



پیش بینی جریان رودخانه با استفاده از روش K - نزدیک ترین همسایگی

کبری مومنی^۱، محمد رضا یزدانی^۲، علی اصغر ذوالفقاری^۲، محمد رحیمی^۲، سیدحسن کابلی^۲
۱- دانشجوی کارشناسی ارشد بیابان زدایی دانشگاه سمنان، ۲- استادیاران دانشکده کویرشناسی دانشگاه سمنان

چکیده

دستیابی به روش های مطمئن پیش بینی جریان رودخانه ها به منظور برنامه ریزی در بهره برداری به موقع از منابع آب از اهمیت روزافزونی برخوردار است. با توجه به اهمیت پیش بینی جریان رودخانه در مدیریت منابع آب روش های مختلفی برای مدل کردن جریان رودخانه ها بکار برده می شوند. در این تحقیق از روش غیر پارامتریک KNN برای پیش بینی جریان رودخانه های چناران و درکش در استان خراسان شمالی استفاده شده است. برای دستیابی به بهترین پیش بینی ۶ سناریو با استفاده از روش KNN مورد آزمون قرار گرفته است که با توجه به کمترین مجذور میانگین مربعات خطا (RMSE) و بیشترین کارایی مدل (EF) و ضریب همبستگی (R)، بهترین سناریو برای پیش بینی استخراج گردید.

واژه های کلیدی: K - نزدیک ترین همسایگی، جریان رودخانه، سناریو.

مقدمه

افزایش تقاضا برای آب در مناطق مختلف، نیاز به مدیریت بهینه منابع آب را بیش از پیش نشان می دهد. پیش بینی دقیق و به موقع منابع آب در دسترس را می توان نکته کلیدی در برنامه ریزی، مدیریت و بهره برداری بهینه از منابع آب قلمداد کرد. بر این پایه دستیابی به روش های مطمئن پیش بینی جریان رودخانه ها به منظور برنامه ریزی در بهره برداری به موقع از منابع آب از اهمیت روزافزونی برخوردار است (فتاحی، ۱۳۹۱). جهت طراحی بهینه و قابل اعتماد سیستم هایی مانند مخازن سدها و برنامه ریزی کارآمد در مدیریت منابع آب، تخمین صحیح آینده رودخانه اهمیت زیادی دارد (سیواکومار و همکاران، ۲۰۰۲). پیش بینی جریان رودخانه ها با توجه به اهمیت آن در طراحی تأسیسات آبی، آبیگری از رودخانه ها، برنامه ریزی بهره برداری از مخازن سدها، کنترل فرسایش و رسوب رودخانه ها و غیره از دیرباز مورد توجه مهندسان آب بوده است. از سوی دیگر با توجه به محدودیت منابع آب شیرین قابل استحصال، پیش بینی هر چه دقیق تر دبی جریان و تغییرات آن در طول رودخانه از ارکان اساسی برنامه ریزی و مدیریت منابع آب های سطحی است. تاکنون روابط و الگوهای گوناگون و پیچیده ای برای پیش بینی میزان آبدی رودخانه ها ارائه شده است (داننده مهر، ۱۳۸۹).

یکی از روش های که برای تولید داده های آب و هوایی مورد استفاده قرار می گیرد، روش KNN^{۱۰۵} است که برای تولید مصنوعی داده های آب و هوایی استفاده شده است. الگوریتم K- نزدیک ترین همسایگی، یکی از مهم ترین و توسعه یافته ترین رویکردهای غیر پارامتریک می باشد که در بسیاری از پژوهش های نوین به کار گرفته شده است (جلالی و همایی، ۱۳۹۰). در تحقیق راجاگوپالان (۱۹۹۹) روش نزدیک ترین K- همسایگی (KNN) با مدل سری زمانی پارامتری مقایسه شد که برتری روش K - نزدیک ترین همسایه به اثبات رسید. در مطالعه قربانی (۱۳۹۳) مدل KNN نسبت به دو روش ماشین بردار پشتیبان (SVM)^{۱۰۶} و درخت تصمیم (M5) در ریزمقیاس نمایی بارش بر اساس داده های مدل گردش عمومی NCEP در ایستگاه سینوپتیک کرمانشاه کارایی بهتری داشته است. عزمی و عراقی نژاد (۱۳۹۰) برای پیش بینی جریان رودخانه در محدوده حوضه بالادست زاینده رود از روش رگرسیون K- نزدیک ترین همسایگی استفاده کردند. نتایج آن ها نشان داد که KNN بهبود یافته دارای عملکرد بهتری بوده است.

مواد و روش ها

در این تحقیق به منظور پیش بینی جریان رودخانه توسط مدل K- نزدیک ترین همسایگی، از آمار دو ایستگاه هیدرومتری و ۱۳ ایستگاه بارانسنجی و ۲ ایستگاه تبخیرسنجی در استان خراسان شمالی با طول دوره ی آماری مشترک ۳۰ سال (۱۳۶۰-۱۳۸۹) استفاده شده است. ۷۰ درصد از داده ها (۲۱ سال) جهت آموزش مدل و ۳۰ درصد باقی مانده (۹ سال) برای آزمون مدل بکار گرفته شد. همچنین برای دستیابی به بهترین پیش بینی از دبی، سناریو های مختلفی طراحی و مورد آزمون قرار گرفت که در جداول ۱ نشان داده شده است.

جدول ۱- سناریو های مورد آزمون برای رودخانه چناران

^{۱۰۵} - K-Nearest Neighbor
^{۱۰۶} - Support Vector Machine



چهاردهمین کنگره علوم خاک ایران - فیزیک خاک و رابطه آب، خاک و گیاه

ساختار	تابع
S_1	$Q = f(P_1, P_2, P_3, P_4, P_5, P_6, P_7, T_1, T_2, T_3, T_4)$
S_2	$Q = f(P_1, P_2, P_3, P_4, P_5, P_6, P_7)$
S_3	$Q = f(P_1, P_2, P_3, P_4, P_5, P_6, P_7, Q_{(t-1)})$
S_4	$Q = f(P_{1(t-1)}, P_{2(t-1)}, P_{3(t-1)}, P_{4(t-1)}, P_{5(t-1)}, P_{6(t-1)}, P_{7(t-1)})$
S_5	$Q = f(SPI_1, SPI_2, SPI_3, SPI_4, SPI_5, SPI_6, SPI_7, T_1, T_2, T_3, T_4)$
S_6	$Q = f(SPI_1, SPI_2, SPI_3, SPI_4, SPI_5, SPI_6, SPI_7, Q_{(t-1)})$

K- نزدیک ترین همسایگی (KNN)

یکی از روش های مدل سازی در داده کاوی، الگوریتم K- نزدیک ترین همسایگی است. این الگوریتم جزء روش های یادگیری نظارت شده است که در پیش بینی استفاده می شود. در این تکنیک، تعداد بهینه ای از نمونه های موجود در یک مجموعه که دارای شبیه ترین ویژگی ها به نمونه هدف باشند (K) در نظر گرفته می شود و سپس جایابی و طبقه بندی عنصر هدف در این مجموعه از داده ها، با تعیین فاصله ها و سپس وزن دهی عناصر آموزش دهنده صورت می پذیرد.

در یک بانک داده مرجع دبی، نزدیک ترین (مشابه ترین) دبی ها به دبی مورد آزمون انتخاب و این دبی ها با توجه به میزان مشابهت به دبی مورد آزمون وزن دهی می شوند. به این ترتیب که در ابتدا فواصل اقلیدسی بین دبی مورد آزمون و دبی های مرجع محاسبه شده، سپس تعداد K عدد از نزدیک ترین دبی ها بر اساس فاصله به دست آمده، وزن دهی می شوند. در انتها با توجه به وزن هر یک از دبی در مجموعه ای با K عدد دبی (نزدیک ترین همسایه)، برآوردی از داده های هدف که مورد آزمون واقع شده اند، صورت می پذیرد (نمس و همکاران، ۲۰۰۶). در این تحقیق فاصله اقلیدسی بین نمونه های هدف با هریک از نمونه ها در بانک داده مرجع از رابطه زیر بدست آمد:

$$d_i = \sqrt{\sum_{j=1}^x \Delta a_{ij}^2} \quad (1)$$

که در آن، d_i نشان دهنده فاصله i امین دبی از بانک داده مرجع تا دبی هدف می باشد. Δa_{ij} : اختلاف فاصله دبی هدف، از i امین دبی و j امین متغیر موجود در بانک داده مرجع می باشد و x : تعداد متغیر ورودی نمونه های دبی (مانند بارندگی و دما) است. در اینجا منظور از فاصله، میزان شباهت و نزدیکی دو نمونه مورد نظر می باشد. به طوری که هرچه مقدار به دست آمده از d_i کوچک تر باشد شباهت دو نمونه مورد نظر بیشتر است.

یکی از مشکلات موجود در استفاده از مدل KNN این است که یک واحد اختلاف در یک متغیر ممکن است که به اندازه یک واحد اختلاف در متغیر دیگر اهمیت نداشته باشد. به عنوان مثال در این تحقیق تغییر یک واحد در داده های دما به عنوان یک متغیر اهمیت کمتری نسبت به تغییر یک واحد در داده های دبی دارد. به همین منظور قبل از هر گونه محاسباتی، ابتدا داده های مورد استفاده در تحقیق با استفاده از رابطه ۲ استاندارد شد:

$$a_{ij(temp)} = \frac{[(a_{ij}) - \bar{a}_j]}{\sigma(a_j)} \quad (2)$$

که در آن، $a_{ij(temp)}$: مقدار عددی موقت استاندارد شده زامین صفت برای هریک از نمونه ها، a_{ij} : نماینده زامین متغیر از i امین دبی است. \bar{a}_j و $\sigma(a_j)$ به ترتیب میانگین و انحراف معیار مقادیر مشاهده ای از زامین متغیر در بانک داده های مرجع می باشد.

سپس مقادیر نهایی تبدیل شده زامین متغیر از i امین دبی $a_{ij(trans)}$ با توجه به دامنه کمترین تا بیشترین مقدار $a_{ij(temp)}$ از رابطه ۳ بدست آمد و بجای مقادیر اعداد واقعی به عنوان داده های ورودی مورد استفاده قرار گرفت (نمس و همکاران، ۲۰۰۶).

$$a_{ij(trans)} = \frac{[\max[\text{range}(a_{j=1(temp)}), \dots, \text{range}(a_{j=x(temp)})]]}{\text{range}(a_j(temp))} \quad (3)$$



چهاردهمین کنگره علوم خاک ایران - فیزیک خاک و رابطه آب، خاک و گیاه

در مرحله بعد، وزن دهی نمونه دبی‌های آموزش دهنده (K) بر اساس فاصله‌های به دست آمده بین دبی هدف و هر یک از دبی‌های تعیین شده در K طبق رابطه‌های ۴ صورت گرفت.

$$W_i = \frac{d_{i(rst)}}{\sum_{i=1}^K d_{i(rst)}} \quad (4)$$

که در آن، W_i : وزن i امین نمونه از دبی‌های آموزش دهنده (K) است و $d_{i(rst)}$ فاصله نسبی هدف و نمونه i ام می‌باشد که از رابطه ۵ بدست آمده است:

$$d_{i(rst)} = \left[\frac{\sum_{i=1}^K d_i}{d_i} \right]^P \quad (5)$$

در تحقیق نس و همکاران (۲۰۰۶) کمترین مقدار خطای تخمین در P های نزدیک به ۱ بدست آمده است که روش KNN به مقادیر مختلف P ، حساسیت اندکی داشته است. در این تحقیق بهترین مقدار P از تکنیک ارزیابی تقاطعی بدست آمد. پس از وزن دهی نمونه‌ها، برآورد مقادیر دبی در نمونه‌های هدف از طریق محاسبه میانگین وزنی دبی در نمونه دبی‌های K با استفاده از رابطه ۶ صورت گرفت.

$$P_i = \sum_{i=1}^K w_i o_i \quad (6)$$

که در آن، P_i : مقدار دبی پیش بینی شده دبی هدف، W_i : وزن مربوط به i امین دبی در K و O_i : مقدار دبی اندازه گیری شده i امین دبی در K است.

در آخرین مرحله، جهت ارزیابی و مقایسه سناریوهای مختلف در مدل از معیارهای مجذور میانگین مربعات خطا (RMSE)^{۱۷}، کارایی مدل (EF)^{۱۸} و ضریب همبستگی (R) استفاده شده است.

نتایج و بحث

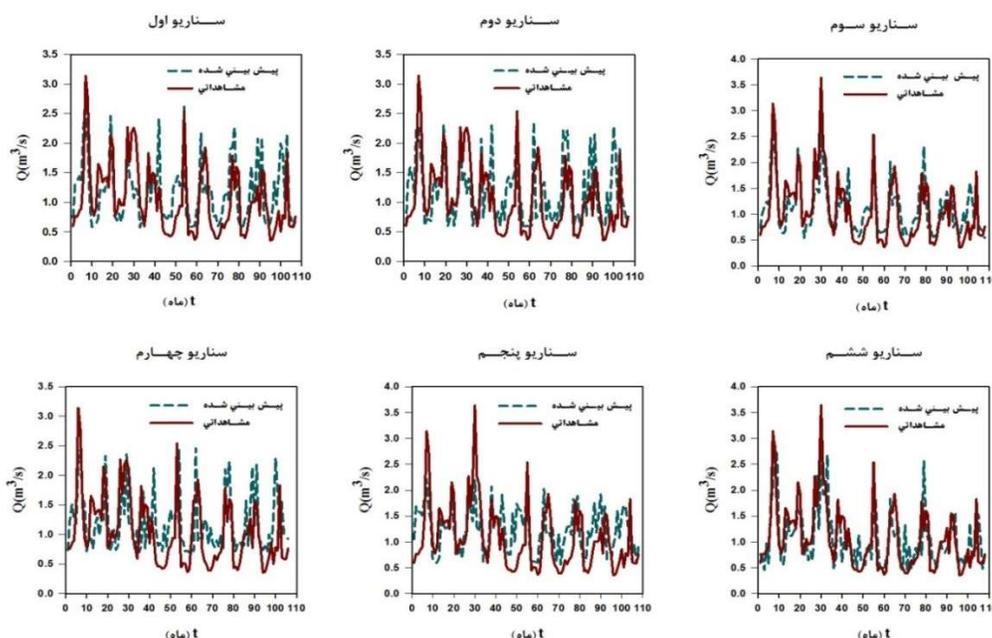
بهینه سازی هم زمان P و K به گونه ای انجام شد که به ازای هر مقدار P از ۱/۰ تا ۲ (با فاصله‌های ۰.۱) K های مختلف از ۱ تا ۳۰ در نظر گرفته شده و مقدار RMSE آن‌ها بدست آمده است. در این تحقیق با توجه به تعداد نمونه‌های بانک مرجع، مقدار خطای برآورد در دامنه ای از مقادیر مختلف K محاسبه شد و بر اساس روش ارزیابی تقاطعی، بهترین تعداد برای K ، زمانی که خطای تخمین‌ها (RMSE) به کمترین مقدار خود رسید تعیین گردید. نتایج تحقیق نشان داد، حساسیت روش KNN به مقادیر P اندک می‌باشد و تغییر مقدار P باعث تغییر بسیار اندکی در RMSE شده است. بنابراین مقدار P در این تحقیق ۱ در نظر گرفته شد. نتایج بدست آمده برای پیش بینی جریان رودخانه‌های چناران و درکش در جدول (۲) و شکل‌های (۱ و ۲) زیر نشان داده شده است.

^{۱۷}- Root Mean Square Error

^{۱۸}- Efficiency of Model

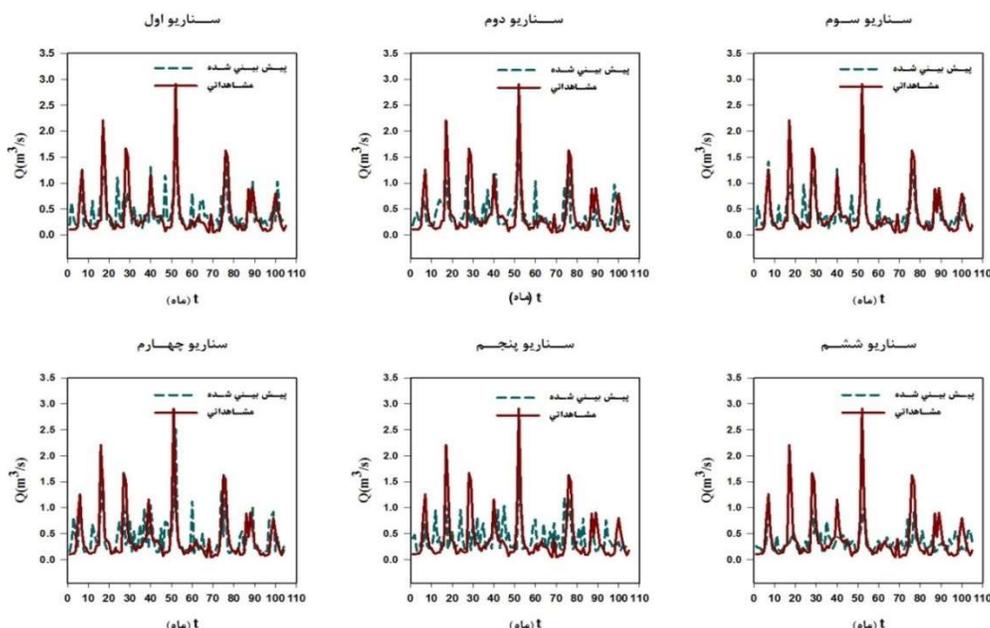
جدول ۲- نتایج سناریوهای مختلف برای پیش بینی جریان رودخانه های چناران و درکش

رودخانه درکش					رودخانه چناران				
R	EF	RMSE (m ³ /s)	K value	سناریو	R	EF	RMSE (m ³ /s)	K value	سناریو
۶۴/۰	۳۵/۰	۶۷/۰	۱۳	۱	۶۵	۳۶/۰	۵۰/۰	۲۵	۱
۵۵/۰	۲۷/۰	۷۲/۰	۹	۲	۵۹/۰	۲۶/۰	۵۴/۰	۲۵	۲
۷۴/۰	۴۴/۰	۶۳/۰	۱۴	۳	۷۹/۰	۶۳/۰	۳۸/۰	۱۳	۳
۵۳/۰	۲۷/۰	۷۲/۰	۱۱	۴	۴۷/۰	۱۱/۰	۵۹/۰	۲۷	۴
۴۶/۰	۱۹/۰	۷۵/۰	۱۴	۵	۵۴/۰	۲۱/۰	۵۶/۰	۲۶	۵
۴۵/۰	۱۴/۰	۷۸/۰	۱۴	۶	۶۹/۰	۴۴/۰	۴۷/۰	۱۳	۶



شکل ۱- نمودارهای نتایج مدل KNN برای سناریوهای مختلف در پیش بینی جریان رودخانه چناران

پس از بررسی ساختارهای مختلف ورودی برای پیش بینی دبی رودخانه چناران و محاسبه آماره های EF، RMSE و R، با توجه به جدول ۲ مشخص گردید که سناریو سوم بهترین پیش بینی را برای دبی داشته است. بنابراین می توان گفت جریان رودخانه چناران در یک ماه مشخص بیشتر به بارندگی در همان ماه و دبی در یک ماه قبل بستگی داشته است.



شکل ۲- نمودارهای نتایج مدل KNN برای سناریو های مختلف در پیش بینی جریان رودخانه درکش

نتایج مربوط به شکل ۲ و جدول ۲ نشان می‌دهد که در سناریو سوم، مجذور میانگین مربعات خطا (RMSE) $0.63/0$ ، کارایی مدل (EF) $0.44/0$ و ضریب همبستگی (R) 0.74 درصد بوده است. بنابراین سناریو سوم بهترین پیش بینی را برای جریان رودخانه درکش داشته است. در نتیجه جریان رودخانه درکش در هر ماه به بارندگی همان ماه و دبی ماه قبل وابستگی بیشتری داشته است.

منابع

- جلالی، و. و همایی، م. ۱۳۹۰. ارائه مدلی غیرپارامتریک با استفاده از تکنیک k- نزدیک‌ترین همسایه در برآورد جرم مخصوص ظاهری خاک. مجله علوم آب و خاک-علوم و فنون کشاورزی و منابع طبیعی. جلد ۱۵ شماره ۵۶ صفحات ۱۸۱-۱۹۱.
- داننده مهر، ع. مجدزاده طباطبائی، م. ۱۳۸۹. بررسی تأثیر توالی دبی روزانه در پیش بینی جریان رودخانه‌ها با استفاده از برنامه ریزی ژنتیک. نشریه آب و خاک (علوم و صنایع کشاورزی). جلد ۲۴، شماره ۲، صفحه های ۳۲۵-۳۳۳.
- عزمی، م. و عراقی، ش. ۱۳۹۰. توسعه روش رگرسیون K- نزدیکترین همسایگی در پیش بینی جریان رودخانه. نشریه آب و فاضلاب، شماره ۲، صفحه های ۱۰۸-۱۱۹.
- فتاحی، ا. دلاور، م. نوحی، ک. ۱۳۹۱. پیش بینی جریان رودخانه های کارون شمالی با استفاده از شبکه عصبی مصنوعی. فصلنامه تحقیقات جغرافیایی، جلد ۲۷. صفحه های ۵۱-۷۷.
- قربانی، خ. ۱۳۹۳. ارزیابی مدل های داده کاوی در ریزمقیاس نمایی بارش بر اساس داده‌های مدل گردش عمومی NCEP (مطالعه موردی: ایستگاه سینوپتیک کرمانشاه). مجله پژوهش آب ایران. سال ۸، شماره ۱۵، صفحه های ۱۷۷-۱۸۶.
- El-Shafie A, RedaTaha M and Noureldin A, ۲۰۰۷. A neuro-fuzzy model for inflow forecasting of the Nile river at Aswan high dam. *Water Resources Management* ۲۱: ۵۳۳-۵۵۵.
- Nemes, A., Rawls, W.J., and Pachepsky, Ya.A. ۲۰۰۶. Use of the nonparametric nearest neighbor approach to estimate soil hydraulic properties. *Soil Sci. Soc. Am. J.* ۷۰: ۳۲۷-۳۳۶.
- Rajagopalan, B. Lall, U. ۱۹۹۹. A k-nearest-neighbor simulator for daily precipitation and other weather variables. *WATER RESOURCES RESEARCH*, VOL. ۳۵, NO. ۱۰, PAGES ۳۰۸۹-۳۱۰۱.
- Sivakumar B, Jayawardena AW and Fernando TMKG, ۲۰۰۲. River flow forecasting: use of phase-space reconstruction and artificial neural networks approaches. *Journal of Hydrology* ۲۶۵: ۲۲۵-۲۴۵.
- Zahoor J. Abrar M. Bashir Sh. And Mirza A. ۲۰۰۹. Seasonal to inter-annual climate prediction using data mining KNN technique. *Wireless Networks, Information Processing and Systems, Communications in Computer and Information Science*. ۲۰: ۴۰-۵۱.



Abstract

Access to reliable methods to predict river flow is very important to timely utilization of water resources planning. Given the importance of predictability of river flow in water resources management, different methods is used to river flow modeling. In this study, non-parametric methods of K Nearest neighbor (KNN) was used to predict river flow in two basins of Chenaran and Darkesh in the Northern Khorasan province. To achieve the best forecast, 6 scenarios were analyzed using the KNN method. The best scenario was selected according to the lowest root mean square error (RMSE), the highest efficiency of model (EF) and correlation coefficient (R) of the best scenarios to prediction river flow.