

علوم و تکنولوژی محیط زیست، دوره بیست و یکم، شماره نه، آذر ماه ۹۸

پیش بینی جریان آبراهه ای با استفاده از مدل های هیبریدی هوشمند در مقیاس

ماهانه (مطالعه موردی: رودخانه زرین رود)

بابک محمدی^{۱*}

babakmohammadi@ut.ac.ir

روزبه موذن زاده^۲

تاریخ پذیرش: ۹۶/۳/۳

تاریخ دریافت: ۹۵/۱۱/۶

چکیده

زمینه و هدف: انتخاب ورودی های مناسب برای مدل های هوشمند از اهمیت بسزایی برخوردار است زیرا باعث کاهش هزینه و صرفه جویی در وقت و افزایش دقت و کارایی مدل ها می شود. هدف از پژوهش حاضر، کاربرد آنتروپی شانون برای انتخاب ترکیب بهینه متغیرهای ورودی در شبیه سازی دبی ماهانه توسط پارامترهای هواشناسی می باشد.

روش بررسی: در این مطالعه داده های هواشناسی و سری زمانی ماهانه دبی رودخانه زرین رود (ایستگاه صفاخانه) واقع در آذربایجان- شرقی در دوره زمانی ۱۳۳۶ تا ۱۳۹۴ مورد استفاده قرار گرفت. پارامترهای هواشناسی و ماه از سال به عنوان ورودی در روش آنتروپی به منظور تعیین ترکیب موثر در نظر گرفته شد.

یافته ها: نتایج آنتروپی شانون نشان داد که پارامترهای بارش، ماه از سال و دما، نتایج بهتری را برای مدل سازی ارائه می دهد. شبیه سازی با استفاده از مدل های هیبرید هوشمند الگوریتم هیبریدی ازدحام ذرات و الگوریتم هیبریدی شبیه سازی تبرید انجام گرفت. کارایی مدل ها با استفاده از معیار ضریب تبیین، ریشه جذر میانگین خطا و شاخص پراکندگی محاسبه گردید.

بحث و نتیجه گیری: نتایج نشان داد از میان این مدل ها با ساختار ورودی های یکسان، مدل الگوریتم هیبریدی شبیه سازی تبرید بر پایه ماشین بردار پشتیبان عملکرد بهتری برای شبیه سازی دبی جریان در مقایسه با سایر مدل های هیبریدی هوشمند داشته است. همچنین نتایج تحقیق نشان داد که روش آنتروپی در انتخاب بهترین ترکیب ورودی در مدل های هوشمند از کارایی خوبی برخوردار است.

واژه های کلیدی: الگوریتم هیبریدی، ازدحام ذرات، تئوری آنتروپی، دبی رودخانه، شبیه سازی تبرید

۱- کارشناسی ارشد مهندسی منابع آب، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران* (مسئول مکاتبات)

۲- استادیار گروه آب و خاک، دانشکده کشاورزی، دانشگاه صنعتی شاهرود، شاهرود، ایران

Prediction of Stream Flow Using Intelligent Hybrid Models in Monthly Scale (Case study: Zarrin roud River)

Babak Mohammadi^{1*}
babakmohammadi@ut.ac.ir
Roozbeh Moazenzadeh²

Admission Date: May 24, 2017

Date Received: January 25, 2017

Abstract

Background and Objective: Selecting appropriate inputs for intelligent models are important because it reduces the cost and saves time and increases accuracy and efficiency of its models. The aim of the present study is the use of Shannon entropy to select the optimum combination of input variables in the simulation of monthly flow by meteorological parameters.

Method: In this study, meteorological data and monthly time series of discharge of Zarrinroud River (Safavankeh Station) in East Azarbaijan from 1336 to 2015 were used. The meteorological parameters and the month of the year were considered as inputs in the entropy method to determine the effective composition.

Results: Shannon entropy results showed that the rainfall parameters, month of year and temperature provide better results for modeling. The simulations were performed using intelligent hybrid models of particle swarm hybrid algorithm and hybrid simulation hybrid algorithm.

Discussion and Conclusion: The results showed that among these models with the same input structure, the hybrid algorithm simulation based on the support vector machine had better performance for simulating the flow rate compared to other intelligent hybrid models. The results also show that the entropy method is good for selecting the best input combination in smart models.

Keywords: Hybrid Algorithms, Particle Swarm, Entropy, Discharge, Simulated Annealing

1- Master of water resources engineering, Department of Water engineering, Faculty of Agricultural, University of Tabriz, Tabriz, Iran *(Corresponding author).

2- Assistant Professor, Department of Soil and Water, Faculty of Agriculture, Shahrood University of Technology, Shahrood, Iran.

مقدمه

امروزه سیستم های هوشمند برای پیش بینی پدیده های غیرخطی مورد استفاده قرار می گیرند که شبکه عصبی مصنوعی^۱ (ANN) از جمله این روش ها می باشد. در سال های اخیر مدل های غیرخطی مانند شبکه هوش مصنوعی به طور گسترده ای برای مدل سازی سری زمانی فرایندهای هیدرولوژیکی مورد استفاده قرار می گیرند. فرج زاده و همکاران در سال ۲۰۱۴ با استفاده از مدل های سری زمانی و شبکه عصبی مصنوعی به پیش بینی جریان ماهانه و بارش حوضه دریاچه ارومیه پرداختند. نتایج حاصل از پیش بینی جریان حاکی از دقت خوب هر دو مدل در تخمین جریان ماهانه بوده است (۱). حسن و همکاران در سال ۲۰۰۴ الگوریتم بهینه سازی ازدحام ذرات را با الگوریتم شبکه عصبی مصنوعی مقایسه کردند نتیجه گرفتند که بهینه سازی ازدحام ذرات یک روش جستجوی اکتشافی نسبتا جدید است که با رفتار مشترک از جمعیت بیولوژیکی الهام گرفته است. در این الگوریتم حرکت از مجموعه ای از نقاط (جمعیت) به مجموعه ای دیگر از نقاط در یک تکرار و تنها با بهبود احتمال با استفاده از هیبریدی از قوانین قطعی و احتمالی صورت می گیرد. در این پژوهش ثابت شد که الگوریتم ازدحام ذرات نسبت به شبکه عصبی مصنوعی راندمان بهتری دارد (۲). در تحقیق دیگری توسط چاو الگوریتم بهینه سازی ازدحام ذرات را برای شبکه عصبی مصنوعی در پیش بینی سطح آب رودخانه استفاده کرد. استفاده از شبکه های عصبی مصنوعی نشان داد که روش مقرون به صرفه ای است اما آموزش آن ها با مشکلاتی از جمله همگرایی بسیار کند به همراه است. نتایج نشان داد که الگوریتم بهینه سازی ازدحام ذرات می تواند جایگزین مناسبی برای بخش آموزش شبکه عصبی مصنوعی باشد (۳). چاو در سال ۲۰۰۷ الگوریتم بهینه سازی ازدحام ذرات را برای پیش بینی سطح آب رودخانه شینگ در هنگ کنگ بررسی نمود. نتایج نشان داد که الگوریتم بهینه سازی ازدحام ذرات از دقت بالاتر در یک زمان بسیار کوتاه تر در مقایسه با سایر الگوریتم ها برخوردار است (۴).

در فرایندهای هیدرولوژیکی از مفهوم آنتروپی در تعیین بهینه نمونه برداری (۵)، طراحی و ارزیابی شبکه های پیمایش کیفیت آب (۶، ۷)، طراحی و ارزیابی شبکه ایستگاه های هیدرومتری (۸) و پیش بینی کیفیت آب رودخانه و تخمین پارامترهای توزیع فراوانی (۱۰) تفکیک مقادیر بارش روزانه به مقیاس ساعتی (۱۱)، بررسی و ارزیابی خصوصیات زمانی و مکانی بارش (۱۲) و استفاده شده است. در تحقیقی توسط آموروچو و اسپیلدورا آنتروپی را برای ارزیابی عدم قطعیت مدل حوضه استانفورد در شبیه سازی رواناب یک حوضه در کالیفرنیا به کاربردند (۱۲). در پژوهشی توسط کریمی در حوضه آبریز زاینده رود، پس از محاسبه آنتروپی انتقال اطلاعات زوج ایستگاه ها، رابطه آنتروپی انتقال اطلاعات فاصله برای منطقه را تعیین و سپس به کمک SA و GA با دو هدف بیشینه کردن حداقل آنتروپی و بیشینه کردن متوسط آنتروپی، مناطق نیازمند ایستگاه های جدید را معرفی کردند (۱۱). در تحقیقی توسط چیانگ و همکاران در سال ۲۰۰۴ تئوری آنتروپی انتقال اطلاعات در طراحی شبکه باران سنجی مورد استفاده قرار دادند. مطالعه ای موجود در مورد اثر تغییرات مکانی و زمانی بارش با محاسبه حداکثر آنتروپی مشترک می باشد. نتایج نشان داد که اثر تغییرات مکانی و مقایسه با مقیاس های زمانی بارش با محاسبه حداکثر آنتروپی مشترک می باشد. نتایج بیان گر این است که اثر تغییرات مکانی و مقایسه با مقیاس های زمانی بارش با محاسبه حداکثر آنتروپی دیگر توسط رمضان و همکاران در سال ۲۰۰۶ در حوضه برو انگلستان به منظور پیش بینی بارش و رواناب از آنتروپی شانون و آزمون گاما جهت تعیین ورودی ها به شبکه عصبی مصنوعی استفاده کردند که نتایج از عملکرد بهتر آنتروپی شانون برای تعیین ورودی ها حاکی بود (۱۵). در پژوهشی توسط چن در سال ۲۰۰۹ با استفاده از ماشین بردار پشتیبان (SVM) و تئوری آنتروپی انتقال اطلاعات به استخراج داده های هیدرولوژیکی از حوادث سیل در حوضه رودخانه یانگ در تایوان پرداختند (۱۶).


مطالعاتی انتخاب شده است. از داده های ۵۸ سال آماری این ایستگاه، از سال ۱۳۳۶ تا سال ۱۳۹۴ شامل دما، تبخیر، رطوبت، بارش، سرعت باد و ماه از سال، پس از بررسی صحت داده ها استفاده گردید. ایستگاه هیدرومتری صفاخانه با ارتفاع ۱۵۰۰ متر از سطح دریا و در طول جغرافیایی ۴۸ دقیقه و ۱۵ دقیقه و عرض جغرافیایی ۳۳ درجه و ۲۶ دقیقه واقع گردیده است. در شکل ۱ هیدروگراف دبی ماهانه این ایستگاه نشان داده شده است.

در این تحقیق برای یافتن بهترین ترکیب از پارامترهای ورودی در پیش بینی سری دبی جریان زرينه رود از تئوری آنتروپی شانون استفاده شد و پس از انتخاب موثر ترین متغیرهای ورودی، برای مدل سازی از الگوریتم های هیبریدی ازدحام ذرات و شبیه سازی تبرید بر پایه های شبکه عصبی مصنوعی پرسپترون چند لایه و ماشین بردار پشتیبان استفاده گردید.

روش بررسی

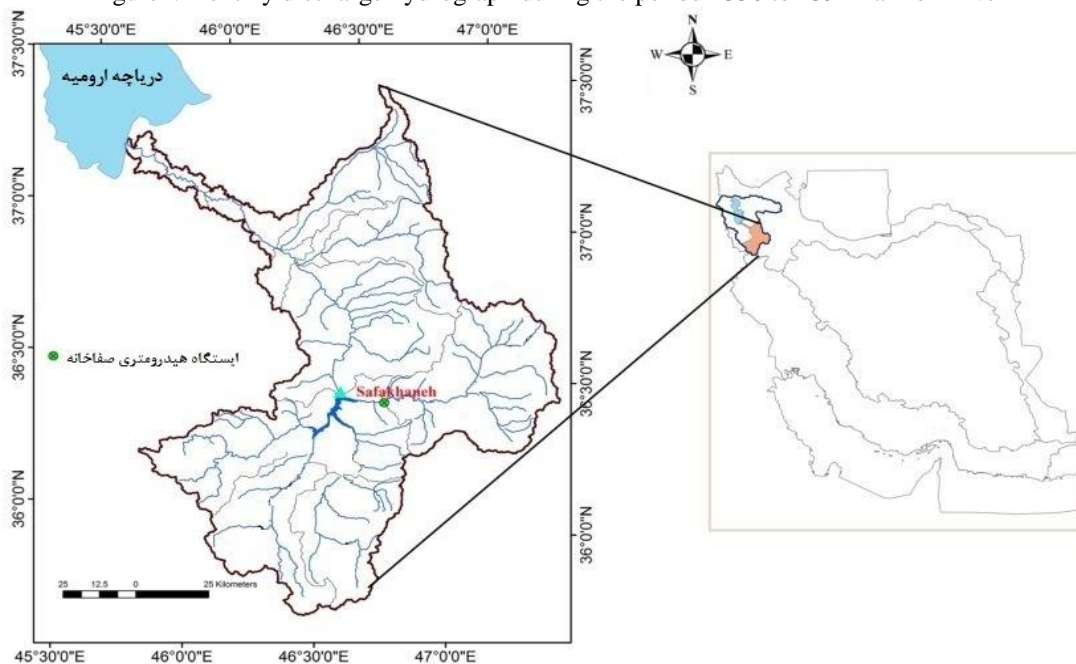
منطقه مورد مطالعه و داده های مورد استفاده

در این پژوهش، ایستگاه هیدرومتری صفاخانه واقع بر روی رودخانه زرينه رود در استان آذربایجان شرقی به عنوان منطقه



شکل ۱- هیدروگراف دبی ماهانه رودخانه زرينه رود در طول دوره آماری ۱۳۳۶ تا ۱۳۹۴

Figure 1. monthly discharge hydrograph during the period 1336 to 1394 Zarineh River



شکل ۲- نمایی از منطقه مورد مطالعه

Figure 2. View of the study area

جدول ۱- مشخصات آماری داده های دبی جریان رودخانه زرینه رود در ایستگاه هیدرومتری صفاخانه در طول سال های ۱۳۳۶ تا ۱۳۹۴

Table 1. Statistical characteristics of the river flow rate data input combination for Safakhaneh Zarineh in hydrometric station during the 1336 to 1394

پارامتر	واحد	میانگین	کمینه	بیشینه	انحراف معیار
دبی	M ³ /S	۹/۷۶	۱/۵۳	۵۶/۵۲	۸/۴۰
دما	°C	۱۳/۵	-۲۰/۷	۳۶	۱۰/۴۶
تبخیر	Mm/day	۸/۲۳	۰/۱	۵۰	۴/۵
رطوبت هوا	%	۵۳/۱۸	۱۲/۸	۹۸/۸	۱۷/۹
بارش	mm	۰/۷۱	۰	۴۳	۲/۵۴
سرعت باد	Km/h	۳/۰۲	۰	۱۵/۷۵	۱/۹
ماه از سال	month	۶/۵	۱	۱۲	۳/۴

پارامتر e_j مقدار آنتروپی انتقال اطلاعات را بیان می کند در واقع آنتروپی انتقال اطلاعات نوعی از آنتروپی است که برابر با تفاضل مجموع آنتروپی مرزی و آنتروپی های مشترک می باشد. هرچقدر مقدار آنتروپی کم تر باشد، تأثیرز بیش تر خواهد بود. آنتروپی انتقال اطلاعات بین دو متغیر x_j به صورت زیر تعریف می شود (۱۸):

$$e_j = -\frac{1}{\ln m} \sum_{i=1}^m P_{ij} \ln P_{ij} \quad (2)$$

با توجه به این که پارامترهای ورودی دارای واحدهای یکسانی باشند معمولاً با استفاده از تابع نرمال سازی، داده ها آماده سازی می شوند. در این پژوهش از روش نرمال سازی نوع کارایی، تابع نرمال سازی به صورت زیر خواهد بود (۱۸):

$$y_{ij} = \frac{x_{ij} - (x_{ij})_{\min}}{(x_{ij})_{\max} - (x_{ij})_{\min}} \quad (3)$$

الگوریتم ازدحام ذرات (PSO)

الگوریتم بهینه سازی ازدحام ذرات روشی برای بهینه سازی توابع پیوسته غیرخطی است. این ذرات در فضای پاسخ حرکت می کنند و نتایج حاصله بر مبنای یک «ملاک شایستگی» محاسبه می شوند. با گذشت زمان، ذرات به سمت ذراتی که دارای ملاک شایستگی بالاتری هستند، شتاب می گیرند (۱۹). بهینه سازی ازدحام ذرات یک روش جستجوی اکتشافی نسبتاً

به منظور تخمین دبی ماه های آینده، پارامترهای هوشناسی منطقه شامل دما، تبخیر، رطوبت، بارش، سرعت باد و ماه از سال به عنوان ورودی برای تعیین وزن به روش آنتروپی مورد استفاده قرار گرفت.

تئوری آنتروپی شانون

شانون در سال ۱۹۴۸ نشان داد که وقایع با احتمال وقوع زیاد اطلاعات کمتری در اختیار می گذارند و برعکس هرچقدر احتمال وقوع یک رخداد کم تر باشد، اطلاعات حاصل از آن بیش تر است. با به دست آوردن اطلاعات جدید، در واقع عدم قطعیت ها کاهش یافته و ارزش اطلاعات جدید برابر با مقداری است که از عدم قطعیت کاسته شده است. در نتیجه عدم قطعیت و اطلاعات پارامترهایی وابسته به هم هستند. به عبارت دیگر، از تئوری آنتروپی می توان به عنوان شاخصی برای کمی کردن میزان عدم آگاهی و دانش نسبت به مشخصات یک سامانه، استفاده نمود (۱۷).

برای به دست آوردن وزن آنتروپی ω_j از معادله زیر استفاده می شود (۱۸):

$$\omega_j = \frac{1 - e_j}{\sum_{j=1}^n 1 - e_j} \quad (1)$$

مسائل بهینه سازی ترکیباتی گذاشته است. از آن موقع به بعد روش تبرید شبیه سازی شده برای حل مسائل بهینه سازی مختلفی که شامل متغیرهای مستقل بسیاری هستند به کار گرفته شده است (۲۱، ۲۲). معروف ترین مزیت این الگوریتم این است که برخلاف روش های بهینه سازی موضعی که فقط می توانند یک مقدار مینیمم نزدیک به حدس اولیه را پیدا کنند، روش تبرید شبیه سازی شده، مقدار مینیمم مطلق را پیدا می کند (۲۱).

ماشین بردار پشتیبان

ماشین بردار پشتیبان (SVM) یک مجموعه از روش های یادگیری باناظر است که برای طبقه بندی و رگرسیون استفاده می شود. ماشین بردار پشتیبان توسط چروونوکیس در سال ۱۹۷۱، بر پایه ی تئوری یادگیری آماری معرفی شد. این روش مبتنی بر طبقه بندی دوتایی در فضای ویژگی های دلخواه است و از این روش مناسب برای مسائل پیش بینی بشمار می رود (۲۳).

در این تکنیک یک داده به صورت یک بردار P بعدی دیده می شود و می توان چنین نقاطی را با یک ابرصفحه $P-1$ بعدی جدا کرد. این عمل جداسازی خطی نامیده می شود. ابرصفحه های بسیاری وجود دارند که می توانند داده ها را جدا کنند، اما بیشینه کردن حاشیه بین دو کلاس مدنظر است. بنابراین ابرصفحه ای انتخاب می شود که فاصله ی آن از نزدیک ترین داده ها در هر دو طرف جداکننده ی خطی، بیشینه باشد. اگر چنین ابرصفحه ای وجود داشته باشد، به عنوان ابرصفحه بیشینه حاشیه شناخته می شود (۲۴). تابع تصمیم گیری برای جدا کردن داده ها با یک زیرمجموعه ای از مثال های آموزشی که بردارهای پشتیبان نامیده می شوند، تعیین می شود. در واقع ابرصفحه بهینه در تکنیک ماشین بردار پشتیبان جداکننده ای بین بردارهای پشتیبان است. اولین کاربرد این روش در مسائل آب توسط دبایک و همکاران (۲۰۰۱) با شبیه سازی بارش-رواناب ارایه شد (۲۴). ماشین بردار پشتیبان یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه سازی مقید است که از اصل استقرای کمینه سازی خطای ساختاری استفاده کرده و منجر به یک جواب بهینه کلی می گردد.

جدید است که با رفتار مشترک از جمعیت بیولوژیکی الهام گرفته شده است. الگوریتم بهینه سازی ازدحام ذرات مبتنی بر جمعیت می باشد، به عبارت دیگر، در این الگوریتم حرکت از مجموعه ای از نقاط (جمعیت) به مجموعه ای دیگر از نقاط در یک تکرار تنها با بهبود احتمال با استفاده از هیبریدی از قوانین قطعی و احتمالی صورت می گیرد. از جمله مزایای آن پیدا کردن جواب بهینه با راندمان بالاتر با دقت بیش تر است (۲).

الگوریتم بهینه سازی ازدحام ذرات از سه مرحله تشکیل شده است، این مراحل عبارتند از تولید مواضع ذرات و سرعت، به روز رسانی سرعت و در نهایت به روز رسانی موقعیت. در این الگوریتم یک ذره بر اساس به روز رسانی سرعت، در فضا تغییر موقعیت می دهد. برای شروع کار موقعیت و سرعت از ازدحام اولیه ذرات به طور تصادفی تولید می شوند. با استفاده از ارزش گذاری متغیرهای مد نظر، مرزهای بالایی و پایینی تعیین می شوند و از روی آن ها X کمینه و X بیشینه تعیین می شوند (۲). برای کسب اطلاعات بیش تر درباره این الگوریتم می توان به مقاله های کنندی و ابرهارت (۱۹۹۵) و حسن و همکاران (۲۰۰۴) مراجعه نمود.

الگوریتم شبیه سازی تبرید

الگوریتم شبیه سازی تبریدی (تبرید شبیه سازی شده) یا سرد کردن تدریجی یکی از الگوریتم های فرا ابتکاری بوده که علی رغم ساختاری ساده، اثربخشی بالایی در حل بسیاری از مسائل بهینه سازی ترکیبی دارد. این الگوریتم یک روش جستجوی محلی بوده که سعی در بدست آوردن جواب بهینه سراسری دارد. شبیه سازی تبریدی یک روش فرا ابتکاری احتمالی بر مبنای مدل مونت کارلو می باشد که توسط متروپولیس و همکارانش در سال ۱۹۵۳ ارایه شد و به طور گسترده در عرصه های گوناگون مسائل بهینه سازی ترکیبی مورد استفاده قرار می گیرد (۲۰، ۲۱).

اساس این الگوریتم بر مبنای رابطه بین ساختار اتمی، آنتروپی و دما در طول تبرید یک ماده و شباهت آن با پدیده آنیلینگ می باشد. این الگوریتم در دهه هشتاد میلادی توسط کرکپاتریک و همکاران معرفی گردید، این محققین و تاکنون به دلیل سادگی و همچنین کارایی، تاثیر شگرفی در زمینه حل

شبکه عصبی مصنوعی (ANN)

استفاده گردید. به منظور مقایسه شبکه عصبی مصنوعی و الگوریتم هیبریدی ازدحام ذرات از شاخص های آماری نظیر: ضریب تبیین (R^2)، ریشه متوسط مربعات خطا (RMSE) و شاخص پراکندگی (SI) استفاده شد.

$$R^2 = \left[\frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \cdot \sum_{i=1}^N (y_i - \bar{y})^2}} \right]^2 \quad (5)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_i - y_i)^2}{N}} \quad (6)$$

$$SI = \frac{\frac{1}{n} \sum_{i=1}^n |x_i - y_i|}{\bar{x}} \quad (7)$$

که در روابط ۵ الی ۷، x_i مقدار دبی مشاهداتی و y_i مقدار دبی پیش بینی شده و \bar{x} و \bar{y} به ترتیب نشان گر مقادیر میانگین داده های متناظر می باشند.

در این تحقیق متغیر های سری زمانی پارامترهای هواشناسی که بر اساس مطالعات پیشین بر روی برآورد دبی جریان موثر بودند و در ایستگاه هیدرومتری صفاخانه نیز مورد اندازه گیری قرار گرفته بودند، تعیین گردیدند. این سری زمانی شامل دما، تبخیر، رطوبت، بارش، سرعت باد و ماه از سال و سپس با استفاده از تئوری آنتروپی شانون موثرترین آن ها برای برآورد دبی جریان به عنوان ورودی های مدل های هوشمند الگوریتم هیبری ازدحام ذرات (SVM-PSO و ANN-PSO)، الگوریتم هیبری شبیه سازی تبرید (SVM-SA و ANN-SA)، شبکه عصبی مصنوعی (ANN) و ماشین بردار پشتیبان (SVM) انتخاب شدند.

یافته ها

به منظور تعیین ترکیب بهینه متغیرهای ورودی به مدل های هوشمند از آنتروپی شانون استفاده گردید با استفاده از آنتروپی شانون مقدار آنتروپی هریک از پارامترهای ورودی تعیین شد سپس با توجه به این که مقدار بیش تر آنتروپی بیانگر تأثیرگذاری بیش تر این پارامتر نسبت به سایر پارامترها در مدل سازی می باشد. بنابراین با توجه به شکل ۴ نتیجه می شود که تأثیر بارش، ماه از سال و دمای هوا در مدل سازی دبی بر میزان خروجی بیش تر بوده و می توان به عنوان پارامترهای ورودی به مدل ها معرفی گردد که شکل ۴ هم این مفهوم را تایید

از اوایل دهه ۱۹۹۰ تاکنون، این شبکه های عصبی مصنوعی در زمینه هیدرولوژی نیز به طور موفقیت آمیز به کار رفته گرفته شده اند. (۲۵). حدود ۹۰٪ شبکه هایی که در مسایل هیدرولوژی کاربرد دارد شبکه های پیشرو هستند (۲۶). معماری معمول این شبکه متشکل از سه لایه ورودی، پنهانی و خروجی است. تعداد نرون های موجود در لایه ورودی و خروجی بستگی به نوع مسأله دارد ولی تعداد گره های لایه پنهان با سعی و خطا به دست می آید شبکه های پیشرو، اتصالات میان گره هایی وجود دارد که در لایه های متفاوت قرار دارند. هم چنین ورودی ها در لایه ورودی شبکه نمایش داده شده و عمل تحریک از ورودی به سمت خروجی شبکه شروع می شود (۲۷).

لازم به ذکر است که در تحقیق حاضر از تعداد نرون های ۱ تا ۳۰ برای لایه پنهان شبکه استفاده گردید تا از این طریق تأثیر ساختار مختلف شبکه بر عملکرد آن در شبیه سازی مقادیر کیفی آبخوان را مورد ارزیابی قرار داد. از آنجا که متداول ترین نوع توابع محرک تابع تانژانت سیگموئید می باشد بنابراین در این مطالعه از آن برای نگاشت اطلاعات از لایه ورودی به لایه پنهان و همچنین برای نگاشت اطلاعات از لایه پنهان به لایه خروجی استفاده شد.


معیارهای ارزیابی

برای استفاده از داده های ورودی تعیین شده، در مدل های هیبریدی هوشمند ابتدا داده ها به دو قسمت تقسیم بندی شدند، ۷۵ درصد برای آموزش مدل و ۲۵ درصد برای بخش صحت سنجی استفاده گردید. به منظور افزایش کارایی مدل، همه داده ها ابتدا به شکل نرمال بین دو عدد ۰ و ۱ استاندارد شدند سپس آن ها به مقادیر اولیه بعد از استفاده در شبیه سازی برگشتند.

$$X_n = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (4)$$

در این X_i رابطه داده های مشاهداتی، X_n داده های استاندارد شده، X_{min} و X_{max} ترتیب معرف داده های بیشینه و کمین = می باشد. برای مقایسه داده های مشاهداتی و پیش بینی شده از شاخص های آماری ضریب تبیین (R^2)، ریشه متوسط مربعات خطا (RMSE) و شاخص پراکندگی (SI)

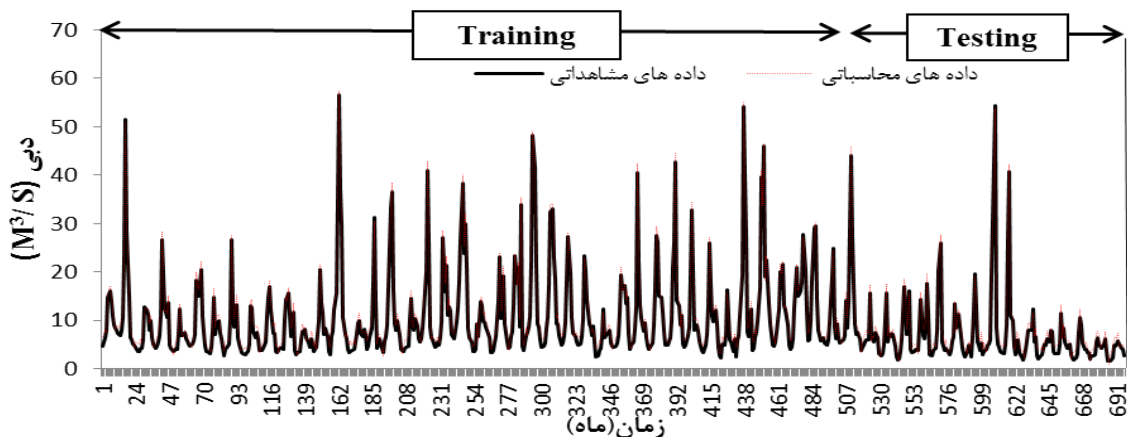
می‌کند. جدول ۲ مقادیر شاخص آماری محاسبه شده مربوط به نتایج بخش آموزش و تست در مدل های هوشمند را نشان می‌دهد.



شکل ۴- مقدار آنتروپی هر یک از پارامترهای ورودی به مدل
Figure 4. Entropy value of each of the input parameters to the model

جدول ۲- نتایج شبیه سازی با مدل های هیبریدی هوشمند در مراحل آموزش و تست
Table 2. Simulation results in terms of training and testing of intelligent hybrid models

مدل	پارامترهای بهینه	آموزش		تست	
		SI	R ²	SI	R ²
ANN	۳-۴-۱	۰/۴۰	۰/۷۴	۰/۳۹	۰/۷۰
SVM-SA	$\delta=18, \alpha=1/5, \beta=2/6$	۰/۱۴	۰/۹۷	۰/۱۶	۰/۹۵
SVM	$\beta=2, \alpha=0, \delta=0,95$	۰/۳۸	۰/۷۵	۰/۴۰	۰/۷۱
SVM-PSO	$C1=C2=2/5, P=30, W=50$	۰/۲۶	۰/۸۸	۰/۲۹	۰/۸۵
ANN-PSO	$C1=C2=2/5, P=30, W=50$	۰/۲۱	۰/۸۹	۰/۲۴	۰/۸۸
ANN-SA	$\delta=18, \alpha=1/5, \beta=2/6$	۰/۲۱	۰/۹۰	۰/۲۲	۰/۸۹



شکل ۵- مقادیر مشاهده‌ای و پیش‌بینی شده دبی با مدل الگوریتم هیبریدی تکامل تفاضلی (مدل برتر) بخش آموزش و صحت سنجی

Figure 5. The observed and predicted values hybrid differential evolution algorithm Dubai model (model) training and validation

بحث و نتیجه گیری

نتیجه و موفق ترین مدل مبدل مبدل است به مدل الگوریتم هیبریدی شبیه سازی تبرید بر پایه ماشین بردار پشتیبان (SVM-SA) با میزان ضریب تبیین (R^2) در بخش آموزش در حدود ۰/۹۵ و شاخص پراکندگی (SI) برابر با ۰/۱۴ و جذر میانگین مربعات خطا (RMSE) برابر با ۱/۲۵ مترمکعب بر ثانیه و در بخش آزمون با ضریب تبیین (R^2) حدود ۰/۹۳ و شاخص پراکندگی (SI) برابر با ۰/۱۶ و جذر میانگین مربعات خطا (RMSE) برابر با ۱/۳۲ مترمکعب بر ثانیه نسبت به تمام ترکیب های مدل سازی شده از دقت بالاتری برخوردار است.

با توجه به نتایج به دست آمده در بخش مدل سازی، می توان الگوریتم هیبریدی شبیه سازی تبرید را به عنوان مدلی با دقت و سرعت پردازش بالا در مدل سازی مسایل هیدرولوژیکی و مسایلی با پارامترهای ورودی تأثیرگذار بر پارامتر خروجی، پیشنهاد نمود. همچنین با توجه به نتایج به دست آمده، تئوری آنتروپی را به عنوان روش دقیق و بهینه در جهت کاهش مراحل سعی و خطا در تعیین پارامترهای ورودی در مدل سازی استفاده کرد.

Reference

1. Farajzadeh, J., FakheriFard, A. and Lotfi, S. 2014. Modeling of monthly rainfall and runoff of Urmia lake basin using feed-forward neural network and time series analysis model. *Water Resources and Industry*. 7 (8).38-48.
2. Hassan, R. Cohanin, B. Weck, O. 2004. A comparison of particle swarm optimization and the genetic algorithm. *American Institute of Aeronautics and Astronautics*. 4(1).12-33.
3. Chau, K. 2006. Particle swarm optimization training algorithm for ANNs in stage prediction of Shing Mun River. *Journal of hydrology* 329(3): 363-367
4. Chau, K. 2007. A split-step particle swarm optimization algorithm in river

در این تحقیق سعی بر آن شد که عملکرد تئوری آنتروپی شانون برای تعیین ترکیب بهینه ورودی های مدل های هوشمند در سری های زمانی مورد بررسی قرار گیرد. با توجه به نتایج در جدول ۲ ملاحظه می گردد در همه مدل ها قسمت آموزش موفق تر از قسمت تست بوده است، که این امری طبیعی است و نشان از آموزش خوب مدل ها است. که البته در قسمت نتایج تست همه مدل ها مشاهده می شود که نتایج به قسمت آموزش نزدیک است که این دلالت بر تایید نتیجه گیری قبلی دارد و علاوه بر آن نشان می دهد که عملیات هیبرید کردن الگوریتم ها موفقیت آمیز بوده است. و همچنین مشاهده می شود که تمام مدل های هیبریدی از پایه خود موفق تر بوده اند یعنی الگوریتم شبیه سازی تبرید بر پایه ماشین بردار پشتیبان با دقت برابر مجذور مربعات خطای ۱/۳۲ برای بخش تست عمل کرده است این در حالی است که پایه این مدل هیبریدی یعنی ماشین بردار پشتیبان با دقت برابر مجذور مربعات خطای ۳/۵۵ عمل کرده است. و همین طور مدل الگوریتم هیبریدی شبیه سازی تبرید بر پایه شبکه عصبی مصنوعی برای بخش تست با دقت برابر مجذور مربعات خطای ۲/۱۸ عمل کرده است در حالی که شبکه عصبی مصنوعی با دقت بخش تست برابر مجذور مربعات خطای ۳/۳۶ عمل کرده است. همان طور که گفته شد مدل های هیبریدی موفق تر از پایه خود بودند که نتیجه گیری ذکر شده این امر را تایید می کند.

در مدل الگوریتم هیبریدی ازدحام ذرات، هیبرید شدن با پایه ی شبکه عصبی مصنوعی دقت بیشتری داشته است نسبت به هیبرید شدن با پایه ی ماشین بردار پشتیبان، که نتایج بخش تست برای این الگوریتم به ترتیب برای معیار مجذور مربعات خطا برابر با ۲/۲۰ است. اما در مدل هیبریدی شبیه سازی تبرید نتایج متفاوت است، یعنی در این مدل هیبرید شدن با پایه ی ماشین بردار پشتیبان موفقیت آمیز تر بوده است نسبت به هیبرید شدن با شبکه عصبی مصنوعی، که نتایج بخش تست مربوط به معیار مجذور مربعات خطای این مدل با ماشین بردار پشتیبان برابر ۱/۳۲ و با شبکه عصبی برابر ۲/۱۸ است. بهترین

12. Chen, sh., 2015. Mining Informative Hydrologic Data by Using Support Vector Machines and Elucidating Mined Data according to Information Entropy, 17, 1023 – 1041.
13. Amorocho, J. and B. Espildora. 1973. Entropy in the assessment of uncertainty in hydrologic systems and models. *Water Resour. Res.* 9(6): 1551-1522.
14. Chiang, W, Hui-Chung, Y. 2014. Spatiotemporal Scaling Effect on Rainfall Network Design Using Entropy. *Entropy*, 16, 4626-4647.
15. Remesan, R. Shamim, M.A. and Han, D. 2008. Model data selection using gamma test for daily solar radiation estimation. *Hydrological Processes*, 22: 4301-4309.
16. Chen, sh. 2016. Application Hydrologic Data Mining Using Artificial Neural Network, *Entropy*. 12, 83 –98.
17. Masoumi, F., Karachian, R., 1387. Evaluating the efficiency of groundwater quality monitoring systems using discrete entropy theory. *Case Study: Tehran Aquifer, Water and Wastewater Journal*, Volume 19, Issue 1, 12-2 (In Persian).
18. Harmancioglu, N. B. 1984. Entropy concept as used in determination of optimum sampling intervals. *Proc. of Hydrosoft 84, International Conf. on Hydraulic Engineering Software*, September 10-14, 1984. Portoroz, Yugoslavia, pp. 6-99 and 6-110.
19. Kennedy, J. Russell, E 2011. Particle swarm optimization. *Encyclopedia of machine learning*, Springer: 760-766
20. Gonzalez R. C. and Perez V. S., (2001). Two procedures for stochastic simulation of vuggy formations, SPE stage forecasting. *Journal of hydrology*, 346(3): 131-135.
5. Harmancioglu, N. B. and N. Alpaslan. 1992. Water quality monitoring network design: A problem of multi-objective decision making. *Water Resour. Bull.* 28(1): 179-192.
6. Guey-Shin S, Bai-You C, Chi TC, Pei HY, Tsun KC. 2011. Applying Factor Analysis Combined with Kriging and Information Entropy Theory for Mapping and Evaluating the Stability of Groundwater Quality Variation in Taiwan. *International Journal Environmental Resources Public Health*, 8: 1084-1109
7. Singh, V. P. and K. Singh. 1985. Derivation of the Pearson type (PT)-III distribution by using the principle of maximum entropy (POME). *J. Hydrol.* 80: 197–214.
8. Misra, D. T., Oommen. A., Agarwal. A., Mishra. S.K. 2009. Application and analysis of Support Vector machine based simulation for runoff and sediment yield. *Biosystems Engineering*, 103, 527-535.
9. Carmona, G., Molina. J.L., Bromley. J., Varela-Ortega. C., Garcia-Arostegu. J.L., 2011. Object Oriented Bayesian network for participatory water management: Two case studies in Spain. *Journal of Water resources planning and management*, 137, 366-376.
10. Karamouz, M., A. K. Nokhandan, R. Kerachian and C. Maksimovic. 2009. Design of on-line river water quality monitoring systems using the entropy theory: a case study. *Environ. Monit. Assess.* 155(1-4): 63-81.
11. Karimi Hoesini, A., 2009. Compare the methods of locating the rain-gauge stations in the GIS environment.

- 2006, Flood estimation at ungauged sites using artificial neural networks. *Journal of Hydrology*. 319 (1-4): 391-409.
26. Coulibaly, P., Anctil, F., Bobée, B., 2000. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach. *Journal of Hydrology*, Vol. 230, PP. 244-257.
27. ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. 2000. Artificial neural networks in hydrology. I preliminary concepts. *Journal of Hydrologic Engineering*, Vol.5, PP.115-123.
28. Shannon CE, Weaver W. 1949. *The Mathematical Theory of Communication*. University of Illinois Press: Urbana, IL.
- 69663, Latin American and Caribbean Petroleum Engineering Conference, Buenos Aires, Argentina, pp. 25–28 March.
21. Tran N. H. and Tran K., 2007. Combination of fuzzy ranking and simulated annealing to improve discrete fracture inversion Elsevier”, *Mathematical and Computer Modeling*, Vol. 45, pp. 1010– 1020.
22. Fabian V., 1997. *Simulated annealing simulated computers & mathematics with applications*, Vol. 33, No. 1/2, pp.81-94.
23. Pai, PF.; WC. Hong. 2007. A recurrent support vector regression model in rainfall forecasting. *Hydrological Process*, 21:819-827.
24. Dibike, Y., Velickov, S., Solomatine, D., Abbott, M., 2001. Model induction with of support vector machines: Introduction and applications. *Journal of Computing in Civil Engineering*, Vol. 15, PP. 208- 216.
25. Dawson, C.W., Abraham, R.J., Shamseldin, A.Y. and R.L. Wibly.