

کاربرد شبکه‌های عصبی آماری، فازی و پرسپترون در پیش‌بینی خشکسالی (مطالعه موردی: ایستگاه گنبد کاووس)

سید محمد حسینی موعاری^{1*} - شهاب عراقی نژاد²

تاریخ دریافت: 1393/05/04

تاریخ پذیرش: 1394/01/30

چکیده

درک صحیح زمان شروع خشکسالی در هر منطقه به مدیریت و کاهش خسارت‌های ناشی از خشکسالی کمک شایانی می‌کند. هدف این تحقیق، پیش‌بینی خشکسالی در ایستگاه گنبد کاووس در مقیاس‌های زمانی کوتاه‌مدت، میان‌مدت و بلندمدت است. بدین منظور شاخص بارندگی استاندارد (SPI) در مقیاس‌های زمانی 1، 3، 6، 9، 12 و 24 ماهه مورد استفاده قرار گرفت. برای محاسبه SPI از آمار ماهانه بارندگی این ایستگاه، در طی سال‌های آبی 52-1351 تا 86-1385 استفاده شد. پس از پیش‌خشکسالی، بر اساس سری زمانی SPI و با استفاده از چهار روش هوش مصنوعی شامل شبکه عصبی پرسپترون چند لایه (MLP)، سیستم استنباط عصبی-فازی تطبیقی (ANFIS)، شبکه عصبی مبتنی بر توابع پایه شعاعی (RBF) و شبکه عصبی رگرسیون تعمیم‌یافته (GRNN) اقدام به پیش‌بینی خشکسالی گردید. نتایج مربوط به پیش‌نشان داد، چهار دوره طولانی مدت خشکسالی مربوط به سال‌های 58-53، 62-60، 70-67 و 76-73 در طول دوره آماری وجود دارد. در قسمت پیش‌بینی، نتایج حاکی از افزایش دقت پیش‌بینی‌ها، با افزایش مقیاس محاسبه SPI بود؛ به نحوی که بر اساس نتایج حاصل از مدل MLP ضریب همبستگی بین مقادیر مشاهده‌ای SPI و مقادیر پیش‌بینی شده آن، برای SPI1 و SPI24 به ترتیب 0/009 و 0/949 بوده است. همچنین با توجه به نتایج مدل‌های ANFIS، RBF و GRNN به ترتیب ضریب همبستگی مربوط پیش‌بینی مقادیر SPI1 تا SPI24 از 0/021 تا 0/925، 0/263 تا 0/953 و 0/210 تا 0/955 متغیر بود. در مجموع با مقایسه نتایج مدل‌های مورد استفاده، ANFIS بهترین عملکرد و بعد از آن GRNN بهترین نتایج را ارائه نموده است.

واژه‌های کلیدی: توابع پایه شعاعی، شاخص بارندگی استاندارد، سیستم استنباط عصبی-فازی تطبیقی، هوش مصنوعی

مقدمه

است. کامپراگو و همکاران (19) خشکسالی را در سطح اتحادیه اروپا به عنوان یک مشکل مهم معرفی نمودند.

تنوع مطالعات خشکسالی به دلیل پیچیدگی آن بسیار گسترده است. مطالعاتی که در زمینه‌ی خشکسالی انجام می‌شوند، از نظر موضوع مورد بررسی در چند گروه متمایز قابل طبقه‌بندی هستند. برخی از محققین به رابطه گردش عمومی جو با خشکسالی و علت وقوع خشکسالی توجه می‌نمایند. گروه دیگری از محققین به شناخت زمان وقوع خشکسالی‌ها و عوامل تاثیرپذیر از آن می‌پردازند و گروهی دیگر احتمال وقوع خشکسالی و تاثیرات آن و خسارت‌های ناشی از آن را مورد تجزیه و تحلیل قرار می‌دهند. در این زمینه‌ها می‌توان به ترتیب به مطالعات چو و همکاران (6)، مک‌کی و همکاران (22) و ویلهایت و همکاران (32، 33 و 34) اشاره نمود.

پایش خشکسالی به منظور بررسی وضعیت منطقه از نظر شروع خشکسالی و چگونگی توسعه زمانی و مکانی خشکسالی انجام می‌شود. مرسوم‌ترین راه به منظور پایش خشکسالی استفاده از

خشکسالی یکی از پیچیده‌ترین بلایای طبیعی است که آسیب‌های اقتصادی، اجتماعی و زیست‌محیطی فراوانی را به همراه دارد. این پدیده اثرات منفی زیادی را به منابع آب، کشاورزی و در نتیجه اجتماع وارد می‌نماید، به نحوی که 50 درصد افرادی که از سال‌های 1967 تا 1992 از بلایای طبیعی آسیب دیده‌اند، تحت تاثیر خشکسالی بوده‌اند (25). ایران به علت قرار گرفتن در موقعیت جغرافیایی خاص، خشکسالی را با فراوانی وقوع بالا و شدت زیاد تجربه کرده است (1). خشکسالی نه تنها در کشورهایی با اقلیم خشک و نیمه‌خشک مانند ایران، بلکه در کشورهای اروپایی نیز مشکل‌آفرین

1 و 2- دانشجوی دکتری مهندسی منابع آب و استادیار گروه مهندسی آبیاری و آبادانی، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی و منابع طبیعی، دانشگاه تهران
* - نویسنده مسئول: (Email: Hosseini_SM@ut.ac.ir)

شدیدی در منطقه رخ داده است.

عیوضی و همکاران (9) به مقایسه روش‌های مختلف پیش‌بینی خشکسالی بر اساس شاخص SPI پرداختند. آن‌ها از دو نوع شبکه عصبی مصنوعی⁴ (ANN) استفاده نمودند. ANN مورد استفاده آن‌ها شبکه عصبی پرسپترون چندلایه⁵ (MLP) و شبکه عصبی مبتنی بر توابع پایه شعاعی⁶ (RBF) بود. هم‌چنین ایشان از مدل‌های خودهمبسته میانگین متحرک تجمعی⁷ (ARIMA) نیز استفاده نمودند؛ نتایج نشان داد که MLP دقت بالاتری در پیش‌بینی مقادیر SPI دارد. ابراهیمی و همکاران (8) به پیش‌بینی میان‌مدت خشکسالی در محدوده‌ی چهار سد امیرکبیر، لار، لتیان و طالقان پرداختند. ایشان در تحقیق خود برای پیش‌بینی SPI از سیستم استنباط عصبی - فازی تطبیقی⁸ (ANFIS) استفاده نمودند. وفاه‌خواه و بشری (31) به پیش‌بینی خشکسالی در حوضه آبریز کشف‌رود با استفاده از زنجیره مارکف پرداختند. حسن‌زاده و همکاران (14) اقدام به پیش‌بینی خشکسالی بر اساس شاخص SPI با استفاده از تلفیق الگوریتم ژنتیک با شبکه عصبی - موجکی نمودند؛ نتایج نشان داد مدل مورد استفاده عملکرد بهتری از مدل تلفیقی الگوریتم ژنتیک با شبکه عصبی دارد. میشرها و همکاران (25) برای پیش‌بینی خشکسالی در حوضه‌ای در هند از یک مدل ترکیبی استفاده نمودند. به این منظور آن‌ها مدل ترکیبی خود را از ترکیب یک مدل استوکستیک با ANN ایجاد کردند، آن‌ها پیش‌بینی خشکسالی را بر اساس شاخص SPI با استفاده از یک مدل استوکستیک، دو مدل ANN و دو مدل ترکیبی انجام دادند. مدل استوکستیک، ARIMA، دو مدل ANN شامل مدل مستقیم چندمرحله‌ای شبکه عصبی⁹ (DMSNN) و مدل بازگشتی چندمرحله‌ای شبکه عصبی¹⁰ (RMSNN) و مدل‌های ترکیبی شامل مدل ترکیبی تصادفی شبکه عصبی با رویکرد بازگشتی¹¹ (HSNNRA) و مدل ترکیبی تصادفی شبکه عصبی با رویکرد مستقیم¹² (HSNNDA) بودند. مقایسه پیش‌بینی‌های پنج مدل نشان داد مدل HSNNRA به خوبی می‌تواند خشکسالی را در حوضه مورد مطالعه پیش‌بینی کند. باکانلی و همکاران (3) عملکرد ANFIS و شبکه‌ی عصبی پیشخور¹³ (FFNN) را برای پیش‌بینی خشکسالی بر

شاخص‌های خشکسالی است (26). از شناخته‌ترین شاخص‌های خشکسالی می‌توان به شاخص شدت خشکسالی پالم¹ (PDSI) (27)، و شاخص بارندگی استاندارد² (SPI) (21) اشاره کرد. از آنجا که شاخص SPI در مقیاس‌های زمانی مختلف 1، 3، 6، 9، 12 و 24 ماهه قابل محاسبه است، می‌تواند برای پیش‌بینی خشکسالی در سه مقیاس، کوتاه‌مدت، میان‌مدت و بلندمدت مورد استفاده قرار گیرد. SPI1 و SPI3 برای پیش‌بینی خشکسالی کوتاه‌مدت، SPI6 و SPI9 برای پیش‌بینی خشکسالی میان‌مدت از SPI12 و SPI24 به‌منظور خشکسالی بلندمدت استفاده می‌گردد (25). مزیت دیگر SPI این است که برای محاسبه‌ی این شاخص تنها اطلاعات بارندگی مورد نیاز است. این مزایا باعث شده است که این شاخص کاربرد گسترده‌ای در مطالعات خشکسالی داشته باشد.

پایش خشکسالی از نظر آگاهی از شروع خشکسالی و شناسایی بزرگی خشکسالی‌هایی که در گذشته اتفاق افتاده است حائز اهمیت است؛ اما مهم‌تر از آن، پیش‌بینی مناسب خشکسالی، به منظور آگاهی از وضعیت آینده خشکسالی در منطقه است. پیش‌بینی خشکسالی به‌منظور مدیریت خشکسالی و کاهش اثرات سوء آن، ضروری به نظر می‌رسد (11). پیش‌بینی مناسب خشکسالی می‌تواند از اثرات و آسیب‌های آن به شدت بکاهد زیرا با آگاه بودن از وضعیت آینده منطقه از نظر خشکسالی، مدیریت ریسک در دستور کار قرار می‌گیرد و کمتر به مدیریت بحران خشکسالی وابسته خواهیم بود.

در زمینه پایش و پیش‌بینی خشکسالی مطالعات متنوعی انجام شده است. زارع‌زاده مهریزی و مرید (35) به پایش خشکسالی در حوضه زاینده‌رود پرداختند. آن‌ها در تحقیق خود از شاخص SPI، شاخص خشکسالی موثر³ (EDI) و تراز آب مخزن به منظور پایش خشکسالی استفاده کردند. نتایج نشان داد استفاده هم‌زمان از چند شاخص برای پایش خشکسالی نتایج بهتری را ارائه می‌دهد. ایشان پیشنهاد دادند که در منطقه مورد مطالعه، برای اعلام شروع خشکسالی SPI6 و برای اعلام خاتمه خشکسالی، شاخص EDI مناسب‌تر است. گوسیک و تراچکویک (12) برای ارزیابی خشکسالی در کشور صربستان از شاخص SPI در 12 ایستگاه سینوپتیک، طی سال‌های 1980 تا 2010 استفاده نمودند. نتایج حاکی از شناسایی دو دوره خشک در طی سال‌های 1987-1994 و 2000-2003 بود. بهزادی (4) به پایش خشکسالی در استان گیلان با استفاده از شاخص SPI پرداخت. ایشان در تحقیق خود از آمار بارندگی ماهانه ایستگاه‌های سینوپتیک منطقه در طی سال‌های 1976-2005 استفاده کرد. نتایج نشان داد در سال‌های 1991 و 1995 خشکسالی‌های

4 -Artificial Neural Network

5 -Multi Layer Perceptron

6 -Radial Basis Function

7 -Auto Regressive Integrated Moving Average

8- Adaptive Neuro-Fuzzy Inference System

9- Direct Multi Step Neural Network

10 -Recursive Multi Step Neural Network

11-Hybrid Stochastic Neural Network of Recursive Approach

12-Hybrid Stochastic Neural Network of Direct Approach

13- Feed Forward Neural Network

1-Palmer Drought Severity Index

2-Standardized Precipitation Index

3- Effective Drought Index

بارندگی باشد، تابع چگالی احتمال دو پارامتری گاما به صورت زیر تعریف می‌شود:

$$f(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-\frac{x}{\beta}} \quad x > 0 \quad (1)$$

در رابطه (1)، α پارامتر شکل، β پارامتر مقیاس توزیع و $\Gamma(\alpha)$ تابع گاما است که به صورت زیر تعریف می‌گردد:

$$\Gamma(\alpha) = \int_0^\infty y^{\alpha-1} e^{-y} dy \quad (2)$$

ضرائب α و β بهینه نیز از طریق روابط زیر حساب می‌شوند:

$$\hat{\alpha} = \frac{1}{4A} \left[1 + \sqrt{1 + \frac{4A}{3}} \right] \quad (3)$$

$$A = \ln(\bar{x}) - \frac{\sum \ln(x)}{n}$$

$$\hat{\beta} = \frac{\bar{x}}{\hat{\alpha}} \quad (4)$$

در رابطه‌ی محاسبه A ، پارامتر n تعداد مشاهدات بارندگی می‌باشد.

در محاسبه شاخص SPI از توزیع احتمال تجمعی گاما استفاده می‌شود که رابطه آن به صورت زیر است:

$$t = x / \hat{\beta} \quad (5)$$

$$F(x) = \frac{1}{\Gamma(\hat{\alpha})} \int_0^x t^{\hat{\alpha}-1} e^{-t} dt$$

از آنجا که در رابطه فوق مقدار لگاریتم صفر تعریف نشده است و توزیع بارندگی ممکن است دارای مقادیر صفر باشد، لذا در این شرایط احتمال تجمعی از رابطه (6) قابل محاسبه است.

$$H(x) = q + (1-q)F(x) \quad (6)$$

در این رابطه q احتمال بارندگی صفر می‌باشد. برای محاسبه q می‌توان از رابطه کالیفرنیا (رابطه (7)) استفاده نمود.

$$q = \frac{m}{n} \quad (7)$$

در این رابطه m تعداد داده‌های صفر موجود در سری زمانی و n نیز تعداد کل داده‌های بارندگی می‌باشد.

گام بعدی در محاسبه SPI انتقال احتمال تجمعی $H(x)$ که از توزیع گامای تجمعی به دست آمده به توزیع نرمال استاندارد تجمعی با میانگین صفر و انحراف معیار یک می‌باشد. در واقع SPI عبارت است از متغیری از تابع توزیع نرمال استاندارد، که مقدار احتمال تجمعی آن با مقدار احتمال تجمعی متغیر مورد نظر در توزیع گاما مساوی باشد. جدول 1 طبقه‌بندی شدت خشکسالی بر اساس شاخص SPI را نشان

مبنای SPI بررسی کردند؛ نتایج، برتری ANFIS را نسبت به FFNN نشان داد.

با توجه به اهمیت خشکسالی در کشور، نیاز به تحقیقات جامع در این زمینه بسیار محسوس است. به همین علت در این تحقیق به پیش‌بینی خشکسالی در ایستگاه گنبدکاووس پرداخته شده است. به دلیل مزیت‌های ذکر شده برای شاخص SPI، پیش‌بینی خشکسالی با استفاده از این شاخص انجام شد. به منظور بررسی خشکسالی در دوره‌های کوتاه‌مدت، میان‌مدت و بلندمدت، SPI در مقیاس‌های زمانی مختلف 1، 3، 6، 9، 12 و 24 ماهه محاسبه گردید. پس از پیش‌بینی خشکسالی به مقایسه توانایی روش‌های هوش مصنوعی در پیش‌بینی خشکسالی پرداخته شده است. روش‌های مورد استفاده در پیش‌بینی عبارت‌اند از: ANFIS، MLP، RBF و شبکه عصبی رگرسیون تعمیم‌یافته¹ (GRNN). برای اولین بار است که به منظور پیش‌بینی خشکسالی مورد استفاده قرار می‌گیرد.

مواد و روش‌ها

مطالعه موردی

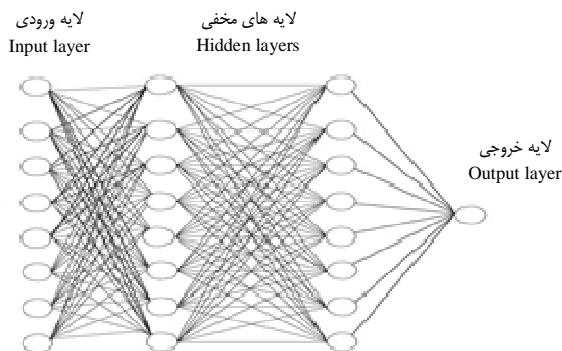
در این پژوهش به بررسی خشکسالی در ایستگاه گنبدکاووس، که یکی از ایستگاه‌های شاخص و بارز در حوضه گرگانود است، پرداخته شده است. بدین منظور از داده‌های بلندمدت بارندگی ماهانه این ایستگاه، در یک دوره آماری 35 ساله مربوط به سال‌های آبی 52-1351 لغایت 86-1385 به علت کفایت و کامل بودن نسبی سری داده‌ها و کیفیت مناسب آماری استفاده شد. این ایستگاه در طول جغرافیایی 55 درجه و 08 دقیقه شرقی و عرض جغرافیایی 37 درجه و 14 دقیقه شمالی واقع شده است. از نظر موقعیت سیاسی این ایستگاه در استان گلستان قرار دارد و یکی از ایستگاه‌های اصلی منطقه محسوب می‌شود. میانگین بارندگی این ایستگاه 471/7 میلی‌متر در سال است.

شاخص بارندگی استاندارد (SPI)

مک‌کی و همکاران (21) برای پیش‌بینی خشکسالی، شاخصی تحت عنوان شاخص بارندگی استاندارد (SPI) ارائه نمودند. SPI تنها به اطلاعات بارندگی نیازمند است و می‌تواند در مقیاس‌های زمانی مختلف 1، 3، 6، 9، 12، 24 و 48 ماهه محاسبه گردد. مسئله اصلی در محاسبه SPI برازش توزیع آماری مناسب بر روی اطلاعات بارندگی می‌باشد. تجربه نشان داده است که توزیع گاما توزیع مناسبی برای برازش روی داده‌های بارندگی است، در صورتی که فرض کنیم بارندگی در یک منطقه از توزیع گاما تبعیت می‌کند و x مقادیر

می‌دهد.

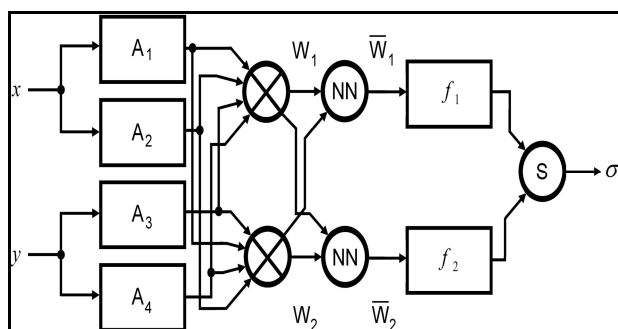
شکل 1 شماتیک یک MLP را نشان می‌دهد. در این تحقیق برای آموزش MLP از الگوریتم آموزشی پس‌انتشار خطا² (BP) استفاده شد. هم‌چنین تابع انتقال زیگموئید برای لایه مخفی و تابع انتقال خطی برای لایه خروجی در نظر گرفته شده است.



شکل 1- شماتیک MLP
Figure 1- Schematic of MLP

سیستم استنباط عصبی-فازی تطبیقی (ANFIS)

سیستم استنباط عصبی-فازی تطبیقی (ANFIS) توسط جانگ در سال 1993 معرفی گردید (18). ANFIS شبیه یک شبکه عصبی چند لایه است با این تفاوت که علاوه بر الگوریتم‌های یادگیری شبکه عصبی از منطق فازی نیز بهره می‌گیرد. یک مدل ANFIS از پنج لایه تشکیل شده است؛ این پنج لایه به ترتیب عبارت‌اند از: لایه ورود اطلاعات، لایه محاسبه وزن قوانین فازی، لایه نرمال‌سازی و وزن‌های قوانین به‌دست آمده، لایه محاسبه قوانین، لایه جمع‌بندی و خروجی شبکه. در این تابع عضویت در نظر گرفته شده، تابع عضویت دوزنقه‌ای و الگوریتم آموزش شبکه، روش هیبریدی در نظر گرفته شد. شکل 2 شماتیکی از ANFIS را نشان می‌دهد.



شکل 2- شماتیک سیستم استنباط عصبی-فازی تطبیقی (ANFIS)
Figure 2- Schematic of adaptive neuro-fuzzy inference system (ANFIS)

گاتمن (13)، نشان داد که فرض پیروی همیشگی داده‌های بارندگی از توزیع گاما صحیح نمی‌باشد و بایستی توزیع احتمالاتی بهینه برای هر سری زمانی به صورت جداگانه تعیین گردد. به همین دلیل در این تحقیق برای تعیین توزیع بهینه بارندگی در ایستگاه گنبدکاووس، چهار توزیع آماری از طریق آزمون کلموگروف-اسمیرنوف¹ (K-S) مورد بررسی قرار گرفت؛ سپس بر اساس توزیع آماری بهینه، اقدام به محاسبه شاخص SPI گردید. توزیع‌های آماری مورد بررسی علاوه بر توزیع گاما، توزیع نرمال، توزیع لوگ‌نرمال و توزیع ویبول می‌باشند.

شبکه عصبی پرسپترون چند لایه (MLP)

شبکه عصبی پرسپترون چند لایه (MLP) یکی از انواع شبکه‌های عصبی می‌باشد که در این شبکه، وزن‌ها و بایاس‌ها می‌توانند برای تولید یک هدف مشخص آموزش داده شوند. MLP از آن جهت که عملکرد مناسبی از خود نشان داده است؛ بسیار شایان توجه است. این شبکه، مجموعه‌ای از نورون‌ها است که در لایه‌های مختلفی پشت سر هم قرار گرفته‌اند. نورون یک واحد ریاضی با یک دستگاه غیرخطی است. بنابراین یک شبکه عصبی MLP که از اجتماع این نورون‌ها تشکیل می‌شود، یک سامانه پیچیده و غیرخطی خواهد بود (20). MLP از یادگیری نظارت‌شده که شامل ارائه ورودی‌ها و خروجی‌ها به شبکه و به حداقل رساندن خطای تخمین است، برای آموزش استفاده می‌کند (2).


جدول 1- طبقه‌بندی خشکسالی بر اساس شاخص SPI

طبقه خشکسالی Drought category	مقدار SPI SPI value
ترسالی بسیار شدید Extremely wet	$SPI \geq 2$
ترسالی شدید Very wet	$1.5 \leq SPI \leq 1.99$
ترسالی متوسط Moderately wet	$1 \leq SPI \leq 1.49$
نزدیک به نرمال Near normal	$-0.99 \leq SPI \leq 0.99$
خشکسالی متوسط Moderately dry	$-1 \leq SPI \leq -1.49$
خشکسالی شدید Severely dry	$-1.5 \leq SPI \leq -1.99$
خشکسالی بسیار شدید Extremely dry	$SPI \leq -2$

که تعداد نورون‌های آن در مقایسه با MLP بسیار آسان‌تر انتخاب می‌شود، زیرا برابر تعداد مشاهدات در نظر گرفته می‌شوند. شکل 4 یک شبکه GRNN را نشان می‌دهد. این شبکه همانند RBF، در لایه میانی از تابع گوسی استفاده می‌کند؛ اما در لایه خروجی یک بخش اضافه‌تر از RBF وارد محاسبات می‌شود. رابطه 10 برای محاسبه مقدار خروجی در این شبکه مورد استفاده قرار می‌گیرد.

$$Y_r = \frac{1}{\sum_{b=1}^n f(X_r, b)} \sum_{b=1}^n [f(X_r, b) \times T_b] \quad (10)$$

که در آن T_b هدف مربوط به b امین مشاهده و n تعداد مشاهدات است.



شکل 4- شماتیک GRNN
Figure 4- Schematic of GRNN

مدل‌های پیش‌بینی

به منظور پیش‌بینی کمی خشکسالی، چهار مدل مختلف مورد استفاده قرار گرفت. سپس بر اساس معیارهای ارزیابی بهترین مدل در هر پیش‌بینی انتخاب گردید. در مدل 1، برای پیش‌بینی شاخص SPI در ماه بعد، از سری زمانی SPI با یک گام تاخیر استفاده گردید، بدین صورت که برای پیش‌بینی مقدار شاخص SPI در زمان $t+1$ از مقدار شاخص در زمان t استفاده شد، در مدل 2 پیش‌بینی شاخص در ماه بعد بر اساس مقادیر شاخص تا دو ماه قبل صورت پذیرفت و به طور مشابه در مدل 3 و مدل 4 پیش‌بینی بر اساس مقادیر شاخص تا سه و چهار ماه قبل انجام شد.

مدل 1 (11) $SPI_{(t+1)} = f(SPI_{(t)})$

مدل 2 (12) $SPI_{(t+1)} = f(SPI_{(t)}, SPI_{(t-1)})$

مدل 3 (13) $SPI_{(t+1)} = f(SPI_{(t)}, SPI_{(t-1)}, SPI_{(t-2)})$

مدل 4 (14) $SPI_{(t+1)} = f(SPI_{(t)}, SPI_{(t-1)}, SPI_{(t-2)}, SPI_{(t-3)})$

شبکه عصبی مبتنی بر توابع پایه شعاعی (RBF)

شبکه عصبی مبتنی بر توابع پایه شعاعی (RBF)، دارای پایه ریاضیاتی بسیار قوی بر مبنای فرضیه منظم‌سازی برای حل مسائل مشکل می‌باشد. به طور کلی این شبکه از سه لایه شامل لایه ورودی، مخفی و خروجی تشکیل شده است. در این شبکه، تابع انتقال گوسی در لایه مخفی استفاده می‌گردد و در لایه خروجی تابع انتقال خطی است. RBF پایه و اساس نوع خاصی از شبکه‌های عصبی به نام شبکه‌های عصبی آماری است. در شکل 3 یک شبکه RBF نشان داده شده است. همان‌طور که در شکل مشخص است، نورون RBF یک تابع گوسی است. ورودی این تابع، فاصله اقلیدسی بین هر ورودی به نورون با بردار مشخص شده‌ی هم اندازه‌ی بردار ورودی است. این تابع گوسی از رابطه زیر استفاده می‌کند:


$$f(X_r, b) = e^{-I^2} \quad (8)$$

$$I = \|X_r - X_b\| * 0.8326/h$$

در این رابطه X_r ورودی شبکه با خروجی نامعلوم، X_b ورودی مشاهداتی در زمان یا مکان b و h پارامتری است که پهنای تابع گوسی را کنترل می‌کند. خروجی این تابع بین صفر تا یک متغیر است. محاسبه خروجی Y_r بر اساس متغیر مستقل X_r به صورت زیر به دست می‌آید:

$$Y_r = LW * f(X_r, b) + Bias \quad (9)$$

در این رابطه LW و $Bias$ به ترتیب وزن ماتریس ارتباطات بین لایه مخفی و لایه خروجی و ماتریس بایاس لایه خروجی است.



شکل 3- شماتیک RBF
Figure 3- Schematic of RBF

شبکه عصبی رگرسیون تعمیم‌یافته (GRNN)

شبکه عصبی رگرسیون تعمیم‌یافته (GRNN) یک شبکه برای حل مسائل رگرسیونی بر پایه آمار است. این شبکه نوع دیگری از شبکه‌های RBF است. GRNN در سال 1991 توسط اسپکت معرفی گردید (29). این شبکه دارای آموزش سریع بوده و می‌تواند توابع غیرخطی را به خوبی مدل نماید. GRNN یک شبکه سه لایه است

معیارهای ارزیابی

برای ارزیابی مدل‌ها و مقایسه نتایج روش‌های مختلف، از سه معیار ارزیابی یعنی ضریب همبستگی¹ (R)، جذر میانگین مربعات خطا² (RMSE) و میانگین قدرمطلق خطا³ (MAE) استفاده گردید. این معیارها به صورت زیر تعریف می‌شوند:

$$R = \frac{\frac{1}{n} \sum_{i=1}^n (o_i - \bar{o})(f_i - \bar{f})}{\sqrt{\frac{1}{n} \sum_{i=1}^n (o_i - \bar{o})^2} \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - \bar{f})^2}} \quad (15)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (o_i - f_i)^2} \quad (16)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |o_i - f_i| \quad (17)$$

در این روابط، O_i مقادیر مشاهداتی در گام زمانی i ام، f_i مقادیر پیش‌بینی شده در گام زمانی i ام، \bar{O} میانگین مقادیر مشاهداتی، \bar{f} میانگین مقادیر پیش‌بینی شده و n تعداد داده‌ها می‌باشند. هر مدل که دارای R بیشتر، $RMSE$ و MAE کمتر باشد، از مطلوبیت بیشتری برخوردار است.

نتایج و بحث

به‌منظور پایش خشکسالی در ایستگاه گنبدکاووس، شاخص SPI بر اساس توزیع آماری بهینه بارندگی در مقیاس‌های زمانی 1، 3، 6، 9، 12 و 24 ماهه محاسبه گردید. توزیع بهینه بارندگی در ایستگاه گنبدکاووس به ازای مقیاس‌های مختلف SPI، بر اساس آزمون K-S در جدول 2 ارائه شده است. همان‌گونه که از جدول 2 مشخص است توزیع بهینه بارندگی در بسیاری از ماه‌ها، توزیع گاما نمی‌باشد. در مقیاس‌های مختلف محاسبه SPI حداقل در 50 درصد مواقع توزیع بهینه بارندگی، توزیعی به جزء توزیع گاما بوده است. بیش‌ترین تبعیت داده‌های بارندگی از توزیع گاما مربوط به SPI1 و SPI3 است، که در شش ماه داده‌های بارندگی، از این توزیع پیروی می‌کنند و کم‌ترین پیروی بارندگی از توزیع گاما مربوط به SPI24 است؛ که تنها در دو ماه، توزیع آماری بهینه، توزیع گاما بوده است. جابجایی (15) نیز با بررسی چهار توزیع گاما، نرمال، لوگ‌نرمال و وییول برای محاسبه شاخص SPI به نتایجی مشابه نتایج فوق دست یافت.

پس از مشخص شدن توزیع احتمالاتی بهینه بارندگی، شاخص SPI در مقیاس‌های زمانی مختلف، محاسبه شد. شکل 5، نمودار

تغییرات این شاخص را، در دوره آماری مورد بررسی نشان می‌دهد. بر اساس این شکل، شاخص SPI در مقیاس زمانی کوتاه‌مدت دارای نوسانات زیادی است، اما با افزایش گام زمانی محاسبه SPI از مقدار این نوسانات کاسته شده است. با افزایش مقیاس زمانی محاسبه SPI تعداد وقوع خشکسالی‌ها کاهش یافته اما تداوم آن‌ها افزایش داشته است. همچنین وقوع خشکسالی‌های پی‌درپی در مقیاس زمانی کوتاه-مدت، موجب وقوع خشکسالی در مقیاس زمانی بلندمدت شده است. نتایج مشابه از ویژگی‌های شاخص SPI در مقیاس‌های زمانی مختلف توسط قاسمی و همکاران (10) ارائه شده است. بر اساس شکل 5، می‌توان چهار دوره طولانی مدت خشکسالی مربوط به سال‌های 53-58، 60-62، 67-70 و 73-76 را تشخیص داد، همچنین سه دوره ترسالی مربوط به سال‌های 64-67، 70-73 و 81-85 در طول دوره آماری وجود دارد.

در ادامه با در دست بودن سری زمانی شاخص SPI، اقدام به پیش‌بینی خشکسالی با استفاده از روش‌های ANFIS، MLP، RBF و GRNN شد. 80 درصد داده‌ها برای مرحله آموزش و 20 درصد برای آزمایش مورد استفاده قرار گرفت. پارامترهای مناسب روش‌های مختلف از طریق آزمون و خطا تعیین گردید. همچنین به‌منظور جلوگیری از بیش‌برازش، از صحت‌سنجی متقاطع استفاده شد. در روش صحت‌سنجی متقاطع در هر بار اجرای مدل پیش‌بینی با یک پارامتر مشخص، یک یا تعدادی از داده‌های مجموعه آموزش، کنار گذاشته می‌شوند (به عنوان داده‌های صحت‌سنجی) و مدل بر اساس داده‌های باقی‌مانده، آموزش می‌بیند، سپس داده‌های کنار گذاشته شده به مجموعه آموزش برگردانده می‌شوند و داده یا مجموعه دیگری از داده‌های آموزش، به عنوان داده صحت‌سنجی کنار گذاشته می‌شوند و بار دیگر شبکه آموزش داده می‌شود، این فرآیند تا زمانی که تمام داده‌های آموزش در قسمت صحت‌سنجی استفاده شوند، ادامه می‌یابد. پس از آن بر اساس میانگین خطای مدل در تخمین داده‌های صحت‌سنجی، پارامتر(های) مناسب شبکه عصبی تعیین می‌شود. برای پیش‌بینی از چهار مدل معرفی شده در بخش 2-7 استفاده گردید. مدل مناسب بر اساس معیارهای ارزیابی R، RMSE و MAE برای هر روش و در تمامی مقیاس‌های زمانی استخراج شد. پس از آن، تحلیل نتایج بر پایه بهترین مدل، برای هر یک از روش‌ها صورت پذیرفت.

نتایج، حاکی از عملکرد مناسب تمامی روش‌های استفاده شده در مقیاس‌های بالای SPI است. در خصوص SPI1 روش‌های مختلف، توانایی قابل قبولی در پیش‌بینی خشکسالی ندارند، بهترین روش در این میان RBF است که به ترتیب با R، MAE و RMSE برابر با 0/263، 0/806 و 0/989 بهترین عملکرد را از خود نشان داده است. علت این موضوع را می‌توان در پراکندگی و تغییرات شدید شاخص SPI در مقیاس یک ماهه جستجو کرد. بهبود عملکرد تمامی روش‌ها

1- Correlation

2- Root Mean Square Error

3- Mean Absolute Error




با افزایش مقیاس زمانی محاسبه SPI رابطه مسقیم دارد، بدین معنی که با افزایش مقیاس محاسبه SPI، مقادیر معیارهای ارزیابی مورد استفاده، بهبود می‌یابد. در این خصوص نتایج مشابهی توسط حجابی و بذرافشان (16) و میثرا و دسای (23 و 24) ارائه شده است.

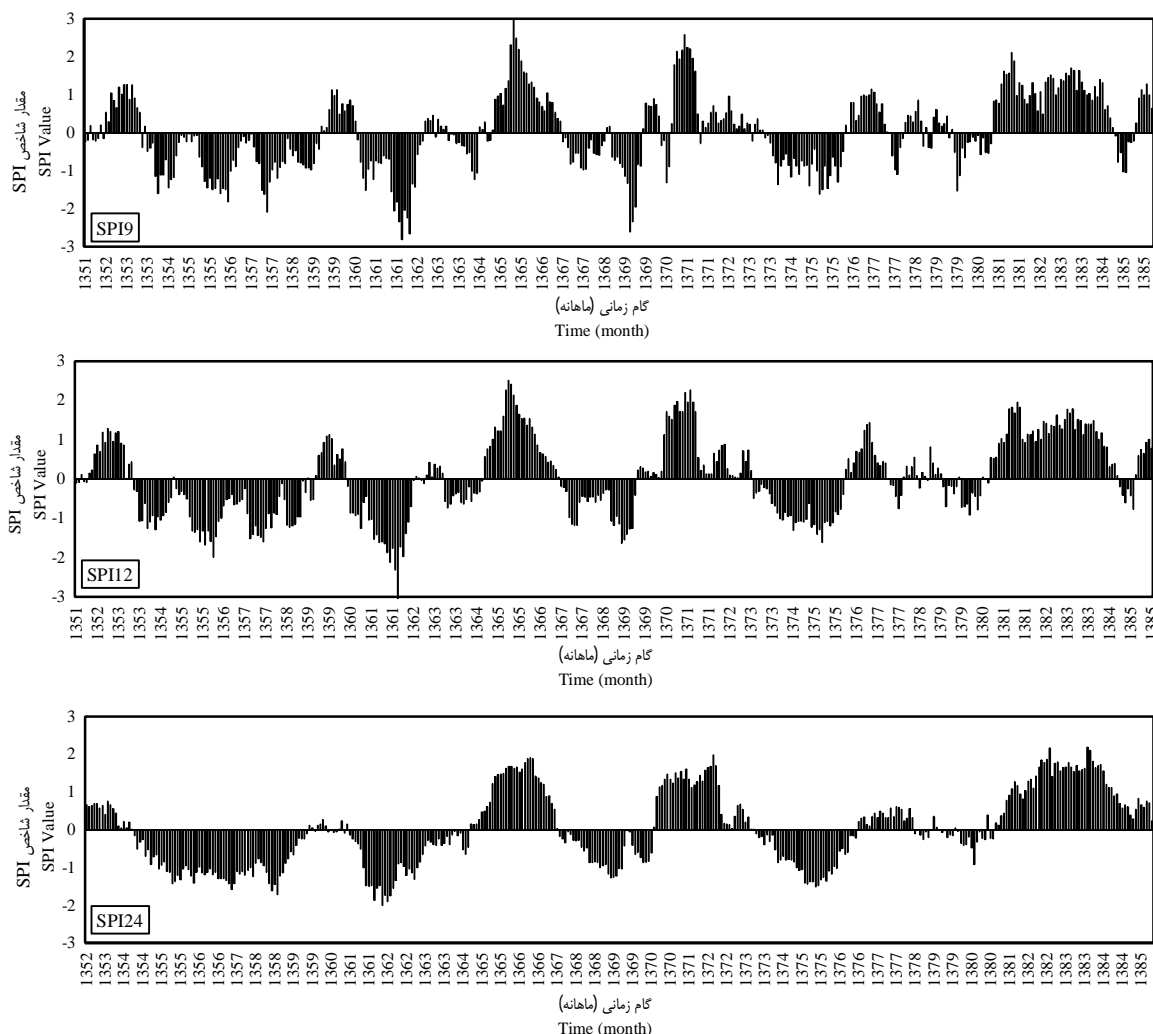
جدول 2- توزیع‌های آماری بهینه بارندگی در ایستگاه گنبد کاووس*
Table 2- Optimal statistical distribution of precipitation in the Gonbad-e Kavous station

شاخص Index	مهر Mehr	آبان Aban	آذر Azar	دی Dey	بهمن Bahman	اسفند Esfand	فروردین Farvardin	اردیبهشت Ordibehesht	خرداد Khordad	تیر Tir	مرداد Mordad	شهریور Shahrivar
SPI1	L	N	N	N	L	G	G	G	G	G	G	W
SPI3	G	G	W	G	W	N	L	G	G	W	G	L
SPI6	W	W	N	N	W	G	L	G	L	L	L	G
SPI9	L	L	L	L	G	W	L	G	L	L	L	G
SPI12	L	L	G	L	L	L	G	G	L	L	G	G
SPI24	W	G	G	L	L	L	L	L	L	N	L	W

*در جدول فوق G: توزیع گاما، N: توزیع نرمال، L: توزیع لوگ‌نرمال و W: توزیع ویبول است

*In the above table G: Gamma distribution, N: normal distribution, L: Log-normal distribution, and W: Weibull distribution.





شکل 5- سری زمانی شاخص SPI در مقیاس‌های زمانی مختلف برای ایستگاه گنبد کاووس
 Figure 5- SPI time series over different time scales for the Gonbad-e Kavous station

تعداد رتبه‌ی اول را داشته‌اند. با ترکیب تعداد معیارهای ارزیابی و تعداد مقیاس‌های مختلف محاسبه‌ی SPI برای هر روش 18 رتبه (3×6) وجود خواهد داشت. در این میان، روش MLP، 2 بار رتبه نخست را داشته است. روش‌های ANFIS، RBF و GRNN نیز به ترتیب 10، 3 و 3 بار در رتبه نخست قرار گرفته‌اند؛ بنابراین در مجموع عملکرد روش ANFIS بهتر از سایر روش‌ها بوده است. در غیاب روش ANFIS، روش GRNN با 9 بار قرارگیری در رتبه دوم بهترین عملکرد را از خود نشان است.

نکته مهم دیگری که باید به آن اشاره کرد عملکرد مناسب مدل GRNN می‌باشد، هر چند که این مدل در تمامی مقیاس‌های پیش-بینی SPI عملکرد تقریباً مشابه با سایر روش‌ها دارد و تنها در پیش‌بینی SPI24 از تمامی روش‌ها عملکرد بهتری داشته است، اما نکته قابل توجه، آموزش سریع این شبکه و کاهش زمان آزمون و خطا برای انتخاب پارامتر بهینه آن است. GRNN تنها به یک پارامتر

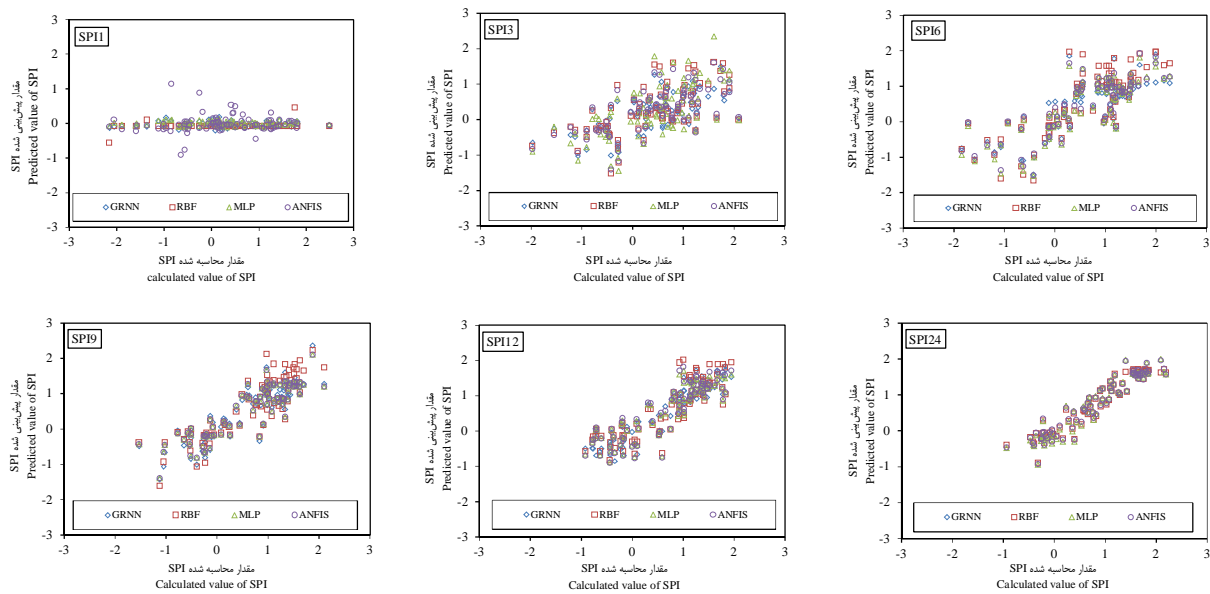
جدول 3 مقادیر معیارهای ارزیابی، مربوط به مرحله آزمایش روش‌های مختلف را نشان می‌دهد. بر اساس جدول 3 تمام روش‌ها در پیش‌بینی SPI1 کم‌ترین دقت و در پیش‌بینی SPI24 بیش‌ترین دقت را داشته‌اند. به‌نحوی که در روش MLP ضریب همبستگی بین مقادیر مشاهداتی SPI و مقادیر محاسباتی آن از 0/009 به 0/949 افزایش می‌یابد. هم‌چنین برای روش‌های ANFIS، RBF و GRNN نیز به ترتیب ضریب همبستگی از 0/021 تا 0/925، 0/263 تا 0/953 و 0/210 تا 0/955 برای پیش‌بینی مقادیر SPI1 و SPI24 متغیر است.

در جدول 3 اعدادی در داخل پرانتز، کنار مقادیر معیارهای ارزیابی نوشته شده است که رتبه هر روش، بر اساس معیار ارزیابی مورد نظر در پیش‌بینی شاخص SPI را نشان می‌دهد. بر این مبنا در پیش‌بینی روش SPI1، RBF، در پیش‌بینی SPI3، SPI6، SPI9 و SPI12 روش ANFIS و در پیش‌بینی SPI24 روش GRNN بیش‌ترین

وابسته است که مقدار مناسب آن نیز در طی چند اجرا به سرعت روشن‌های ذکر شده سریع‌تر است. مشخص می‌گردد. این شبکه از نظر سرعت آموزش از تمامی

جدول 3- معیارهای ارزیابی برای مدل‌های مختلف در پیش‌بینی خشکسالی
Table 3- Performance measures for the various models in forecasting drought

روش Method	معیارهای ارزیابی Performance measures	SPI1	SPI3	SPI6	SPI9	SPI12	SPI24
MLP	مدل بهینه The optimal model	3	3	2	1	1	1
	R	0.009 (4)	0.645 (3)	0.804 (1)	0.879 (3)	0.927 (2)	0.949 (3)
	MAE	0.794 (3)	0.560 (4)	0.458 (2)	0.317 (3)	0.249 (2)	0.149 (1)
	RMSE	0.997 (3)	0.703 (4)	0.571 (2)	0.399 (3)	0.307 (2)	0.254 (4)
ANFIS	مدل بهینه The optimal model	2	1	1	1	1	1
	R	0.021 (3)	0.653 (1)	0.801 (2)	0.885 (1)	0.915 (3)	0.925 (4)
	MAE	0.835 (4)	0.532 (1)	0.453 (1)	0.303 (1)	0.238 (1)	0.187 (3)
	RMSE	1.012 (4)	0.668 (1)	0.562 (1)	0.390 (1)	0.305 (1)	0.244 (3)
RBF	مدل بهینه The optimal model	3	1	1	1	1	1
	R	0.263 (1)	0.626 (4)	0.783 (3)	0.860 (4)	0.910 (4)	0.953 (2)
	MAE	0.806 (1)	0.559 (3)	0.473 (3)	0.348 (4)	0.276 (4)	0.118 (4)
	RMSE	0.989 (1)	0.692 (2)	0.599 (4)	0.439 (4)	0.337 (4)	0.243 (2)
GRNN	مدل بهینه The optimal model	3	3	2	2	2	1
	R	0.210 (3)	0.648 (2)	0.776 (4)	0.883 (2)	0.928 (1)	0.955 (1)
	MAE	0.808 (2)	0.558 (2)	0.474 (4)	0.314 (2)	0.250 (3)	0.171 (2)
	RMSE	0.992 (2)	0.694 (3)	0.589 (3)	0.398 (2)	0.310 (3)	0.232 (1)



شکل 6- نتایج مقادیر محاسبه شده و پیش‌بینی شده شاخص SPI در ایستگاه گنبدکاووس
Figure 6- The results of calculated and forecasted values of SPI in the Gonbad-e Kavous station

جدول 4- آزمون مقایسه میانگین سری زمانی مشاهداتی و پیش‌بینی شده SPI
 Tabel 4- Comparison mean test for observed and forecasted SPI time series

	مشاهداتی Observed	میانگین Mean				آماره Z Z- Statistics			
		MLP	ANFIS	RBF	GRNN	MLP	ANFIS	RBF	GRNN
SPI1	0.229	0.002	-0.011	-0.071	-0.031	2.142	2.188	2.822	2.450
SPI3	0.420	0.267	0.278	0.303	0.333	1.209	1.209	0.976	0.778
SPI6	0.563	0.425	0.471	0.532	0.431	1.019	0.689	0.220	1.025
SPI9	0.616	0.541	0.541	0.609	0.527	0.624	0.624	0.053	0.723
SPI12	0.662	0.586	0.606	0.633	0.609	0.635	0.456	0.241	0.442
SPI24	0.833	0.780	0.792	0.783	0.783	0.435	0.341	0.416	0.423

طریق آزمون K-S تعیین گردید؛ پس از آن به محاسبه شاخص SPI با استفاده از توزیع آماری بهینه پرداخته شد. در ادامه با در دست بودن سری زمانی شاخص SPI با استفاده از چهار روش هوش مصنوعی شامل MLP، ANFIS، RBF و GRNN اقدام به پیش‌بینی خشکسالی گردید.

نتایج نشان داد که توزیع بهینه بارندگی همواره توزیع گاما نمی‌باشد و بایستی برای مقیاس‌های زمانی مختلف SPI به طور جداگانه مشخص گردد. بر اساس شاخص SPI در مقیاس 12 و 24 ماهه، چهار دوره طولانی مدت خشکسالی مربوط به سال‌های 53-58، 60-62، 67-70 و 73-76 تشخیص داده شد، همچنین سه دوره ترسالی مربوط به سال‌های 64-67، 70-73 و 81-85 در طول دوره آماری وجود داشت.

نتایج مربوط به پیش‌بینی خشکسالی نشان داد، که پیش‌بینی SPI1 با دقت بسیار پایینی انجام می‌شود به نحوی که در بهترین حالت روش RBF، به ترتیب با r ، MAE و RMSE برابر با 0/263، 0/806 و 0/989 بهترین عملکرد را داشته است. همچنین با افزایش مقیاس محاسبه SPI دقت پیش‌بینی تمام روش‌ها افزایش می‌یابد. به نحوی که تمامی روش‌ها در SPI1 بدترین عملکرد و در SPI24 بهترین عملکرد را از خود نشان داده‌اند. همچنین در پیش‌بینی SPI با مقیاس زمانی بالاتر، مدل بهینه پیش‌بینی کننده مدل ساده‌تری بوده است، به صورتی که برای SPI24 در کلیه روش‌های مدلی که تنها از یک گام تاخیر در پیش‌بینی استفاده کرده است، بهترین مدل پیش‌بینی کننده بوده است. دوردو (7) بر اساس سری زمانی شاخص SPI و با استفاده از مدل‌های سری زمانی به پیش‌بینی خشکسالی در حوضه‌ای در ترکیه پرداخت، نتایج ایشان با نتایج تحقیق حاضر سازگاری دارد. رضاییان‌زاده و تبری (28) با منظور بررسی پیش‌بینی پذیری خشکسالی در 5 ایستگاه سینوپتیک کشور از شبکه عصبی MLP استفاده کردند که نتایج ایشان حاکی از افزایش دقت

نتیجه دیگری که از جدول 3 قابل استنتاج است، انتخاب مدل‌های ساده‌تر، به عنوان مدل بهینه پیش‌بینی کننده با افزایش مقیاس زمانی SPI است. به‌نحوی که برای پیش‌بینی SPI1 اکثر روش‌ها از مدل 3 استفاده کرده‌اند، در حالی که برای پیش‌بینی SPI24 تمام روش‌ها، با استفاده از مدل شماره یک، نتایج بهتری را گزارش نموده‌اند. در این زمینه RBF و ANFIS بیش‌ترین استفاده از مدل شماره یک را دارا می‌باشند؛ که می‌توان این مورد را به عنوان نقطه قوتی برای این دو روش دانست. شکل 6 مقادیر مشاهداتی و پیش‌بینی شده شاخص SPI را برای داده‌های آزمایش نشان می‌دهد. این شکل بهبود عملکرد روش‌های مورد استفاده با افزایش مقیاس زمانی محاسبه SPI را به خوبی نشان می‌دهد. همان‌طور که مشخص است ارتباط بین مقادیر محاسباتی و پیش‌بینی شده از یک خط بدون شیب در SPI1 به خطی با شیب تقریباً 45 درجه در SPI24 رسیده است مقایسه میانگین مقادیر مشاهداتی و پیش‌بینی شده بر اساس آزمون Z نشان می‌دهد، که فرض صفر مبنی بر برابر بودن میانگین سری مقادیر مشاهداتی و پیش‌بینی شده تنها در مورد SPI1 در سطح اشتباه یک درصد رد می‌شود. بنابراین صرف‌نظر از پیش‌بینی SPI1، می‌توان نتیجه گرفت که در بقیه موارد، تمامی روش‌های مورد استفاده، میانگین سری زمانی مشاهداتی را حفظ کرده‌اند. این ویژگی نیز می‌تواند تأکیدی بر کارایی روش‌های هوش مصنوعی در پیش‌بینی خشکسالی باشد.

نتیجه‌گیری کلی

هدف از این تحقیق پایش و پیش‌بینی خشکسالی، بر مبنای شاخص SPI در مقیاس‌های زمانی مختلف بود. بدین منظور از اطلاعات بارندگی ایستگاه گنبدکاووس در یک دوره 35 ساله مربوط به سال‌های آبی 52-1351 لغایت 86-1385 استفاده گردید. در ابتدا توزیع آماری بهینه بارندگی در مقیاس‌های مختلف محاسبه‌ی SPI از

تحقیق در پیش‌بینی خشکسالی مورد استفاده قرار گرفت، بهترین دقت را داشته است. صرف‌نظر از دقت مناسب روش GRNN، یک مزیت دیگر آن نسبت به سایر روش‌ها، سرعت آموزش بالای این شبکه عصبی است. سرعت بالای آموزش GRNN در کنار دقت مناسب این روش، می‌تواند GRNN را به یک روش مناسب برای پیش‌بینی خشکسالی و سایر مسائل رگرسیونی تبدیل نماید.

پیش‌بینی‌ها با افزایش مقیاس محاسبه SPI بود. حسینی موعاری و عراقی‌نژاد (17) نیز نتایج مشابه‌ای در پیش‌بینی خشکسالی با استفاده از شبکه عصبی در حوضه گرگانرود گزارش کردند. در خصوص بررسی دقت روش‌های مختلف استفاده شده، می‌توان عملکرد تمام روش‌ها را رضایت‌بخش دانست، اما در قضاوت سخت‌گیرانه روش ANFIS بهترین عملکرد را از خود نشان داده است. بعد از ANFIS، روش GRNN که برای اولین بار در این

منابع

- 1- Alipour H. 2011. Effects of drought on socio-economic status of farmers: A case study on the Nehbandans wheat farmers. Watershed Management Research (Pajouhesh & Sazandegi), 99: 113-125. (In Persian with English abstract)
- 2- Araghinejad S. 2014. Data-driven Modeling: Using MATLAB in Water Resources and Environmental Engineering. Springer.
- 3- Bacanlı U.G., Firat M., and Dikbas F. 2009. Adaptive neuro-fuzzy inference system for drought forecasting. Stochastic Environmental Research and Risk Assessment, 23(8): 1143-1154.
- 4- Behzadi J. 2010. Drought Monitoring and Analysis of Its Characteristic in Golestan Province. M A K A N Geography and Land Management, 1(1): 21-36.
- 5- Belayneh A., and Adamowski J. 2012. Standard precipitation index drought forecasting using neural networks, wavelet neural networks, and support vector regression. Applied Computational Intelligence and Soft Computing, 6: 1-13.
- 6- Chu P.S., Nash A.J., and Porter F.Y. 1993. Diagnostic studies of two contrasting rainfall episodes in Hawaii: Dry 1981 and wet 1982. Journal of climate, 6(7): 1457-1462.
- 7- Durdu Ö.F. 2010. Application of linear stochastic models for drought forecasting in the Büyük Menderes river basin, western Turkey. Stochastic Environmental Research and Risk Assessment, 24(8): 1145-1162.
- 8- Ebrahimi R., Zahraie B., and Nasserli M. 2010. Mid-term Prediction of Meteorological Drought Using Fuzzy Inference Systems. Water and Wastewater, 22(78): 112-125. (in Persian with English abstract)
- 9- Eivazi M., Mosaedi A., and Dehghani, A.A. 2009. Comparison of different approaches for predicting SPI. Journal of Water and Soil Conservation, 16(2): 145-167. (in Persian with English abstract)
- 10- Ghasemi M., Eslamian S.S, and Soltani S. 2008. Monitoring and Regionalization of Meteorological Drought in Karkhe Watershed Using Standardized Precipitation Index and Precipitation Deciles. Agricultural research: water, soil and plants in agriculture, 8(3): 23-35. (in Persian with English abstract)
- 11- Ghamghami M., and Bazrafshan J. 2011. Prediction of meteorological drought conditions in Iran using Markov chain model. Journal of Water and Soil Resources Conservation, 1(3):1-12. (in Persian with English abstract)
- 12- Gocic M., and Trajkovic S. 2013. Analysis of precipitation and drought data in Serbia over the period 1980–2010. Journal of Hydrology, 494: 32-42.
- 13- Guttman N.B. 1999. Accepting the Standardized Precipitation Index: a calculation algorithm. Journal of the American Water Resources Association, 35(2): 311-322.
- 14- Hassanzadeh Y., Abdi Kordani A., and Hassanzadeh A. 2011. Drought Forecasting Using Genetic Algorithm and Conjoined Model of Neural Network-Wavelet. Water and Wastewater, 23(83): 59-48. (in Persian with English abstract)
- 15- Hejabi S. 2010. An Adaptive Study of Meteorological Drought Forecasting Methods in Dry and Wet Climates of Iran. Master Thesis, University of Tehran. (in Persian with English abstract)
- 16- Hejabi S., and Bazrafshan J. 2012. Evaluation of several model in forecasting time series of standardized precipitation index. Journal of Water Research in Agriculture, 27(3): 429-444.
- 17- Hosseini-Moghari S.M., and Araghinejad S. 2015. Monthly and seasonal drought forecasting using statistical neural networks. Environmental Earth Science, 74(1): 397-412.
- 18- Jang J.S. 1993. Anfis: adaptive-network-based fuzzy inference systems. Journal of IEEE Transactions on, 23(3): 665–685.
- 19- Kampragou E., Apostolaki S., Manoli E., Froebrich j., and Assimacopoulos D. 2011. Towards the harmonization of water-related policies for managing drought risks across the EU. Environmental science and policy, 14(7): 815-824.
- 20- Karamouz M., and Araghinejad S. 2009. Advanced Hydrology. Amirkabir University Press. Tehran.

- 21- McKee T.B., Doesken N.J., and Kleist J. 1993. The relationship of drought frequency and duration to time scales. In Proceedings of the 8th Conference on Applied Climatology, 17(22): 179-183.
- 22- McKee T.B., Doesken N.J., and Kleist J. 1995. Drought monitoring with multiple time scales, Ninth Conference on Applied Climatology, American Meteorological Society, Boston, Massachusetts, 233-236.
- 23- Mishra A.K., and Desai V.R. 2005. Drought forecasting using stochastic models. Stochastic Environmental Research and Risk Assessment, 19(5): 326-339.
- 24- Mishra A.K., and Desai, V.R. 2006. Drought forecasting using feed-forward recursive neural network. Ecological Modelling, 198(1): 127-138.
- 25- Mishra A.K., Desa V.R., and Singh V.P. 2007. Drought Forecasting Using a Hybrid Stochastic and Neural Network Model. Journal of Hydrologic Engineering, 12(6): 626-638.
- 26- 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.
- 27- Palmer W.C. 1965. Meteorological drought. Washington, DC, USA: US Department of Commerce, Weather Bureau.
- 28- Rezaeian-Zadeh M., and Tabari H. 2012. MLP-based drought forecasting in different climatic regions. Theoretical and Applied Climatology, 109(3-4): 407-414.
- 29- Specht D.F. 1991. A general regression neural network, Neural Networks, IEEE Transactions on, 2(6):568-576.
- 30- Thom H.C.S. 1958. A note on gamma distribution. Monthly Weather Review, 86: 117-122.
- 31- Vafakhah M., and Bashari M. 2011. Probability study of hydrological drought and wet period's occurrence using markov Chain in Kashafrood Watershed. Watershed Management Research (Pajouhesh & Sazandegi), 25(1): 1-9. (In Persian with English abstract)
- 32- Wilhite D.A., and Pulwarty R.S. 2005. Drought and water crises: lessons learned and the road ahead. Drought and water crises.
- 33- Wilhite D.A., Hayes M.J., Knutson C., and Smith K.H. 2000. Planning for Drought: Moving from Crisis to Risk Management. Journal of the American Water Resources Association, 36(4): 697-710.
- 34- Wilhite D.A., Svoboda M.D., and Hayes M.J. 2007. Understanding the complex impacts of drought: a key to enhancing drought mitigation and preparedness. Water Resources Management, 21(5): 763-774.
- 35- Zare-Zade-Mehrizi M., and Morid S. 2011. Application of Reservoir Level and Meteorological Indices for Drought Monitoring (Case Study: Zayandeh Rud Water System). Iranian Journal of Soil and Water Research, 1(42): 19-26.

Application of Statistical, Fuzzy and Perceptron Neural Networks in Drought Forecasting (Case Study: Gonbad-e Kavous Station)

S.M. Hosseini-Moghari^{1*} - Sh. Araghinejad²

Received: 26-07-2014

Accepted: 19-04-2015

Introduction: Due to economic, social, and environmental perplexities associated with drought, it is considered as one of the most complex natural hazards. To investigate the beginning along with analyzing the direct impacts of drought; the significance of drought monitoring must be highlighted. Regarding drought management and its consequences alleviation, drought forecasting must be taken into account (11). The current research employed *multi-layer perceptron (MLP)*, *adaptive neuro-fuzzy inference system (ANFIS)*, *radial basis function (RBF)* and *general regression neural network (GRNN)*. It is interesting to note that, there has not been any record of applying GRNN in drought forecasting.

Materials and Methods: Throughout this paper, *Standard Precipitation Index (SPI)* was the basis of drought forecasting. To do so, the precipitation data of Gonbad Kavous station during the period of 1972-73 to 2006-07 were used. To provide short-term, mid-term, and long-term drought analysis; SPI for 1, 3, 6, 9, 12, and 24 months was evaluated. SPI evaluation benefited from four statistical distributions, namely, *Gamma*, *Normal*, *Log-normal*, and *Weibull* along with *Kolmogrov-Smirnov (K-S)* test. Later, to compare the capabilities of four utilized neural networks for drought forecasting; *MLP*, *ANFIS*, *RBF*, and *GRNN* were applied. *MLP* as a multi-layer network, which has a sigmoid activation function in hidden layer plus linear function in output layer, can be considered as a powerful regressive tool. *ANFIS* besides adaptive neuro networks, employed fuzzy logic. *RBF*, the foundation of radial basis networks, is a three-layer network with Gaussian function in its hidden layer, and a linear function in the output layer. *GRNN* is another type of *RBF* which is used for radial basis regressive problems. The performance criteria of the research were as follows: Correlation (R^2), Root Mean Square Error (RMSE), Mean Absolute Error (MAE).

Results Discussion: According to statistical distribution analysis, the optimal precipitation distribution in many cases was not Gamma distribution. The various time-scales of *SPI* revealed that, at least in 50% of the events, Gamma was not the selected distribution. Throughout the drought forecasting on the basis of *SPI* time-series with four aforementioned networks, 80% of the data was allocated to the training process whilst the rest of them considered for the test process. The proper parameters of the networks were chosen via trial and error. Moreover, Cross-validation was used to overcome the over-estimation. The results revealed that the long-term *SPI*s outdid the others. Performance of the networks promoted with increases in time scales of *SPI*. In other words, the performance criteria improved proportional to the increases in the time-scales. Based on the Table 3, the least and best performance were contributed to *SPI1* and *SPI24*, respectively. In this regard, R^2 of *MLP* for observed and estimated values of *SPI* vitiated from 0.009 to 0.949. Similar to *MLP*, correlation of *ANFIS*, *RBF*, and *GRNN* increased from 0.021 to 0.925, 0.263 to 0.953, and 0.210 to 0.955. Comparison of observed and estimated mean values via *Z* test indicated that null hypothesis of equal mean observed and estimated values was only rejected for *SPI1* with $\alpha=0.01$. Hence, except *SPI1* forecasting, the all other scenarios have remained the mean of observed time series which highlighted the robustness of artificial intelligence in drought forecasting.

Conclusion: The main objective of the ongoing research was monitoring and forecasting of drought based upon various time scales of *SPI*. In doing so, the precipitation data of Gonbad Kavous station during the period of 1972-73 to 2006-07 were used. Based on *K-S* test, the best statistical distribution test for different time scales of *SPI* evaluation was chosen, and then, the *SPI* was calculated based on the most fitted distribution. After generating the time-series, *MLP*, *ANFIS*, *RBF*, and *GRNN* were applied for drought forecasting. According to the findings, the lowest performance of forecasting belonged to *SPI1* where its *RBF*'s best performance for R^2 , RMSE, and MAE were 0.263, 0.806, and 0.989. Furthermore, increases in *SPI* time-scale promoted the performance of networks. Thus, the worst and best performance belonged to *SPI1* and *SPI24*, respectively. Among the utilized models, *ANFIS* stood superior to the others, and *GRNN* followed up after it.

Keywords: Artificial Intelligence, *Generalized Regression Neural Network*, *Radial Basis Functions*, Standardized Precipitation Index

1, 2- Ph.D Student of Water Resources Engineering and Associate Professor, Department of Irrigation & Reclamation Engineering, University of Tehran

(*-Corresponding Author Email: Hosseini_SM@ut.ac.ir)