش به‌عنوان مهم‌ترین پارامترهای هواشناسی در حوضه‌های مختلف منابع آب، کشاورزی، اقتصادی و... به‌منظور انجام مدیریت منابع آب، با توجه به خشکسالی‌های اخیر و بحران آب جدی در منطقه، انجام پیش‌بینی بلندمدت بارش در آینده و شناخت پارامترهای مؤثر بر بارش لازم و ضروری است.

منابع

- [1]. Motamedi M, Ehtramyan K, Shahabfar A. Study of telecommunications of ENSO Meteorological signal via Fluctuations of rainfall and temperature in Khorasan province. Journal of Environmental Sciences. 2007; 4 (4): 90-75. [In Persian]
- [2]. Hejazizadeh Z, Fattahi A, Salighe M, Arsalani F. The effect of climatic signals on precipitation in central part of Iran using artificial neural network. Research Applied Geographical Sciences. 2013; 13 (29): 89-75. [In Persian]
- [3]. Alizadeh A, Erfaniyan M, Ansari H. Study Teleconnection patterns of influencing on temperature and precipitation parameters (Case Study: Mashhad synoptic station). Journal of

[15]. Moghaddamnia A, Gousheh MG, Piri J, Amin S, Han D. Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques. *Advances in Water Resources*. 2009 Jan 31; 32(1):88-97.

[16]. Niromand H, Bozorgnia A. *Introduction to Time Series Analysis (Translation)*. First Edition. Press of Ferdowsi University of Mashhad. 1993; 283. [In Persian]