



"مقاله پژوهشی"

پیش‌بینی بارش پاییزه مبتنی بر الگوهای دورپیوندی حوزه دریای کاسپین

رضا نوروز ولاشدی^۱ و جلیل هلالی^۲

۱- استادیار گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ساری، ایران، (نویسنده مسوول: r.norooz@sanru.ac.ir)

۲- دانش‌آموخته دکتری گروه آبیاری و آبادانی، دانشکده مهندسی و فناوری کشاورزی، پردیس کشاورزی دانشگاه تهران، کرج، ایران

تاریخ دریافت: ۱۳۹۹/۵/۲۲ تاریخ پذیرش: ۱۳۹۹/۷/۷

صفحه: ۲۲۸ تا ۲۳۵

چکیده مبسوط

مقدمه و هدف: الگوهای دورپیوندی یکی از عوامل مؤثر هیدروکلیماتولوژیکی در پیش‌بینی بارش، دما و دبی در مقیاس بزرگ می‌باشند. از طرفی، مدیریت جامع و یکپارچه منابع آب ایجاب می‌کند که بتوان متغیرهای بارشی و در نتیجه دبی حاصل از رواناب آن را پیش‌بینی نمود. الگوهای دورپیوندی از دیدگاه دینامیکی و سینوپتیکی می‌توانند بر الگوی بارشی مناطق مختلف مؤثر باشند. هدف از این پژوهش بررسی ارتباط دقیق این شاخص‌ها با بارش پاییزه حوزه دریای کاسپین و پیش‌بینی آن با استفاده از مدل‌های آماری است.

مواد و روش‌ها: بر این اساس در این مطالعه زیرحوضه‌های دریای کاسپین انتخاب شده و بارش فصل پاییز در دوره ۲۸ ساله ۱۹۸۷ تا ۲۰۱۵ محاسبه شد. سپس همبستگی شاخص‌های SOI، MEI، NAO، NCP، AO، CSST، P-SST، MSST با بارش پاییزه در گام‌های زمانی July، Aug، Sep، Oct، Nov، Aug-Sep-Oct، Summer و Sep-Oct-Nov محاسبه و مهم‌ترین آن‌ها که بالاترین همبستگی را داشتند به‌عنوان ورودی به مدل‌های مختلف در نظر گرفته شد. در نهایت پیش‌بینی بارش پاییزه با استفاده از یک مدل آماری و سه مدل هوش مصنوعی با ساختار متفاوت انجام شده است.

یافته‌ها: نتایج این پژوهش نشان داد الگوهای دورپیوندی متنوعی بسته به نوع زیرحوضه و گام زمانی تأثیرگذار بوده‌اند. نتایج پیش‌بینی نشان داد اختلاف داده‌های مشاهداتی و مدل شده در دوره آموزش ناچیز و در دوره آزمون تا حدودی افزایش یافته و به حدود ۲۵/۷- تا ۴۷/۶ میلی‌متر در کل زیرحوضه‌ها رسیده است. بررسی نوع مدل پیش‌بینی کننده اثبات نمود دو مدل SVR و MLP دقت بالاتری از دو مدل GRNN و MLR داشته‌اند به‌طوری‌که جذر میانگین مربعات خطا به‌وسیله مدل SVR در زیرحوضه‌های ارس، اترک، هراز-سفیدرود، قره‌سو-گرگان، هراز-قره‌سو، سفیدرود و تالش به ترتیب ۰/۳۴، ۰/۴۴، ۰/۲۵، ۰/۱۸، ۰/۶۸، ۰/۱۷ و ۰/۲۲ میلی‌متر و ضریب تبیین نیز به ترتیب ۰/۹۴، ۰/۹۱، ۰/۹۲، ۰/۸۴، ۰/۸۸، ۰/۸۸ و ۰/۸۷ بود.

نتیجه‌گیری: به طور کلی نتایج به دست آمده نشان از ارتباط قوی بین شاخص‌های دورپیوندی با بارش پاییزه در حوزه مورد مطالعه دارد. از جمله آن‌ها می‌توان به شاخص‌های AO، SOI، NAO و دمای سطح دریای کاسپین و مدیترانه در تأخیرهای زمانی مختلف اشاره نمود. با این نتایج می‌توان جهت پیش‌بینی و مدیریت دقیق‌تر منابع آبی حوزه دریای کاسپین گام برداشت.

واژه‌های کلیدی: الگوهای دور پیوندی، حوزه دریای کاسپین، مدل‌های آماری، SOI، MEI

مقدمه

بارش به‌عنوان یکی از مهم‌ترین متغیرهای اقلیمی و هیدرولوژیکی از اهمیت بالایی برخوردار است که پیش‌بینی و مدیریت آن در بخش‌های مختلف از جمله منابع آب و کشاورزی نقش مهمی بازی می‌کند. در این زمینه ارتباط بین بارش و الگوهای دور پیوندی در مطالعات متعددی مورد بررسی قرار گرفته است (۸،۳). این الگوها با تغییرات دما و فشار در پهنه‌های مختلف آبی موجب تغییر الگوهای بارشی و دمایی نیز می‌شوند (۵،۱۶). بنابراین محققان تلاش می‌کنند از طریق این متغیرها رفتار بارشی را مطالعه کنند (۱۰،۱۱،۱۵). این بررسی‌ها می‌تواند از طریق مدل‌های آماری ساده مثل رگرسیون (۱۰) تا مدل‌های پیچیده از قبیل مدل‌های خطی و غیر خطی (۱۷) و شبکه عصبی انجام شود (۱۳). مدل‌های آماری در ساخت مدل نسبتاً انعطاف‌پذیر بوده و بسته به طول دوره آماری و همچنین نوع داده‌های موجود دارای پتانسیل لازم جهت بهبود دوره پیش‌بینی هستند.

گستره جغرافیایی و اقلیمی ایران متنوع بوده و یکی از مهم‌ترین حوزه‌های آبریز آن حوزه دریای کاسپین با توان اکولوژیکی بسیار غنی متأثر از رطوبت ناشی از سطوح فوقانی جو رسیده از دریای مدیترانه، دریای سرخ و سیاه است (۱۴). مطالعه هلالی و همکاران (۸) نشان داده است درصد فراوانی همبستگی‌های معنادار الگوهای دور پیوندی با بارش زیرحوضه‌های دریای کاسپین بین ۳/۱ تا ۳۵/۹ درصد بوده که

عمدتاً دو شاخص SOI و MEI تابستانه هستند، بنابراین این الگوها پتانسیل مناسبی به‌عنوان متغیرهای پیش‌بینی کننده بارش در این حوزه دارند. همچنین شیوخی سوغانلو و موسوی‌بایگی (۱۸) در تعدادی از ایستگاه‌های حوزه دریای کاسپین نشان دادند الگوهای دور پیوندی AMM، Nino 1.2، TNA و WHWP دارای همبستگی معنادار با بارش هستند و پیشنهاد دادند که از این متغیرها برای مدیریت منابع آب استفاده شود. مطالعه مشابه خسروی و پودینه در جنوب شرقی کشور در استان سیستان و بلوچستان نشان داده است الگوهای PNA، PDO، Nino 4، EA، Nino 1، TSA، TNI و NAO تأثیر معناداری بر بارش‌های حدی این منطقه دارد. حوزه دریای کاسپین در واقع پر بارش‌ترین حوزه آبریز ایران (۹)، با فلور غنی جنگلی بوده (۳) و نقش بارش به‌ویژه نوع پاییزه آن در پایداری جنگل، محصولات کشاورزی پاییزه، و منابع آب سطحی و همچنین زیرزمینی غیرقابل‌اغماض است (۲۰). در حال حاضر این حوزه آبریز درگیر مسائل زیست‌محیطی بسیاری است که از آن جمله می‌توان به افزایش تراکم جمعیت، تهاجم آب‌های شور به آبخوان‌های ساحلی آب شیرین و همچنین آلودگی‌های زیست‌محیطی فراوانی اشاره نمود (۴). پیش‌بینی بارش پاییزه و احتمال جبران این خلأها را می‌توان از اهداف این مطالعه دانست. بنابراین در این مطالعه سعی گردید با استفاده از شاخص‌های دور پیوندی مؤثر بر اقلیم حوزه دریای کاسپین


نوع این داده‌ها و یکسان سازی از داده‌های روزانه ایستگاه‌های سازمان هواشناسی و ماهانه وزارت نیرو در ماههای مهر، آبان و آذر استفاده شد. برای انجام این مطالعه مقادیر بارش پاییزه ۷ زیرحوضه فوق در ۱۵۰ ایستگاه استخراج شد (شکل ۱). بعد از انتخاب ایستگاه‌های مورد مطالعه پالایش اولیه داده‌ها شامل همگنی و نرمال بودن آمار ایستگاه‌ها بررسی شد. سپس همبستگی آن‌ها با شاخص‌های دور پیوندی (توضیحات بیشتر در منابع ۸، ۱۳ و ۱۶) شامل Caspian Sea Surface، AO، NCP، NAO، SOI، MEI Mediterranean Sea Surface، Temperature (CSST) Persian Gulf Surface و Temperature (MSST) Temperature (PSST) در گام‌های زمانی August July، September، October، November، Summer، ASO، SON (Sep-Oct-Nov) و (Aug-Sep-Oct) در قالب ماتریس همبستگی ارائه شدند (جدول ۱).

و با کمک مدل‌های ساده تا پیچیده اقدام به پیش‌بینی بارش پاییزه گردد.

مواد و روش‌ها

منطقه مورد مطالعه و داده‌های مورد استفاده

این مطالعه در حوضه دریای کاسپین انجام شده است. دلیل انتخاب حوضه دریای کاسپین به دلیل اهمیت راهبردی این حوضه در زمینه کشاورزی، گردشگری و تراکم بالای جمعیت بوده است که موجب می‌شود اهمیت پیش‌بینی بارش و استفاده آن در مسائل مدیریتی استان دو چندان شود. این حوضه شامل ۷ زیرحوضه اصلی شامل ارس، سفیدرود، تالش، تالش-سفیدرود، هراز-قره‌سو، قره‌سو-گرگان و اترک است. به دلیل گستردگی کار از طول دوره آماری ۲۸ ساله در دوره ۱۹۸۷-۲۰۱۶ ایستگاه‌های سینوپتیک و اقلیم‌شناسی سازمان هواشناسی و باران‌سنجی شرکت مدیریت منابع آب ایران تحت نظر وزارت نیرو استفاده شد با توجه به متفاوت بودن



شکل ۱- نمایی از زیرحوضه‌های دریای کاسپین و موقعیت ایستگاه‌های مورد مطالعه

Figure 1. The Caspian Sea sub-basins and the location of the studied stations

جدول ۱- شاخص‌های دور پیوندی و مقیاس زمانی مورد استفاده به‌عنوان متغیرهای پیش‌بینی‌کننده

Table 1. Teleconnection indices and time scale used as predictor variables

شاخص دور پیوندی								مقیاس زمانی
C-SST	P-SST	M-SST	AO	NCP	NAO	MEI	SOI	
Jul-C-SST	Jul-P-SST	Jul-M-SST	Jul-AO	Jul-NCP	Jul-NAO	Jul-MEI	Jul-SOI	Jul
Aug-C-SST	Aug-P-SST	Aug-M-SST	Aug-AO	Aug-NCP	Aug-NAO	Aug-MEI	Aug-SOI	Aug
Sep-C-SST	Sep-P-SST	Sep-M-SST	Sep-AO	Sep-NCP	Sep-NAO	Sep-MEI	Sep-SOI	Sep
Oct-C-SST	Oct-P-SST	Oct-M-SST	Oct-AO	Oct-NCP	Oct-NAO	Oct-MEI	Oct-SOI	Oct
Nov-C-SST	Nov-P-SST	Nov-M-SST	Nov-AO	Nov-NCP	Nov-NAO	Nov-MEI	Nov-SOI	Nov
SUM-C-SST	SUM-P-SST	SUM-M-SST	SUM-AO	SUM-NCP	SUM-NAO	SUM-MEI	SUM-SOI	SUM
ASO-C-SST	ASO-P-SST	ASO-M-SST	ASO-AO	ASO-NCP	ASO-NAO	ASO-MEI	ASO-SOI	ASO
SON-C-SST	SON-P-SST	SON-M-SST	SON-AO	SON-NCP	SON-NAO	SON-MEI	SON-SOI	SON

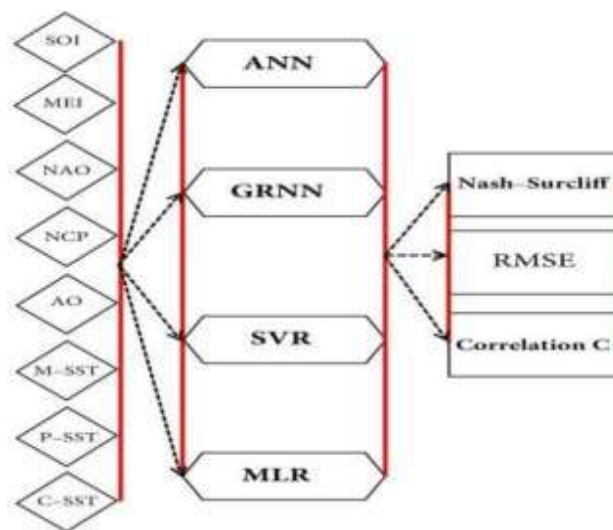
تابستان (SUM)، اوت-سپتامبر-اکتبر (ASO)، سپتامبر-اکتبر-نوامبر (SON)، دمای سطح خلیج فارس (SST-P)، خزر (SST-C)، مدیترانه (SST-M)

پیش‌بینی کننده به مدل معرفی شدند. مدل‌های مورد استفاده مدل مطابق جدول ۲ شامل شبکه عصبی پرسپترون چند لایه (MLP)، شبکه عصبی رگرسیون تعمیم یافته (GRNN)، رگرسیون بردار پشتیبان (SVR) و رگرسیون خطی چند متغیره (MLR) بودند، که ۷۰ و ۳۰ درصد داده‌ها برای آموزش و آزمون مدل‌ها استفاده شدند (۲).

پیش‌بینی بارش با استفاده از شاخص‌های دور پیوندی
به‌منظور پیش‌بینی مقدار بارش بر اساس شاخص‌های دور پیوندی (مقادیر ماهانه و فصلی شاخص در تابستان) می‌توان از مدل‌های مختلف در یک طرحواره (۸،۱۵) مطابق شکل ۲ استفاده نمود. ابتدا متغیرهای پیش‌بینی کننده بر اساس روش ماتریس همبستگی انتخاب و در بخش نتایج ارائه شد. در نهایت سه متغیر اول بر اساس روش گام‌به‌گام به‌عنوان جدول ۲- نام و خصوصیات مدل‌های پیش‌بینی کننده بارش

Table 2. Characteristics of precipitation forecasting models

نام اختصاری	نام کامل	نوع پارامترهای بهینه‌شده
ANN	شبکه عصبی مصنوعی	تعداد لایه پنهان، تعداد نورون و نوع تابع انتقال
GRNN	شبکه عصبی رگرسیون تعمیم یافته	پارامتر تنظیم مدل (پارامتر سیگما)
SVR	رگرسیون بردار پشتیبان	نوع تابع کرنل، پارامترهای تابع کرنل و پارامتر تنظیم مدل (پارامتر گاما)
MLR	رگرسیون خطی چندگانه	ضریب متغیرهای پیش‌بینی کننده



شکل ۲- طرحواره پیش‌بینی بارش با استفاده از شاخص‌های دور پیوندی (۱۱،۲۰)
Figure 2. Precipitation prediction scheme using teleconnection indices (11,20)

$$R^2 = \frac{\sum_{i=1}^n (O_i - \bar{O})(S_i - \bar{S})}{\sqrt{\left(\sum_{i=1}^n (O_i - \bar{O})^2\right)\left(\sum_{i=1}^n (S_i - \bar{S})^2\right)}} \quad (۴)$$

که در آن NSE شاخص نش-ساتکلیف، S_i داده‌های شبیه‌سازی شده، O_i داده‌های مشاهده شده و \bar{O} متوسط داده‌های مشاهده شده است. با توجه به این آماره‌ها تغییرات RMSE و MBE هر قدر به صفر نزدیک‌تر باشد بهتر است. نوسانات NSE و R^2 نیز هر قدر به ۱ نزدیک‌تر باشد بهتر خواهد بود.

نتایج و بحث

نوع متغیر مؤثر بر بارش پاییزه

بر اساس نتایج به دست آمده از روش ماتریس همبستگی و روش گام‌به‌گام متغیرهای دور پیوندی مؤثر بر بارش پاییزه زیرحوضه‌های آبریز دریای کاسپین در جدول ۳ ارائه شده است. نتایج نشان می‌دهد الگوی مؤثر بر بارش پاییزه زیرحوضه ارس شاخص‌های NAO اوت و نوامبر و SOI اوت،

آماره‌های ارزیابی مدل پیش‌بینی کننده

در این مرحله، نتایج حاصل از مدل‌های مورد استفاده بر اساس چهار معیار ارزیابی خطا که روابط ریاضی آن در معادلات ۱ تا ۴ ارائه شده است، با نام‌های نش-ساتکلیف (NSE)، ریشه متوسط مربعات خطا (RMSE)، متوسط انحراف خطا (MBE) و ضریب تبیین (R^2) میان مقادیر متغیر مشاهداتی و مدل‌سازی شده و بهترین مدل انتخاب شدند (۱۲).

$$NSE = 1 - \frac{\sum_{i=1}^n (O_i - S_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (۱)$$

$$RMSE = \left[\frac{\sum_{i=1}^n (S_i - O_i)^2}{n} \right]^{0.5} \quad (۲)$$

$$MBE = \frac{1}{n} \sum_{i=1}^n (S_i - O_i) \quad (۳)$$

نسبت به مشاهده‌ای در مدل MLP تا ۱۰/۶- میلی‌متر است. ولی در دوره آزمون در همه زیرحوضه‌های شرقی در همه مدل‌های مورد استفاده اختلاف بارش قابل مشاهده است به طوری که در زیرحوضه اترک بین ۵/۳- تا ۷/۳ میلی‌متر، زیرحوضه قره‌سو-گرگان ۲۱/۷- تا ۱۷/۵ میلی‌متر و زیرحوضه هراز-قره‌سو ۲/۹- تا ۱۳/۰ میلی‌متر است. با توجه به میانگین بارش بالا در این بخش از حوضه دریای کاسپین اختلاف مشاهده شده قابل توجه نیست بنابراین می‌توان گفت مدل‌های مورد استفاده دقت کافی در پیش‌بینی بارش نشان می‌دهند که جزئیات بیشتر در ادامه بررسی خواهد شد (شکل ۳).

در زیرحوضه‌های غربی نیز اختلاف بین داده‌های مشاهده‌ای و مدل شده در دوره آموزش در همه زیرحوضه‌ها ناچیز بوده است (به‌استثناء زیرحوضه هراز-سفیدرود) ولی در دوره آزمون این اختلاف دیده می‌شود (به‌استثناء زیرحوضه سفیدرود) به طوری که در زیرحوضه هراز-سفیدرود ۲۵/۷- تا ۲۸/۱، زیرحوضه ارس ۷/۲- تا ۰/۶-، زیرحوضه سفیدرود ۲/۰- تا ۰/۰ و تالش ۲۴/۷- تا ۴۷/۶ میلی‌متر است. بنابراین در زیرحوضه‌های دریای کاسپین در مرحله آموزش خطای داده‌های مشاهده‌ای و مدل شده پایین بوده و در دوره آزمون تا حدودی افزایش می‌یابد که نسبت به متوسط بارش بالای این منطقه این اختلاف قابل ملاحظه نخواهد بود (شکل ۴).

زیرحوضه اترک شاخص‌های SOI اوت، AO سپتامبر و دمای سطح دریای مدیترانه در فصل تابستان، زیرحوضه هراز-سفیدرود شاخص‌های NAO نوامبر، AO سپتامبر و دمای سطح خلیج فارس در تابستان، زیرحوضه قره‌سو-گرگان دمای سطح دریای مدیترانه و کاسپین جولای و نوامبر و AO سپتامبر، حوضه هراز-قره‌سو SOI و دمای مدیترانه در جولای و دمای کاسپین در نوامبر، زیرحوضه سفیدرود شاخص‌های NAO نوامبر، MEI اکتبر و دمای سطح مدیترانه در سپتامبر، و در زیرحوضه تالش NAO نوامبر و AO تابستان و همچنین دمای سطح خلیج فارس در جولای خواهند بود. بنابراین در زیرحوضه‌های دریای کاسپین متغیرهای دور پیوندی متفاوت با تأخیر زمانی متغیر می‌توانند به‌عنوان متغیرهای پیش‌بینی کننده بارش پاییز باشند. این نتایج با تحلیل انجام شده توسط (۸) که تنها شاخص‌های MEI و SOI را بهترین متغیرهای پیش‌بینی کننده بیان کرده‌اند متفاوت بوده است.


مقایسه نتایج آموزش و آزمون

مقایسه نتایج به دست آمده نشان می‌دهد اختلاف بین بارش پاییز مشاهده شده و مدل شده در دوره آموزش ناچیز است (شکل ۳ زیرحوضه‌های شرقی، شکل ۴ زیرحوضه‌های غربی). بررسی نتایج نشان می‌دهد در زیرحوضه‌های شرقی اترک و قره‌سو-گرگان در دوره آموزش اختلاف زیادی بین داده‌های مشاهده‌ای و مدل شده وجود ندارد (در همه مدل‌ها) ولی در زیرحوضه هراز-قره‌سو اختلاف داده‌های مدل شده


جدول ۳- مهم‌ترین الگوهای دور پیوندی مؤثر بر پیش‌بینی بارش پاییزه زیرحوضه‌های دریای کاسپین

Table 3. The most important teleconnection patterns for autumn precipitation forecasting in Caspian sub-basins

متغیر ۳	متغیر ۲	متغیر ۱	زیرحوضه
Nov-NAO	Aug-SOI	Aug-NAO	ارس
SUM-M	Sep-AO	Aug-SOI	اترک
SUM-P	Sep-AO	Nov-NAO	هراز-سفیدرود
Sep-AO	Nov-C	Jul-M	قره‌سو-گرگان
Nov-C	Jul-SOI	Jul-M	هراز-قره‌سو
Sep-M	Oct-MEI	Nov-NAO	سفیدرود
SUM-AO	Nov-NAO	Jul-P	تالش



شکل ۳- مقایسه داده‌های مشاهده‌ای و مدل شده در دوره آموزش و آزمون در زیرحوضه‌های شرقی (۲۰ سال آموزش و ۸ سال آزمون)
Figure 3. Comparison of observational and modeled data during training and testing in the eastern sub-basins



شکل ۴- مقایسه داده‌های مشاهده‌ای و مدل شده در دوره آموزش و آزمون در زیرحوضه‌های غربی (۲۰ سال آموزش و ۸ سال آزمون)
Figure 4. Comparison of observational and modeled data in training and testing courses in western sub-basins

متناظر MBE نیز به ترتیب $-۰/۸۲$ ، $۲/۷۲$ ، $-۸/۲۸$ و $۳/۸۰$ میلی‌متر خواهد بود. با توجه به نتایج فوق بهترین مدل در برآورد و پیش‌بینی بارش حوضه قره‌سو-هراز مدل SVR است که اختلاف زیادی با سه مدل دیگر داشته است (جدول ۴).

زیرحوضه ارس

نتایج به دست آمده مشخص نمود مقدار ضریب تبیین مدل‌های SVR، MLP، GRNN و SVR به ترتیب $۰/۶۸$ ، $۰/۹۴$ ، $۰/۵۷$ ، $۰/۷۶$ ، ضریب RMSE به ترتیب $۱۳/۰۹$ ، $۱۳/۱۸$ ، $۱۶/۸۵$ و $۱۲/۰۸$ میلی‌متر، و ضریب NSE نیز به ترتیب $۰/۶۸$ ، $۰/۹۳$ ، $۰/۵۱$ و $۰/۷۵$ خواهد بود و از طرف دیگر مقدار MBE نیز به ترتیب $-۰/۳۷$ ، $-۰/۱۶$ ، $-۵/۸۱$ و $-۲/۱۶$ میلی‌متر خواهد بود. با توجه به نتایج فوق بهترین مدل در برآورد و پیش‌بینی بارش حوضه ارس در وهله اول مدل SVR بوده و مدل‌های GRNN، MLP و MLP در رتبه بعد قرار دارند. به این ترتیب در حوضه ارس مدل SVR بهترین پیش‌بینی بارش پاییزه را به دست می‌دهد (جدول ۴).

زیرحوضه هرآز-سفیدرود

نتایج به دست آمده مشخص نمود مقدار ضریب تبیین مدل‌های SVR، MLP، GRNN و SVR به ترتیب $۰/۵۷$ ، $۰/۹۲$ ، $۰/۶۰$ ، $۰/۵۸$ ، ضریب RMSE به ترتیب $۷۶/۶۷$ ، $۳۵/۴۴$ ، $۸۰/۰۶$ و $۸۷/۳۱$ میلی‌متر و ضریب NSE نیز به ترتیب $۰/۵۷$ ، $۰/۹۲$ ، $۰/۵۷$ و $۰/۴۸$ خواهد بود و از طرف دیگر مقدار MBE نیز به ترتیب $-۴/۶۱$ ، $۱۸/۰۳$ ، $۱۷/۵۷$ و $-۱۰/۰۷$ میلی‌متر خواهد بود. با توجه به نتایج فوق بهترین مدل در برآورد و پیش‌بینی بارش حوضه هرآز-سفیدرود نیز مدل SVR است که از نظر دقت اختلاف فاحشی با سه مدل دیگر نشان می‌دهد (جدول ۴).

زیرحوضه سفیدرود

نتایج به دست آمده مشخص نمود مقدار ضریب تبیین مدل‌های SVR، MLP، GRNN و SVR به ترتیب $۰/۷۵$ ،

بررسی دقت مدل‌ها به تفکیک زیرحوضه‌های شرقی و غربی زیرحوضه اترک

نتایج به دست آمده مشخص نمود مقدار ضریب تبیین مدل‌های SVR، MLP، GRNN به ترتیب $۰/۶۸$ ، $۰/۹۱$ ، $۰/۸۷$ ، $۰/۷۸$ ، ضریب RMSE به ترتیب $۱۳/۸۱$ ، $۷/۳۴$ ، $۸/۸$ و $۱۳/۳۴$ میلی‌متر و ضریب NSE نیز به ترتیب $۰/۶۷$ ، $۰/۹۱$ ، $۰/۸۷$ و $۰/۶۹$ خواهد بود و از طرف دیگر مقدار MBE نیز به ترتیب $۲/۰۹$ ، $-۱/۵$ ، $-۰/۹۴$ و $۱/۷۴$ میلی‌متر خواهد بود. با توجه به نتایج فوق بهترین مدل در برآورد و پیش‌بینی بارش حوضه اترک دو مدل SVR و MLP بوده و مدل‌های GRNN و MLP در رتبه بعد قرار دارند. به این ترتیب در حوضه اترک دو مدل SVR و MLP بهترین پیش‌بینی بارش پاییزه را به دست می‌دهد (جدول ۴).

زیرحوضه قره‌سو-گرگان

نتایج به دست آمده مشخص نمود مقدار ضریب تبیین مدل‌های SVR، MLP، GRNN به ترتیب $۰/۵۵$ ، $۰/۸۴$ ، $۰/۸۰$ ، $۰/۵۳$ ، ضریب RMSE به ترتیب $۲۶/۱۹$ ، $۱۸/۲۵$ ، $۱۹/۸۰$ و $۳۴/۵۹$ میلی‌متر، و ضریب NSE نیز به ترتیب $۰/۵۴$ ، $۰/۸۱$ ، $۰/۷۸$ و $۰/۳۲$ خواهد بود و از طرف دیگر مقدار MBE نیز به ترتیب $۵/۰۱$ ، $۵/۳۸$ ، $-۶/۴۲$ و $-۰/۲۷$ میلی‌متر خواهد بود. با توجه به نتایج فوق بهترین مدل در برآورد و پیش‌بینی بارش حوضه قره‌سو-گرگان دو مدل SVR و MLP است که اختلاف زیادی با دو مدل GRNN و MLP نشان می‌دهد (جدول ۴).

زیرحوضه قره‌سو-هرآز

نتایج به دست آمده مشخص نمود مقدار ضریب تبیین مدل‌های SVR، MLP، GRNN به ترتیب $۰/۷۵$ ، $۰/۸۸$ ، $۰/۸۱$ ، $۰/۶۷$ ، ضریب RMSE به ترتیب $۲۷/۵۵$ ، $۱۹/۵۸$ ، $۲۵/۳۴$ و $۳۷/۱۵$ میلی‌متر، و ضریب NSE نیز به ترتیب $۰/۷۵$ ، $۰/۸۷$ ، $۰/۷۹$ و $۰/۵۵$ خواهد بود که مقدار

تشکر و قدردانی

به این وسیله از سازمان هواشناسی کشور و شرکت مدیریت منابع آب ایران به دلیل در اختیار قرار دادن داده‌های مورد نیاز تشکر و قدردانی می‌گردد. همچنین از حمایت مالی معاونت پژوهشی دانشگاه علوم کشاورزی و منابع طبیعی ساری از محل طرح تحقیقاتی با کد ۰۱-۱۳۹۹-۰۲ تشکر و قدردانی می‌گردد.

امر اشاره نشده است هرچند در پژوهش هلالی و همکاران (۸) از دیدگاه حوضه‌ای این مهم را بررسی کرده‌اند و کارایی این شاخص‌ها و ارتباط آن بارش‌های حوضه‌های آبریز نشان داده‌اند. با توجه به نتایج به دست آمده پیشنهاد می‌شود در آینده تأثیر الگوهای دور پیوندی بیشتری بر بارش مورد مطالعه قرار گیرد و همچنین این بررسی به صورت فضایی و نه ایستگاهی انجام پذیرد.

منابع

1. Abbot, J. and J. Marohasy. 2012. Application of artificial neural networks to rainfall forecasting in Queensland, Australia. *Advances in Atmospheric Sciences*, 29(4): 717-730.
2. Araghinejad, S., *Data-driven modeling: using MATLAB® in water resources and environmental engineering*. Vol. 67. 2013: Springer Science & Business Media.
3. Asadi, H., S.M. Hosseini, O. Esmailzadeh and A. Ahmadi. 2011. Flora, Life form and chorological study of Box tree (*Buxus hyrcanus* Pojark.) sites in Khybus protected forest, Mazandaran. *Iranian Journal of Plant Biology*, 3(8): 27-40 (In Persian).
4. Binesh Barahmand, M., R. Nabizadeh and K. Nadafi. 2012. Qualitative analysis of coastal waters in the Caspian Sea in Guilan Province: Determining the environmental health indicators in swimming areas. *Journal of Mazandaran University of Medical Sciences*, 22(88): 41-52 (In Persian).
5. Ghasemi, A. and D. Khalili. 2008. The effect of the North Sea-Caspian pattern (NCP) on winter temperatures in Iran. *Theoretical Applied Climatology*, 92(1-2): 59-74 (In Persian).
6. Ghasemieh, H., O. Bazrafshan and M.K. Bakhshayesh. 2017. Artificial Neural Network for Monthly Rainfall Forecasting Using Teleconnection Patterns (Case Study: Central Plateau Basin of Iran). *Journal of The Earth And Space Physics*, 43(2): 405-418 (In Persian).
7. Hejazizadeh, Z., E. Fatahi, M. Saligheh and F. Arsalani. 2013. Study on the Impact of climate signals on the Precipitation of the central of Iran using Artificial Neural Network. *Journal of Geographical Sciences*, 13(29): 75-89.
8. Helali, J., E. Pishdad, M. Alidadi, S. Loukazadeh, E. Asadi Oskouei and R. Norooz Valashedi. 2020. Investigation the relationship between climate Teleconnection Indices and Autumnal Rainfall in Iran Watersheds. *Iranian Journal of Soil and Water Research*, (DOI:10.22059/IJSWR.2020.294238.668434), (In Persian).
9. Khosravi, M. and M.R. Poodineh. 2010. A Survey on Climatic Impacts of Gonu Tropical Cyclone (June2007) in Southeast of Iran. *Physical Geography Research*, 42(72) (In Persian).
10. Kim, C.G., J. Lee, J.E. Lee, N.W. Kim and H. Kim. 2020. Monthly Precipitation Forecasting in the Han River Basin, South Korea, Using Large-Scale Teleconnections and Multiple Regression Models. *Water*, 12(6): 1590.
11. Mahdian, M. 2009. Autumn rainfall forecasting using ENSO indices by Neural Network method. *Watershed Management Researches*, 84: 42-52.
12. McCuen, R.H., Z. Knight and A.G. Cutter. 2006. Evaluation of the Nash-Sutcliffe efficiency index. *Journal of Hydrologic Engineering*, 11(6): 597-602.
13. Mekanik, F., M. Imteaz, S. Gato-Trinidad and A. Elmahdi. 2013. Multiple regression and Artificial Neural Network for long-term rainfall forecasting using large scale climate modes. *Journal of Hydrology*, 503: 11-21.
14. Mirmousavi, H., M. Darand and S. Ahmadpour. 2020. Identifying the moisture source of precipitation in the southern coasts of the Caspian Sea. *Theoretical Applied Climatology*: 1-9 p.
15. Modaresi, F., S. Araghinejad and K. Ebrahimi. 2015. Assessment of model fusion strategy for increasing the accuracy of autumn rainfall forecasting. *Journal of Agricultural Meteorology*, 3(2): 1-13 (In Persian).
16. Nazemosadat, M. and I. Cordery. 2000. On the relationships between ENSO and autumn rainfall in Iran. *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 20(1): 47-61.
17. Nozari, H. and F. Tavakoli. 2019. Evaluation of the Efficiency of Linear and Nonlinear Models in Predicting Monthly Rainfall (Case Study: Hamedan Province). *Journal of Watershed Management Research*, 10(20): 1-12 (In Persian).
18. Shiukhy, S. and M. Mousavi. 2019. The Effect of Large-Scale Climatic Signals on Rainfall in Mazandaran Province. *Journal of Watershed Management Research*, 10(20): 13-24 (In Persian).
19. Silverman, D. and J.A. Dracup. 2000. Artificial neural networks and long-range precipitation prediction in California. *Journal of Applied Meteorology*, 39(1): 57-66.
20. Yousefi, K. 2007. A study on the interactive impact of tree's aerial parts and physical factors in rain production. *Iranian Journal of Natural Resources*, 60(1): 115-126 (In Persian).

Caspian Sea Basin Autumnal Precipitation Forecasting Based on Teleconnection Patterns

Reza Norooz Valashedi¹ and Jalil Helali²

1- Assistant Professor in Agrometeorology, Water Engineering Department, Sari Agricultural Sciences and Natural Resources University, Sari, Iran, (Corresponding Author: r.norooz@sanru.ac.ir)

2- Graduated Ph.D., Department of Irrigation and Reclamation Engineering, faculty of agricultural engineering and technology, University of Tehran, Karaj, Iran

Received: 12 August, 2020 Accepted: 28 September, 2020

Extended Abstract

Introduction and Objective: Teleconnection patterns are one of the effective hydro-climatological factors in predicting precipitation, temperature and discharge on a large scale. Oppositely, comprehensive and integrated management of water resources requires that rainfall variables and consequently runoff flow can be predicted. From a dynamic and synoptic approach, teleconnection patterns can affect the precipitation pattern of different regions. The purpose of this study is to inspect the relationship between these indicators and autumn rainfall in the Caspian Sea basin and forecast it using various statistical models.

Material and Methods: Therefore, in this study, Caspian Sea sub-basins were selected and autumn rainfall in the 28-year period from 1987 to 2015 was calculated. Then the correlation of MEI, SOI, NCP, NAO, AO, CSST, P-SST and MSST indices with autumn rainfall in July, Aug, Sep, Oct, Nov, summer, Aug-Sep-Oct and Sep-Oct-Nov was calculated. And the most important ones that had the highest correlation were considered as inputs to different models. Finally, autumn rainfall forecasting was done using a statistical model and three artificial intelligence models with different structures.

Results: The study showed that various teleconnection patterns were effective depending on the type of sub-basin and time step. Prediction results showed that the difference between observational and modeled data in the training period was small and increased somewhat in the test period and reached about -25.7 to 47.6 mm in the whole sub-basins. Thoughtfulness of the type of analytical model showed that both SVR and MLP models had higher accuracy than GRNN and MLR models, so that the Root Mean Square Error by SVR model in Aras, Atrak, Haraz-Sefidrood, Qarahsu-Gorgan, Serazod-Haraz, and Haraz-Qarahsu sub-basins. 6.18, 7.34, 35.44, 18.25, 19.58, 17.68 and 47.22 mm, respectively, and the coefficient of determination will be 0.94, 0.91, 0.92, 0.84, 0.88, 0.88 and 0.87, respectively.

Conclusion: Therefore, the results show a strong relationship between teleconnection indices with autumn rainfall in the study basin. These include NAO, SOI, AO and Caspian and Mediterranean Sea surface temperatures at different time delays. With these results, steps can be taken to more accurately predict and manage the water resources of the Caspian Sea basin.

Keywords: Caspian Sea Sub-Basin, MEI, SOI, Statistical Models, Teleconnection Patterns