

شبیه سازی بارش - رواناب با شبکه عصبی (مطالعه موردی: دشت نسا بم)

مهدی شاهرخی ساردو^۱، مجتبی جعفری کرمانپور^{۲*}

۱- استادیار، گروه مهندسی عمران، واحد، جیرفت، دانشگاه آزاد اسلامی، جیرفت، ایران.

*۲- استادیار، گروه مهندسی آب، دانشگاه شهید باهنر کرمان، m.jafari@eng.uk.ac.ir

چکیده

پیشینی رواناب به صورت کوتاه مدت به دلیل رابطه مستقیم آن با چگونگی تعامل مدیران با خطرات جانی ناشی از سیلابها، از اهمیت خاصی برخوردار است. در این تحقیق با استفاده از شبکه های عصبی مصنوعی، اقدام به شبیه سازی فرآیند بارش- رواناب به صورت روزانه، در حوزه آبخیز دشت نسا بم شده است. به منظور پیش بینی روند آبی بهره برداری از منابع آبی دشت مذکور، ترکیبات مختلفی از داده های بارش و دما و دبی و اختلاف دبی دو روز متوالی، مورد استفاده قرار گرفت. تعداد نرونهای لایه مخفی در شبکه عصبی بین 2 تا 10 نرون متغیر بود. معیارهای آماری متوسط ریشه مربع خطا RMSE، متوسط قدر مطلق خطا MAE و ضریب همبستگی R برای ارزیابی و مقایسه عملکرد شبکه های عصبی در پیشینی رواناب، مورد استفاده قرار گرفت. نتایج نشان داد با داشتن 2 ورودی و شبکه عصبی feedforward و یا 1 ورودی و شبکه newrbe بهترین عملکرد حاصل شده و فرآیند بارش- رواناب با دقت بالاتری پیشینی شده است.

واژه های کلیدی: شبیه سازی بارش- رواناب، شبکه عصبی مصنوعی، حوزه آبخیز دشت نسا بم

Precipitation-runoff Simulation with Neural Network(Case study: Nasa Bam Plain)

Abstract:

Short-term runoff forecasting is of particular importance due to its direct relationship with how managers interact with life risks caused by floods. In this research, by using artificial neural networks, simulation of rainfall-runoff process has been done on a daily basis in the Nasa Bam watershed. In order to predict the future process of using the water resources of the mentioned plain, different combinations of rainfall and temperature data and discharge and discharge difference of two consecutive days were used. The number of hidden layer neurons in the neural network varied between 2 and 10 neurons. The statistical criteria of root mean square error RMSE, mean absolute value of error MAE and correlation coefficient R were used to evaluate and compare the performance of neural networks in runoff forecasting. The results showed that by having 2 inputs and feedforward neural network or 1 input and newrbe network, the best performance was achieved and the rainfall-runoff process was predicted with higher accuracy.

Key words: rainfall-runoff simulation, artificial neural network, Nasa Bam watershed

در مدیریت منابع آب است. پیش بینی دبی میتواند به صورت بلندمدت یا کوتاه مدت باشد. در این بین پیش بینی کوتاه مدت دبی به صورت روزانه از اهمیت خاصی برخوردار است چرا که به

مقدمه


شبیه سازی جریان رودخانه به منظور آگاهی از آورد رودخانه در دوره های زمانی آینده از مسایل مهم و کاربردی

منطقه ی مورد مطالعه انتخاب شده است. در مرحله ی تایید مدل ANFIS پیش بینی مدل ARMA را با 06/6 درصد و 12/20 درصد کاهش در مقادیر RMSE و MAPE بهبود می بخشد. مطالعات نشان می دهد مدل ANFIS، GP و SVM در مدل سازی دبی ماهانه مناسب می باشند طالعی و همکاران (2012) تاخیرات زمانی در مدل سازی بارش- رواناب در یک حوضه ی آبریز در سنگاپور را با استفاده از مدل انفیس مورد مطالعه قرار داده اند. عملکرد انفیس را با ANN4, SWMM5 مورد مقایسه قرار داده اند. نتایج نشان می دهد، مدل انفیس نتیجه ی مطلوب تری در پیش بینی دبی پیک از خود نشان داده است. به عبارتی دیگر، انفیس نتایج بهتری را در مقایسه با مدل SWMM از خود نشان می دهد. بدرزاده و همکاران، (2015) از مدل های شبکه عصبی مصنوعی، سیستم های استنتاج عصبی فازی تطبیقی، شبکه های عصبی موجک و ترکیب سیستم های استنتاج عصبی فازی تطبیقی با موجک را جهت پیش بینی رواناب استفاده کرده اند. تمامی مدل ها به طور قابل ملاحظه ای تا حداکثر 12 ساعت زمان مورد استفاده قرار گرفته شده اند. نتایج نشان می دهد مدل های پایه ای موجک به طور قابل توجهی نتایج بهتری نسبت به شبکه عصبی و سیستم های فازی در پیش بینی های طولانی مدت از خود نشان داده اند. در تحقیق پیش رو از شبکه عصبی , newrb feedforward با تعداد داده های مختلف برای شبیه سازی بارش- رواناب دشت نسا بم استفاده شده و کدهای مختلف در جهت دستیابی به دقیقترین شبیه سازی، مورد ارزیابی قرار گرفته است.

مواد و روش ها

منطقه ی مورد مطالعه و اطلاعات مورد استفاده

صورت مستقیم بر نحوه تعامل مدیران با خطرات جانی ناشی از سیلابها اثرگذار است. این پیش بینی نوعی سیستم هشدار سیلاب را برای ساکنان حوزه آبخیز و ساکنان حوزه های پایین دست فراهم میکند و به مدیران فرصتی برای تخلیه ساکنان مناطق در معرض سیل میدهد. با توجه به این که مدل های مفهومی اغلب نیازمند دانش صحیح و کامل در مورد راهکارهای فیزیکی اثرگذار بر روی جریان رودخانه هستند و این امر تاکنون برای بشر ممکن نشده است، پژوهشگران به استفاده از مدل های روی آورده اند که با توجه به رفتار گذشته سیستم، رفتار سیستم در زمان آینده را پیش بینی نماید که به این مدل ها، مدل های مبتنی بر داده یا مدل های آماری اطلاق می شود. در بین مدل های آماری، سیستم های هوشمند به دلیل استفاده از الگوریتم های خاص و پیچیده، قابلیت های مناسبی برای پیش بینی پدیده های پیچیده و غیر خطی مانند رواناب از خود نشان داده اند. با گسترش روز افزون کاربردهای مبتنی بر هوش مصنوعی در دو دهه ی اخیر، استفاده از شبیه سازی های متکی بر شبکه های عصبی مصنوعی به طور گسترده ای در مباحث مربوط به پیش بینی فراسنجهای مختلف منابع آب مورد استفاده قرار گرفته، و محققان مختلف به دقت بالای این روش در مقایسه با شبیه های گروه زمانی تاکید نموده اند. در ادامه به تعدادی از این تحقیقات اشاره می گردد: وانگ و همکاران (2009) از مدل های ANN شبیه سازی و مقایسه ی برآورد رواناب به روش های شبکه عصبی، رگرسیون و استنتاج فازی جهت پیش بینی دبی ماهانه استفاده کرده اند و نتایجش با مدل ARMA3 مورد مقایسه قرار داده شده است. در مطالعه ی فوق الذکر، نیروگاه آبی manwan در رودخانه ی ancangiang به عنوان




شکل 1: موقعیت دشت نسا بم

شبکه عصبی مصنوعی


شبکه عصبی مصنوعی، سیستمی است که با پردازش روی داده های موجود، رابطه ی نهفته بین داده ها را شناسایی می کند و هدف از آموزش شبکه عصبی این است که شبکه قانون کار را یاد بگیرد و پس از آموزش به ازای هر ورودی، خروجی مناسب را ارائه دهد. یکی از مهم ترین مراحل در مدل سازی، انتخاب الگوی مناسب از متغیرهای ورودی است. میانگین دبی ماهانه در ایستگاه هواشناسی یالخری بر روی رودخانه نسا را با استفاده از شبکه عصبی مصنوعی منتخب و بر اساس 4 متغیر مستقل ثبت شده در ایستگاه (شامل: سال، ماه، میانگین درجه حرارت ماهانه و میانگین بارش ماهانه) به عنوان ورودی به شبکه، پیش بینی شده است. داده های موجود در سال های آبی 79 - 78 تا 94 - 95، دارای همپوشانی هستند. چندین ترکیب از داده های ورودی انتخاب شده است. ابتدا پیش بینی دبی رودخانه با تنها یک ورودی میزان بارندگی پرداخته شده است (feedforward). در مراحل بعدی، علاوه بر ورودی بارندگی، یک ورودی دیگر که اختلاف بین دبی دو ماه متوالی است نیز اضافه شده است. در این حالت، دقت شبیه سازی افزایش یافته

منطقه مورد مطالعه قسمتی از حوضه رودخانه نسا واقع در بخش جنوبی آبخوان بم بنام دشت نسا می باشد. موقعیت جغرافیایی آن بین طول 57 درجه و 37 دقیقه تا 59 درجه و 29 دقیقه شرقی و 28 درجه و 25 دقیقه تا 29 درجه و 26 دقیقه عرض شمالی قرار گرفته است که در شکل 1 نشان داده شده است. ارتفاع متوسط دشت از سطح دریا حدود 800 متر است. منطقه مورد مطالعه دارای تابستان های گرم و طولانی و زمستان های نسبتاً معتدل است. این منطقه در مناطق کویری ایران قرار گرفته و جزء مناطق خشک و نیمه گرمسیری به شمار می رود. مساحت کلی این محدوده مطالعاتی 9658/18 کیلومترمربع است که از این مقدار سهم دشت و ارتفاعات به ترتیب 6032/79 و 3625/39 کیلومترمربع می باشد. در این محدوده مطالعاتی بر اساس پراکندگی چاه های مشاهده ای و بهره برداری و با در نظر گرفتن پهنه هایی که دارای مطالعات ژئوفیزیک هستند، یک آبخوان آبرفتی تشخیص داده شده است. آبخوان بم-نرماشیر دارای مساحت 3883/71 کیلومترمربع می باشد [وزارت نیرو، 1396]. محاسبات بیلان در این محدوده مطالعاتی در سطح آبخوان آبرفتی انجام گردیده که نتایج آن در بخش های مربوطه ارائه شده است. رواناب های این محدوده پس از گذر از مخروط افکنه رودها و دشت، از شرق خارج شده و وارد محدوده مطالعاتی دق کهورک می شود.



شکل 3:

در فایل 3 با وجود این که تنها یک ورودی داریم، اختلاف بین مقادیر پیش بینی و واقعی تقریباً مانند فایل 2 است. زیرا شبکه عصبی newrbe عملکرد بسیار بهتری دارد. در نتیجه با داشتن 2 ورودی و شبکه عصبی feedforward و یا 1 ورودی و شبکه newrbe بهترین عملکرد را خواهیم داشت (شکل 4).



شکل 4:


نتایج و بحث

در نهایت برای ارزیابی عملکرد مدل در برآورد رواناب ماهانه، برخی معیارهای اساسی از جمله ضریب همبستگی، ریشه میانگین مربعات خطا و ضریب نش-ساتکلیف مورد استفاده قرار گرفته اند. هر شبیه سازی، مقداری خطا را

است. پس از سعی و خطاهای مختلف، شبکه دارای 5 لایه مخفی انتخاب شده است. یک لایه خروجی نیز به صورت پیش فرض به آن اضافه می شود. در برخی مدل ها شبکه newrbe جایگزین feedforward شده است. خلاصه مدل ها در 4 حالت مقایسه شده است:

- فایل 1: prediction_1_input_ff.m
- فایل 2: prediction_2_inputs_ff.m
- فایل 3: prediction_1_input_newrbe.m
- فایل 4: prediction_2_inputs_newrbe.m

ملاحظه شده است که برای فایل 1، دقت پیش بینی ها اصلاً خوب نیست و نقاط قرمز (پیش بینی) اختلاف زیادی با نقاط آبی (واقعی) دارند (شکل 2).




شکل 2:

در فایل 2 به دلیل اضافه شدن ورودی دوم، ملاحظه می گردد که دقت بسیار بالاتر رفته است و نقاط قرمز خیلی بیشتر از حالت قبل به نقاط آبی نزدیک شده اند (شکل 3).


$$\begin{aligned} \text{MSE}_{tr} &= & R^2_{tr} &= \\ &0.0967 & &0.9577 \end{aligned}$$

$$\begin{aligned} \text{MSE}_{ts} &= & R^2_{ts} &= \\ &0.0302 & &0.9492 \end{aligned}$$

در شکل های 5 و 6 میزان همبستگی بین دبی پیش‌بینی شده و میزان دبی واقعی در فرایند آموزش و ارزیابی نشان داده شده است.



شکل 5: میزان همبستگی بین میزان دبی پیش‌بینی شده و میزان دبی واقعی در فرایند آموزش



دارا است. در واقع هر اندازه مقدار واقعی Q_{obs} به مقدار پیش‌بینی شده به وسیله ی شبیه Q_{for} نزدیک تر باشد، شبیه سازی دقیق تر بوده و خطای کمتری را دارد. مقدار R و NSE به یک نزدیک تر باشد، نشان دهنده ی تطابق بهتر مقادیر تخمین و مقادیر اندازه گیری شده است [1]. MSE به صفر نزدیک باشد، نشان دهنده ی خطای پایین مدل در برآورد رواناب است.

Q_{obs} میانگین دبی مشاهداتی

Q_{for} میانگین دبی شبیه سازی شده

$$RMSE = \sqrt{\left(\frac{1}{N} \sum_{i=1}^N (Q_{for.i} - Q_{obs.i})\right)^2}$$

$$E_{ns} = \frac{Q_{ns}}{1} = \frac{\sum_{i=1}^N (Q_{for.i} - Q_{obs.i})^2}{\sum_{i=1}^N (Q_{for.i} - Q_{obs.i})^2}$$

$$R = \left(\frac{\sum_{i=1}^N (Q_{obs.i} - \bar{Q}_{obs}) \sum_{i=1}^N (Q_{for.i} - \bar{Q}_{for})}{\sqrt{\left(\frac{1}{N} \sum_{i=1}^N (Q_{obs.i} - \bar{Q}_{obs})^2\right) \sqrt{\left(\frac{1}{N} \sum_{i=1}^N (Q_{for.i} - \bar{Q}_{for})^2\right)}} \right)$$

خطاها و ضرایب همبستگی در مراحل آموزش و ارزیابی شبکه بین نتایج حاصل از پیش‌بینی شبکه و داده‌های موجود در اینجا آورده شده است: مشاهده می‌شود که با توجه به حجم داده‌های موجود که برای طراحی یک شبکه عصبی مناسب کم است، نتیجه قابل قبول حاصل شده است.

منابع

بارانی، غلامعباس. (1381) پیش بینی دبی اوج با استفاده از شبکه عصبی (مطالعه موردی در رودخانه هلیل)، ششمین سمینار مهندسی رودخانه، دانشگاه شهید چمران اهواز بهمن 81، ص 479 الی 486.

دهقانی، نوید، وفاخواه، مهدی، بهره مند، عبدالرضا. (1395) مدل سازی بارش- رواناب با استفاده از شبکه عصبی مصنوعی و شبکه فازی- عصبی تطبیقی در حوزه آبخیز کسلیان. پژوهشنامه مدیریت حوزه آبخیز ۱۳۹۵؛ ۷ (۱۳): ۱۳۷-۱۲۸

فاطمی نیا، فخری سادات. حسینی، سید محمد، دستجردی، جواد خوشحال. (1392) شبیه سازی بارش- رواناب با استفاده از شبکه عصبی مصنوعی (مورد: حوضه آبخیز فریدن). مجله جغرافیا و برنامه ریزی محیطی دوره 24، شماره 3 - شماره پیاپی 3 آذر 1392 صفحه 25-40


زارع ابیانه، حمید و بیات ورکشی، مریم. () 1389 ارزیابی مدل های هوشمند عصبی و تجربی در تخمین رواناب سالانه، نشریه آب و خاک (علوم و صنایع کشاورزی)، جلد 25، شماره 2، 379

Cavazos, T (2000) Using Self-Organizing Maps to Investigate Extreme Climate Event: An Application to wintertime Precipitation in the Balkans, Journal of Climate, Vol 13. 718.

Coulibaly P.,D Yonas., A Francois.;(2005), Downscaling precipitation and temperature with temporal neural networks; Journal of Hydrometeorology, Vol.6,NO.4. 483.

شکل 6: میزان همبستگی بین میزان دبی پیش بینی شده و میزان دبی واقعی در فرایند ارزیابی

همانطور که در شکل 7 نشان داده شده است، در بهترین حالت شبیه سازی، ضریب همبستگی حدود 0,9 بین دیتاهای شبیه سازی و دیتاهای واقعی برقرار شده است.



شکل 7: همبستگی بین داده های واقعی و شبیه سازی

نتیجه گیری

در این تحقیق، ترکیبات مختلفی از داده های بارش و دما و دبی و اختلاف دبی دو روز متوالی، در این تحقیق مورد استفاده قرار گرفته است. نتایج نشان داد با داشتن 2 ورودی و شبکه عصبی feedforward و یا 1 ورودی و شبکه newrbe بهترین عملکرد حاصل شده و فرآیند بارش- رواناب با دقت بالاتری پیش بینی شده است. هم چنین با وجود کم بودن تعداد متغیر های ورودی، روش شبکه ی عصبی، پیش بینی تقریباً مطلوبی از دبی روزانه عبوری از رودخانه نتیجه داده است.

<https://sanad.iau.ir/journal/pmi.ced>

Lorrai, M. and H.M. Sechi. (1995), Neural networks for modeling rainfall-runoff transformations. *Water Resources Management*, 9: 299-313.

Maria, C. Haroldo, F and Ferreira, N (2005) Artificial neural network technique for rainfall forecasting applied to the Sao Paulo region, *Journal of Hydrology*, Volume 301, Issues 1-4.

Wang, W.C., Chau, K.W., Cheng, C.T. and Qiu, L., 2009. A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. *Journal of hydrology*, 374(3-4), pp.294-306.

Talei, A. and Chua, L.H., 2012. Influence of lag time on event-based rainfall-runoff modeling using the data driven approach. *Journal of hydrology*, 438, pp.223-233.

Badrzadeh, H., Sarukkalige, R. and Jayawardena, A.W., 2015. Hourly runoff forecasting for flood risk management: Application of various computational, intelligence models. *Journal of Hydrology*, 529, pp.1633-1643.

Gissila, T, Black, E, Grimes, D. I. F and Slingo, J. M. (2004), Seasonal forecasting of the Ethiopian summer rains. *International Climatology*. Vol. 24: 1345 – 1358.

Gwo - Fong, Lin, chun – mingwang, (2007), A nonlinear rainfall-runoff model embedded

with an automated calibration method. Part1: The model. *Journal of hydrology* 341. 186.

Halid, H and Ridd, P. (2002), Modeling InterAnnual Variation of a Local Rainfall Data Using a Fuzzy Logic Technique, *Proceeding of International Forum on Climate Prediction*, James Cook University, Australia. First Proof Pages.

Hawkins, R.H., (1978). Effect of Rainfall Intensity on Run off Curve Number Hydrology and water resources in Arizona and Southwest, University of Arizona, Office of Arid Lands, No 1. 8.

Kadioglou M., and Sen Z. (2001), Monthly precipitation-runoff polygons and mean coefficients. *Hydrological Sciences Journal*. 46 (1): 3-11.