

در مرحله آزمایش بود و برای متغیر دما، که دارای بیشترین اثر (از بین ورودی مدل‌های با یک متغیر هواشناسی) بر جریان خروجی بود معیارهای ارزیابی به ترتیب شامل RMSE، MSE و MAE برابر با ۰/۳۱، ۰/۵۶ و ۰/۳۳ در مرحله آموزش و ۰/۱۳، ۰/۳۶ و ۰/۱۳ در مرحله آزمایش بودند. درباره بارندگی نیز مشاهده شد که میزان خطای مدل وقتی که بارندگی با دو تأخیر استفاده می‌شود نسبت به زمانی که از بارندگی همان روز یا یک روز قبل استفاده می‌شود خطای مدل کاهش می‌یابد؛ این یافته با نتایج شریفی و همکاران (۱۳۹۲) مبنی بر تأثیر مثبت بارندگی روزهای قبل بر جریان رودخانه در حوضه آبخیز معرف امامه هم‌خوانی دارد. علاوه بر این، با توجه به معیارهای ارزیابی، از بین مدل‌هایی که فقط در آن‌ها از تأخیر زمانی جریان استفاده شده نتایج حاکی از تأثیر یکسان تأخیر زمانی تا سه روز بر جریان رودخانه حوضه امامه است و از تأخیر چهارم، پنجم و ششم نه تنها تأثیری مشاهده نمی‌شود، بلکه خطاها نیز افزایش یافته است؛ این موضوع نشان می‌دهد که حداکثر میزان توالی آورد رودخانه حوضه امامه برابر با دو تأخیر بوده است؛ این یافته با نتایج شریفی و همکاران (۱۳۹۲)، که با استفاده از آزمون گاما به این نتیجه رسیده‌اند، هم‌راستا است. با توجه به مدل ۵۴ (بهترین مدل) میزان ضریب همبستگی دبی مشاهده‌ای و پیش‌بینی شده در مرحله آموزش و آزمایش به ترتیب برابر با ۰/۹۰ و ۰/۸۲ است (شکل‌های ۲ و ۳). بنابراین، با توجه به نتایج جدول ۲، مدل ۵۴ با هشت متغیر ورودی و با ساختار دو لایه پنهان - در لایه اول به ترتیب با ۹ و ۸ نرون و با آرایش ۸-۹-۸-۱ دارای بهترین عملکرد بود. علاوه بر این، در این پژوهش از یک، دو، و سه لایه پنهان استفاده شد؛ نتایج نشان داد استفاده از سه لایه پنهان هیچ تأثیری در بهتر شدن شرایط مدل‌ها ندارد و یک شبکه عصبی پرسپترون دو لایه مناسب بود. با نگاهی دقیق بر نتایج شبکه عصبی پرسپترون چندلایه، مشخص می‌شود که بیشتر مدل‌های این شبکه عصبی دارای دو لایه در لایه پنهان‌اند؛ به طوری که هر چه متغیرهای ورودی مدل افزایش می‌یابد و، به عبارتی، ساختار شبکه عصبی پیچیده‌تر می‌شود استفاده از شبکه عصبی پرسپترون چهارلایه، که دارای دو لایه پنهان است، می‌تواند بسیار موثر باشد. نتایج یافته‌های این تحقیق با نظر ریپ‌لای (۱۹۹۴) و فود و کارتمن (۱۹۹۶) مبنی بر استفاده از شبکه‌های پخش‌خطای دو لایه مخفی به دلیل قابلیت انعطاف‌پذیری آن‌ها در حل مسائل هیدرولوژی به دلیل تغییرات شدید داده‌های اغتشاش حاکم بر داده‌ها هم‌خوانی دارد. همچنین، گرچه برای اجرای این تحقیق در پرسپترون چندلایه از یک، دو، و سه لایه در لایه پنهان استفاده شد، با توجه به نتایج مدل‌ها در حوضه مورد مطالعه، هیچ یک از مدل‌های نهایی پرسپترون چندلایه دارای سه لایه پنهان نبود؛ حتی در صورت استفاده از سه لایه باعث افزایش خطای مدل‌ها در هر دو حوضه شد. از طرفی، تعداد نرون‌های لایه پنهان نیز از ۱ تا ۳۰ نرون برای مدل‌ها به صورت سعی و خطا استفاده شد؛ نتایج نشان داد تعداد نرون‌های لایه پنهان چنانچه از یک لایه پنهان استفاده شود، بین ۱ تا ۱۶ نرون است و اگر از دو لایه پنهان استفاده شود، بین ۱ تا ۱۲ نرون برای حوضه آبخیز امامه برای یک و دو لایه پنهان به دست آمد؛ یافته‌های این تحقیق تأییدکننده آرای دائی و همکاران (۲۰۱۱) و هیو و همکاران (۲۰۱۲) مبنی بر افزایش خطاها در صورت افزایش تعداد نرون‌های لایه پنهان است. همچنین، روش برنامه‌ریزی ژنتیک در حوضه آبخیز امامه انجام شد و نتایج آن در جدول ۴ درج گردید. در این نوع روش نیز، با توجه به آماره‌های ارزیابی بدترین مدل، مدل ۳ با متغیر رطوبت نسبی، به عنوان تنها ورودی، دارای مقدار عددی به ترتیب برابر با ۰/۰۰۷، ۰/۰۸۴ و ۰/۰۱۵ در مرحله آموزش و ۰/۰۰۹، ۰/۰۹۵ و ۰/۰۱۷ در مرحله آزمایش به عنوان ضعیف‌ترین عملکرد

بود، بنابراین، بدترین مدل از بین ۶۲ ساختار ریاضی در حوضه آبخیز امامه شناخته شد؛ بعد از آن تبخیر و تعرق (مدل ۲) با میزان خطای برابر با ۰/۰۰۶، ۰/۰۷۹، و ۰/۰۱۵ در مرحله آموزش و ۰/۰۰۸، ۰/۰۹۰، و ۰/۰۱۶ در مرحله آزمایش، متغیر بارندگی (مدل ۱) با مقدار عددی به ترتیب برابر با ۰/۰۰۶، ۰/۰۷۸، و ۰/۰۱۵ در مرحله آموزش و ۰/۰۰۸، ۰/۰۸۹، و ۰/۰۱۶ در مرحله آزمایش، و دما (مدل ۴) با میزان خطای ۰/۰۰۶، ۰/۰۷۷، و ۰/۰۱۵ در مرحله آموزش و ۰/۰۰۷، ۰/۰۸۹، و ۰/۰۱۶ در مرحله آزمایش برای RMSE، MSE، و MAE بودند. بهترین ساختار پیشنهادی هم مدل ۵۴ با میزان خطا به ترتیب برابر با ۰/۰۰۱، ۰/۰۳۱، و ۰/۰۰۹ در مرحله آموزش و ۰/۰۰۱، ۰/۰۳۲، و ۰/۰۰۹ در مرحله آزمایش بود. شکل‌های ۴ و ۵ نمودار مقادیر مشاهده‌ای و پیش‌بینی شده در مرحله آموزش و آزمایش را نشان می‌دهد. علاوه بر این، یکی از قابلیت‌های مهم روش برنامه‌ریزی ژنتیک ارائه رابطه ریاضی برای متغیرهای هیدرولوژیکی مورد مطالعه است. در این تحقیق نیز رابطه ریاضی به دست آمده با استفاده از برنامه‌ریزی ژنتیک برای حوضه آبخیز امامه به همراه ساختار آن در رابطه ۵ ارائه شده است.

$$Q_t = (Q_{t-2} - Q_{t-1})((RH_t Q_t - 10.92P_t)) + (Q_{t-1} - (0.02P_{t-1})0.06) + 0.089T_t + 0.089P_{t-2} - ET_t \quad \text{رابطه ۵}$$

از طرفی، از بین دو نوع مجموعه عملگر ریاضی اصلی از عملکرد بهتری برخوردار بود؛ به دلیل تعدد مدل‌ها، از ذکر نتایج مجموعه دوم - که شامل عملگرهای متعدد و زیادی بود، همچون sin، cos، tang، و cotg - خودداری شد. از آنجا که برنامه‌ریزی ژنتیک از ترکیب تصادفی مجموعه ترمینال‌ها (اعداد ثابت) و توابع به دست می‌آید، چنانچه رابطه بین ورودی‌ها و خروجی‌ها خطی باشد و از این نوع عملگرها استفاده شود، موجب کاهش دقت مدل می‌شود. نتایج این تحقیق نشان داد گرچه رابطه بارش - رواناب رابطه پیچیده و غیرخطی است، در تخمین این رابطه عملگرهای ذکر شده باعث پیچیدگی بیش از حد مدل و کاهش دقت مدل می‌شوند و برنامه‌ریزی ژنتیک خطی به دلیل کارایی بسیار زیاد قادر است با همان عملگرهای اصلی این رابطه غیرخطی را تخمین بزند؛ یافته‌های این تحقیق با نتایج داننده‌مهر و همکاران (۲۰۱۴) و سلطانی و همکاران (۱۳۸۹) هم‌خوانی دارد. با توجه به نتایج شبکه عصبی دو حوضه مورد مطالعه و مقایسه آن با نتایج حاصل از برنامه‌ریزی ژنتیک مشخص شد که از بین شبکه عصبی مصنوعی و برنامه‌ریزی ژنتیکی روش برنامه‌ریزی ژنتیکی از عملکرد بهتری برخوردار است؛ نتایج این تحقیق با نتایج دورادو و همکاران (۲۰۰۳)؛ آیتک و همکاران (۲۰۰۸)؛ گوین (۲۰۰۹)؛ وانگ و همکاران (۲۰۰۹)؛ قربانی و همکاران (۲۰۱۰)؛ داننده‌مهر و همکاران (۲۰۱۳)، ۲۰۱۴؛ فربودنام و همکاران (۱۳۸۸)؛ و سلطانی و همکاران (۱۳۸۹) مبنی بر کارایی و دقت زیاد این روش با توجه به مقادیر خطاها هم‌خوانی دارد.

منابع

- سلطانی، ع.؛ قربانی، م.ع.؛ فخری‌فرد، ا.؛ دربندی، ص. و فرسادی‌زاده، د. (۱۳۸۹). برنامه‌ریزی ژنتیک و کاربرد آن در مدل‌سازی فرایند بارش - رواناب، *دانش آب و خاک*، ۱(۴): ۶۱ - ۷۱.
- شریفی، ع.ر.؛ دین‌پژوه، ی.؛ فخری‌فرد، ا. و مقدم‌نیا، ع.ر. (۱۳۹۲). ترکیب بهینه متغیرها برای شبیه‌سازی رواناب در حوضه آبخیز امامه با استفاده از آزمون گاما، *دانش آب و خاک*، ۳(۴): ۵۹ - ۷۲.

- فربودنام، ن.؛ قربانی، م.ع. و اعلمی، م.ت. (۱۳۸۸). پیش‌بینی جریان رودخانه با استفاده از برنامه‌ریزی ژنتیک (مطالعه موردی حوضه آبخیز لبقوان)، *دانش آب و خاک*، ۱۹(۱): ۱۰۷ - ۱۲۲.
- مسعودی، ا.؛ پارسامهر، پ.؛ سلماسی، ف. و پوراسکندر، س. (۱۳۹۱). تخمین ضریب دبی در سرریزهای لبه پهن مرکب با استفاده از رگرسیون، *برنامه‌ریزی ژنتیک و شبکه عصبی، آب و خاک*، ۲۶(۴): ۹۳۳ - ۹۴۲.
- Aytek, A.; Asce, M. and Alp, M. (2008). **An Application of Artificial Intelligence for Rainfall-Runoff Modeling**, *Hydrology Earth System science*, 117(2): 145-155.
- Chiang, J.L. and Yeh, C.H. (2010). **Suspended Sediment Forecasting in Gao-Pen River using Artificial Neural Network**, Vol. 12, EGU2010-7549.
- Dai, X.; Huo, Z. and Wang, H. (2011). **Simulation for Response of Crop Yield to Soil Moisture and Salinity with Artificial Neural Network**, *Field crops research*, 121: 441-449.
- DanandehMehr, A.; Kahya, E. and Olyaie, E. (2013). **Streamflow Prediction using Linear Genetic Programming in Comparison with a Neuro-Wavelet Technique**, *Journal of Hydrology*, 505: 240-249.
- DanandehMehr, A.; Kahya, E. and Yerdelen, C. (2014). **Linear Genetic Programming Application for Successive-Station Monthly Stream Flow Prediction**, *Journal of Computers and Geosciences*, 70: 63-72.
- Dawson, C.W and Wilby, R.L. (2001). **Hydrological modeling using artificial neural network**, *Progress in Physical Geography*, 25(1): 80-108.
- Dorado, J.; Rabunal, J.R.; Pazos, A.; Rivero, D.; Santos, A. and Puertas, J. (2003). Prediction and Modeling of the Rainfall-Runoff Transformation of a Typical Urban Basin using ANN and GP, *Applied Artificial Intelligence*, 17: 329-343.
- Farboodfam, N.; Ghorbani, M.A. and Alami, M.T. (2009). **River Flow Prediction Using Genetic Programming (Case Study: Lighvan River Watershed)**, *Journal of Soil and Water Science*, 19(1): 107-122 (In Persian).
- Gharaei-Manesh, S.; Fathzadeh, A. and Taghizadeh-Mehrjardi, R. (2016). **Comparison of Artificial Neural Network and Decision Tree Models in Estimating Spatial Distribution of Snow Depth in a Semi-Arid Region of Iran**, *Cold Regions Science and Technology*, 122: 26-35.
- Ghorbani, M.A.; Khatibi, R.; Aytek, A.; Makarynskyy, O. and Shiri, J. (2010). **Sea water Level Forecasting using Genetic Programming and Artificial Neural Networks**, *Computers and Geoscience*, 36(5): 620-627.
- Güven, A. (2009). **Linear Genetic Programming for Time-Series Modeling of Daily Flow Rate**, *Journal of Earth System Science*, 118(2): 157-173.
- Harun, S.; Ahmat Nor, N.I. and Kassim, A.H.M. (2002). **Artificial Neural Network Model for Rainfall-Runoff Relationship**, *Journal Technology*, Vol. 37, (B) Dis. 2002: 1-12 © University Technology Malaysia.
- Hosseini, S.M. and Mahjouri, N. (2016). **Integrating Support Vector Regression and a Geomorphologic Artificial Neural Network for Daily Rainfall-Runoff Modeling**, *Applied Soft Computing*, 38: 329-345.
- Huo, Z.; Feng, S.; Kang, S.; Huang, G.; Wang, F. and Guo, P. (2012). **Integrated Neural Networks for Monthly River Flow Estimation in Arid Inland Basin of Northwest China**, *Journal of Hydrology*, 420-421: 159-170.
- Jayawardena, A.W; Muttill, N. and Fernando, T. (2005). **Rainfall-Runoff Modelling using Genetic Programming**, *International Congress on Modelling and Simulation Society of Australia and New Zealand*, December 2005, New Zealand, PP. 1841-1847.
- Koza, J.R. (1992). *Genetic Programming: On the Programming of Computers by Natural Selection*, A Bradford book Cambridge, MIT Press.
- Masoodi, A.; Parsamehr, P.; Salmasi, F. and Pureskandar, S. (2012). **Regression Analysis, Genetic Programming and ANN to Predict Discharge Coefficient of Compound Broad Crested Weir**, *Journal of Water and Soil*, 26(4): 933-942 (In Persian).

Pramanik, N. and Panda, R.K. (2009). **Application of Neural Network and Adaptive Neurofuzzy Inference Systems for River Flow Prediction**, *Journal of Hydrology*, 54(2): 247-260.

Sarangi, A. and Bhattacharya, A.K. (2005). **Comparison of Artificial Neural Network and Regression Models for Sediment Loss Prediction from Banha Watershed in India**, *Agricultural water management*, 28(4): 373-385.

Sharifi, A.R.; Dinpashoh, Y.; Fakheri-Fard, A. and Moghaddamnia, A.R. (2013). **Optimal combination of Variables for Runoff Simulation in the Amameh Watershed using Gamma test**, *Water and Soil Science*, 23(4): 59-72 (In Persian).

Sinivasulu, S. and Jain, A. (2006). **A comparative analysis of training methods for artificial neural network rainfall-runoff models**, *Applied Soft Computing*, 6: 295-306.

Solaimani, K. (2009). **Rainfall-Runoff Prediction Based on Artificial Neural Network (A Case Study: Jarahi Watershed)**, *American-Eurasian Journal of Agriculture and Environment, Science*, 5(6): 856-865.

Soltani, A.; Ghorbani, M.A.; Fakherifard, A.; Darbandi, S. and Farsadizadeh, D. (2010): Genetic programming and its application in modeling the rainfall-runoff process, *Journal of Soil and Water*, 1(4): 61-71 (In Persian).

Sudheer, P.K.; Gosain, A.K. and Ramasastri, K.S. (2002). **A Data Driven Algorithm for Constructing Artificial Neural Network Rainfall-Runoff Models**, *Journal of Hydrology*, 16(6): 1325-1330.

Tao, W.; Kailin, Y. and Yongxin, G. (2008). **Application of Artificial Neural Networks to Forecasting Ice Conditions of the Yellow River in the Inner Mongolia Reach**, *Journal of Hydrology*, 13(9): 811-816.

Wang, W.C.; Chau, K.W.; Cheng, Ch.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): 294-306.

Wu, C.L.; Chau, K.W. and Li, Y.S. (2009). **Methods to Improve Neural Network Performance in Daily Flows Prediction**, *Journal of Hydrology*, 372(1-4): 80-93.