رویکردهای نوین در مهندسی عمران
ISSN PRINT: 2588-6886 ISSN ONLINE: 2588-7122، دوره سوم، شماره ۲ ،۱۳۹۸، صفحه: ۴۹-۶۲

ArchID

توسعه روش ترکیبی موجک-شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای مدلسازی چند ایستگاهه بارش-رواناب با استفاده از ابزارهای خوشه‌بندی و اطلاعات مشترک

غلامرضا عندلیب*[۱]، وحید نورانی[۲]، حسین منیری فر[۳]، الناز شرقی[۴]

[*۱] دکتری مهندسی آب و سازه های هیدرولیکی، گروه مهندسی آب، دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران
(gholamreza.andalib@gmail.com)

[۲] استاد، گروه مهندسی آب، دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران

[۳] کارشناسی ارشد مهندسی سازه، گروه مهندسی سازه، دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران

[۴] استادیار، گروه مهندسی آب، دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران

(تاریخ دریافت مقاله: ۹۸/۰۲/۱۰، تاریخ پذیرش مقاله: ۹۸/۰۵/۲۶)

چکیده

در این مقاله پیش بینی چند ایستگاهه رواناب با استفاده از تبدیل موجک و شبکه عصبی مصنوعی خودسازمانده و مدل های هوش مصنوعی در حوضه آبریز Little River Watershed (LRW) انجام گردید. بطوریکه سری های زمانی رواناب توسط تبدیل موجک تجزیه گشته و سپس زیرسری های تجزیه شده توسط شبکه عصبی مصنوعی خودسازمانده خوشه بندی گردید. در ادامه، معیار استخراج ویژگی (اطلاعات مشترک) برای انتخاب نماینده از هر خوشه جهت ورود به مدلهای هوش مصنوعی شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای پیش بینی رواناب خروجی حوضه آبریز LRW بکار گرفته شدند. مدلسازی چند ایستگاهه بارش-رواناب بر اساس خاصیت فصلی بودن انجام شده و با مدلسازی چند ایستگاهه بر اساس خاصیت مارکف مقایسه گردید. نتایج نشان داد که مدلهای هوش مصنوعی ترکیب شده با تبدیل موجک، شبکه عصبی مصنوعی خودسازمانده و اطلاعات مشترک توانایی پیش بینی رواناب چند ایستگاهه را نسبت به مدل های هوش مصنوعی که از خاصیت مارکف بهره می برند تا ۲۳ درصد بهبود می بخشد. بطور کلی، استفاده از خاصیت فصلی بودن پدیده ها به همراه کاهش ابعاد ورودی ها، می تواند به مدل های هوش مصنوعی در جهت استفاده از اطلاعات خالص داده های مشاهداتی کمک کند.

کلمات کلیدی

اطلاعات مشترک، تبدیل موجک، حوضه آبریز LRW، نقشه‌های خودسازمانده، هوش مصنوعی.

www.SID.ir

رویکردهای نوین در مهندسی عمران
ISSN PRINT: 2588-6886 ISSN ONLINE: 2588-7122، دوره سوم، شماره ۲ ،۱۳۹۸، صفحه: ۴۹-۶۲

Development of Hybrid Wavelet-Artificial Neural Network and Support Vector Machine Approach for Multi-Station Rainfall-Runoff Modeling Using Clustering and Mutual Information Tools

Gholamreza Andalib [1], Vahid Nourani [2], Hosein Monirifar [3], Elnaz Sharghi [4]*

*[*1] Ph.D. of Water and Hydrualic Structure, Department of Water Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran (gholamreza.andalib@gmail.com)*

[2] Professor, Department of Water Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran

[3] M.Sc. of Structural Engineering, Department of Structural Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran

[4] Assistant Professor, Department of Water Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran

(Date of received: 30/04/2019, Date of accepted: 17/08/2019)

ABSTRACT

Conversion of rainfall to runoff according to the laws of gravity vivifies earth, replenishes groundwater, keeps rivers and lakes full of water, and varies the landscape by the action of erosion. Large uncertainties and high non-linearity of the Rainfall-Runoff (R-R) process make it complex task to have the process-based modeling, so it is preferred to create a black box relationship between driving and resultant variables. Therefore, several black box approaches including Artificial Intelligence (AI) models have been developed and used to simulate R-R process. In this paper, WANN and WSVM models are employed for Multi-Station (MS) modeling of R-R. However in any data driven modeling, some of the inputs may have no significant relationship with the output variables. Therefore, determination of dominant input variables, is one of the indispensable challenges in the model development procedure. For this purpose, to extract main features and inputs of the WANN, WSVM methods, two kinds of data pre-processing methods of Self-Organizing Map (SOM) based clustering and Mutual Information (MI) concepts are employed in this study. Therefore, spatio-temporal investigation, identification and using all sub-basins records as a cascade-based MS analysis can improve prediction of runoff in watersheds. For this purpose, two scenarios with distinct views were used for MS modeling of R-R to identify the suitable strategy for future hydro-environmental researches. The results indicated that the proposed AI-models coupled with the SOM and MI tools improved the performance of MS runoff prediction compared to the Markovian-based models up to 23%. Nevertheless, benefit of the seasonality of the process along with reduction of dimension of the inputs could help the AI-models to consume pure information of the recorded data.

Keywords:

Mutual information, Wavelet transform, Little River watershed, Self-organizing map, Artificial intelligence.

www.SID.ir

ArchID

۱- مقدمه

بدون تردید مدلسازی دقیق فرآیند بارش- رواناب یکی از عوامل اساسی برای تصمیم گیری های مدیریتی در حوضه آبریز می باشد و اطلاعات مهمی برای صاحب-نظران و تصمیم گیرندگان عرصه مدیریت منابع آب جهت حفظ و افزایش این منبع حیات ارائه می کند. از طرفی عدم قطعیت بالا در پدیده های هیدرولوژیکی نظیر بارش-رواناب، الزام به استفاده از روش های محاسبات نرم در این نوع پدیده ها را آشکار می سازد. از این رو، تاکنون روش-های محاسبات نرم متعددی از جمله مدل‌های هوش مصنوعی برای شبیه سازی پدیده بارش-رواناب مورد استفاده قرار گرفته است. برای مثال [۱] به شبیه سازی پدیده بارش رواناب با استفاده از شبکه عصبی مصنوعی و شبکه عصبی فازی در حوضه آبریز حاجی قوشان و مقایسه نتایج این دو مدل پرداختند. [۲] با استفاده از شبکه عصبی مصنوعی بارش-رواناب حوضه آبریز پل رود را مدلسازی کرد. [۳] به مدل سازی بارش-رواناب با استفاده از سیستم استنتاج فازی عصبی پرداختند. [۴] با استفاده از مدل برنامه ریزی ژنتیکی اقدام به مدلسازی فرآیند بارش-رواناب حوضه آبریز کنت ریج واقع در کشور اندونزی نمودند. [۵] از شبکه عصبی مصنوعی هیجانی برای پیش-بینی بارش-رواناب حوضه های آبریز لابز هول کریک و حوضه آبریز مازل استفاده نمود. در این راستا، شبکه عصبی مصنوعی ANN و ماشین بردار پشتیبان SVM به عنوان روش¬های محاسبات نرم توانایی های خود را در مدلسازی و پیش بینی روند غیرخطی رواناب نشان داده¬اند [۶]، [۷]، [۸] و [۹]. با توجه به طبیعت غیرخطی و تصادفی پدیده بارش-رواناب، کاربرد مدل‌هایی نظیر SVM و ANN در این زمینه کاملاً قابل توجیه است. علیرغم ماهیت انعطاف پذیر مدل‌های SVMو ANN، این مدل ها نقایصی را در مواجهه با سیگنال های هیدرولوژیکی، که عموماً ناایستا بوده و محدوده وسیعی از مقیاس (از چند دقیقه تا چند دهه) را شامل می شود، از خود نشان می دهند. از این رو، در چنین شرایطی پیش پردازش زمانی و یا مکانی داده ها قبل از اعمال آنها به مدل‌های SVM و ANN برای غلبه بر این مشکل ضروری به نظر می رسد. تبدیل موجک زیرسری های مفیدی از سری اصلی بدست می دهد که این زیر سری ها با استخراج اطلاعات سودمند در مقیاس های مختلف، توانایی مدل را در پیش بینی کمیت مورد نظر بالا می برند. تبدیل موجک با تجزیه سری¬های زمانی، به کمک ضرایب جزئی، به تفسیر ساختار سری و دریافت اطلاعات مفید در مورد تاریخچه آن کمک می کند [۱۰] و [۱۱]. در این مقاله، مدل‌های ترکیبی موجک-شبکه عصبی WANN و موجک-ماشین بردار پشتیبان WSVM برای مدلسازی چند ایستگاهه بارش-رواناب استفاده شده-اند. با این حال در هر گونه اطلاعات استخراج شده در مدلسازی ممکن است برخی از ورودی ها آلوده به نویز باشند و یا با متغیرهای خروجی رابطه معنی داری نداشته باشند. بنابراین، تعیین ورودی های غالب و حاوی اطلاعات مفید یکی از چالش های ضروری در روند توسعه مدلهای WANN و WSVM است. بدین منظور، برای تعیین ورودی های مدل های WANN و WSVM، از شبکه عصبی مصنوعی خودسازمانده SOM و مفاهیم اطلاعات مشترک MI استفاده شده است. SOM به عنوان یک ابزار خوشه-بندی قوی یک نوع سیستم شبکه عصبی بدون نظارت است و به تازگی در زمینه های مختلف مهندسی آب به طور گسترده استفاده شده است [۱۲] و [۱۳]. از سوی دیگر، معیار MI به عنوان یک معیار غیر خطی برای داده ها و اطلاعات می تواند یک ابزار ارزشمند در انتخاب ورودی مناسب زیر سری های زمانی تجزیه شده توسط موجک باشد [۱۴]. در مجموع، بر اساس اهمیت ورودی های مدل برای به دست آوردن الگوی کلی از فرآیند بارش-رواناب، مشارکت داده های موثر حوضه آبریز از اهمیت بسیاری برخوردار است. بنابراین، شناسایی و استفاده زمانی-مکانی از اطلاعات زیرحوضه ها به عنوان یک تجزیه و تحلیل چند ایستگاهه می تواند پیش بینی رواناب در حوضه آبریز را بهبود بخشد. لازم به ذکر است که مدل های چند ایستگاهه در برخی دیگر از زمینه های هیدرولوژی مورد استفاده واقع شده اند [۱۵] و [۱۶]. بر اساس آخرین تحقیقات و بررسی های انجام شده توسط محققین، تاکنون مدلسازی چند ایستگاهه پدیده بارش-رواناب با پیش پردازش زمانی-مکانی در حوضه آبریز تاکنون انجام نگرفته است. بر همین اساس، تلاش این مقاله نه تنها پیش¬بینی رواناب خروجی حوضه آبریز بلکه اطلاع یافتن از وقایع درون حوضه آبریز

www.SID.ir

نیز می باشد. یعنی پیش‌بینی میزان رواناب در درون حوضه نیز صورت خواهد گرفت. جهت توضیح بیشتر، از زیرحوضه های ابتدایی و مولد جهت پیش بینی رواناب زیرحوضه های میانی و از زیرحوضه های میانی جهت پیش-بینی رواناب خروجی حوضه بهره گرفته خواهد شد که این کار سبب آماده شدن بستر مناسب جهت اطلاع یافتن از مقادیر رواناب در قسمتهای مختلف حوضه را فراهم می¬سازد. برای این منظور در این مقاله برای مدلسازی چند ایستگاهه بارش-رواناب از دو سناریو با دو دیدگاه متفاوت استفاده شده است تا مطلوب ترین آنها برای استفاده در کارهای آتی در مسائل هیدرولوژیکی معرفی گردد. در سناریوی اول خاصیت مارکف پدیده بارش-رواناب مورد توجه قرار گرفته است بطوریکه از سوابق بارش و رواناب در روزهای گذشته برای پیش بینی رواناب خروجی زیرحوضه مورد نظر استفاده شده است. از طرف دیگر، برای تعیین ورودی های مدل های هوش مصنوعی ANN و SVM از معیار MI به جای معیار خطی ضریب همبستگی استفاده شده است تا از سعی و خطا برای انتخاب ورودی مدل ها جلوگیری شود. در سناریوی دوم خاصیت فصلی بودن پدیده بارش-رواناب مد نظر قرار گرفته شده است، بطوریکه سری¬های زمانی رواناب در سطح مناسب جهت استخراج زمان و طیف تجزیه شدند. سپس زیرسری های زمانی همگن توسط SOM، خوشه بندی شده و از هر خوشه یک نماینده جهت ورود به مدل هوش مصنوعی توسط MI انتخاب گردید تا رواناب محل های مورد نظر در حوضه آبریز LRW پیش‌بینی شوند.

۲- مواد و روش ها

۲-۱- منطقه مورد مطالعه

حوضه آبریز LRW واقع در ایالت جورجیا بوده که با وسعتی معادل ۳۳۴ کیلومتر مربع در جنوب ایالات متحده آمریکا قرار دارد. داده های مورد استفاده از ژانویه سال ۱۹۹۰ تا دسامبر سال ۲۰۱۲ میلادی می¬باشد که از سایت ftp://www.tiftonars.org اقتباس شده اند (شکل ۱، جدول ۱). در این مقاله ۷۵ درصد داده ها (از ژانویه ۱۹۹۰ تا آوریل ۲۰۰۷) برای آموزش و ۲۵ درصد داده‌ها (از مه ۲۰۰۷ تا دسامبر ۲۰۱۲) برای صحت سنجی در مدل های هوش مصنوعی مورد استفاده قرار گرفته شد.

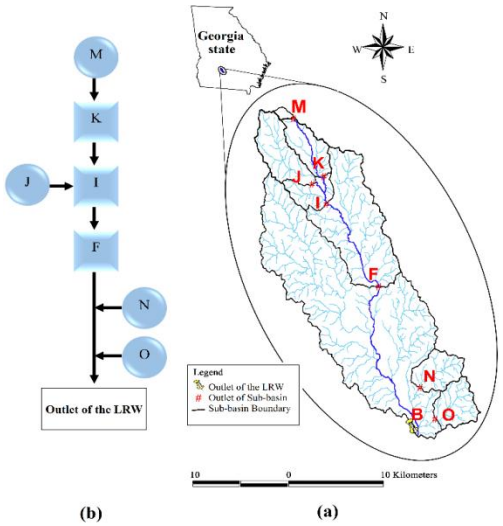

شکل ۱: منطقه مورد مطالعه و مدل آبشاری حوضه آبریز LRW [۱۷].

www.SID.ir

جدول ۱: مشخصات آماری حوضه آبریز LRW.

Sub-basins	Average		Channel slope %	Mean runoff×100 / area	Drainage area (km^2)
	Runoff (m^3/s)	Rainfall (mm)			
B	۳/۰۸۵	۳/۱۲	۰/۱۰	۳۹/۱۰	۰/۹۲
F	۱/۱۸۳	۳/۱۶	۰/۱۴	۲۴/۰۲	۱/۰۳
I	۰/۵۹۲	۳/۱۸	۰/۲۲	۲۱/۱۷	۱/۱۸
J	۰/۲۵۸	۳/۱۸	۰/۲۵	۱۰/۳۰	۱/۱۶
K	۰/۱۹	۳/۱۸	۰/۲۹	۸/۷۳	۱/۱۴
M	۰/۰۲	۳/۰۷	۰/۳۳	۲/۴۵	۰/۷۶
N	۰/۱۵	۳/۰۹	۰/۳۲	۱۰/۴۴	۰/۹۶
O	۰/۱۷	۳/۰۹	۰/۳۷	۶/۱۱	۱/۰۷

۲-۲- مدل پیشنهادی

از آنجایی که پدیده بارش-رواناب یک پدیده پیچیده هست، بدین منظور از مدلهای هوش مصنوعی غیر خطی نظیر ANN و SVM برای مدلسازی چند ایستگاهه بارش-رواناب استفاده شد. هدف مدلسازی چند ایستگاهه بارش-رواناب در این مقاله، پیش بینی رواناب زیرحوضه-های میانی و خروجی با استفاده از اطلاعات زیرحوضه های مرتبط و همچنین اطلاع یافتن از نحوه جریان رواناب در درون حوضه می باشد. بنابراین، مدلسازی چند ایستگاهه به هیدرولوژیست ها این امکان را می دهد که با اطلاع از رواناب درون حوضه، تصمیم گیری های به مراتب قطعی تر داشته باشند. شکل (۱) مدلسازی چند ایستگاهه حوضه آبریز LRW را به طور شماتیک نشان می دهد بطوریکه زیرحوضه هایی که با دایره مشخص شده اند مبدل بارش به رواناب و زیرحوضه هایی که با مربع مشخص شده اند مبدل و منتقل کننده رواناب هستند. در مدلسازی چند ایستگاهه مورد نظر رواناب زیرحوضه I با استفاده از زیرحوضه‌های M، K و J پیش بینی شده است. در گام دوم، رواناب زیرحوضه F با استفاده از رواناب زیرحوضه I پیش بینی شده است و در آخر رواناب خروجی حوضه LRW در ایستگاه B، با استفاده از زیرحوضه های F، O و N محاسبه شد. بدین ترتیب الگوی پیش¬بینی چند ایستگاهه با سه گام مدلسازی بمانند مخازن آبشاری مرتبط تکمیل می گردد. ذکر این نکته نیز ضروری است که با استفاده از مدلسازی چند ایستگاهه می توان داده های مفقود شده سری های زمانی در ایستگاه های هیدرومتری آسیب دیده را نیز ترمیم کرد. مدلسازی چند ایستگاهه با استفاده از سناریوی مارکف و فصلی در بخش های زیر شرح داده شده است (شکل۲).



شکل ۲: مراحل سناریوی یک و سناریوی دو.

www.SID.ir

۲-۲-۱- سناریوی اول

در سناریوی اول، خاصیت مارکف پدیده بارش-رواناب اساس مدلسازی چند ایستگاهه قرار گرفته است، بطوریکه پیش بینی رواناب زیرحوضه های I و F و B بصورت زیر صورت گرفته است. رواناب زیرحوضه I با استفاده از رواناب زیرحوضه های M، K و J و همینطور بارش زیرحوضه I پیش بینی شده است.

$$Q_t^I = f_n\left(I_t^I, Q_t^M, \ldots, Q_{t-p_M}^M, Q_t^K, \ldots, Q_{t-p_K}^K, Q_t^J, \ldots Q_{t-p_J}^J\right) \quad (۱)$$

که رواناب (Q) زیرحوضه F در زمان t تابعی (fn) از بارش (I) زیرحوضه I در زمان t و رواناب زیرحوضه های M، K و J در زمان t تا زمان چند روز گذشته pM، pK و pJ می باشد. البته باید اشاره گردد که بارش زیرحوضه های بالادستی تأثیر خود را در میزان رواناب آنها در روزهای بعد گذاشته است. اما انتخاب داده های مناسب از میان انبوه داده ها، مهمترین گام در مدلسازی چند ایستگاهه تلقی می‌گردد. از این رو، معیار نظارت شده MI جهت انتخاب ورودی به مدل ها به جای روش سعی و خطا مورد استفاده قرار گرفت بطوریکه از میان داده های بالقوه، آن دسته از داده هایی که دارای بیشترین مقدار MI با خروجی مدل می‌باشند به عنوان ورودی مدل انتخاب گردیدند. کارایی بالای ضریب MI نسبت به معیار خطی ضریب همبستگی در تحقیقات اخیر گزارش شده است [۱۴]. به همین ترتیب، رواناب زیرحوضه F با استفاده از رابطه (۲) و رواناب خروجی حوضه (ایستگاه B) با استفاده از رواناب زیرحوضه‌های F، O و N توسط رابطه ۳ پیش‌بینی شدند.

$$Q_t^F = f_n\left(I_t^F, Q_t^I, \ldots, Q_{t-p_I}^I\right) \quad (۲)$$

$$Q_t^B = f_n\left(I_t^B, Q_t^F, \ldots, Q_{t-p_F}^F, Q_t^N, \ldots, Q_{t-p_N}^N, Q_t^O, \ldots Q_{t-p_O}^O\right) \quad (۳)$$

۲-۲-۲- سناریوی دوم

در سناریوی دوم، رویکرد به خاصیت فصلی پدیده بارش-رواناب در حوضه آبریز LRW معطوف بوده است. در این سناریو هدف استفاده از فرکانس های غالب سری‌های زمانی زیرحوضه ها با توجه به حذف اطلاعات زائد بصورت ذیل بوده است، برای پیش بینی رواناب زیرحوضه I سه گام پشت سرگذاشته شد. درگام اول، سری های زمانی رواناب زیرحوضه های M، K و J توسط تبدیل موجک در سطح q جهت رفع ناایستایی و استخراج خاصیت فصلی سری های زمانی تجزیه شدند، بطوریکه رواناب زیرحوضه I به زیرسری‌های زیرحوضه های بالادستی مرتبط گردید:

$$\begin{aligned} Q_t^I = f_n\left(I_t^I, Q_a^M, Q_{d1}^M, \ldots Q_{dq}^M, Q_a^K, Q_{d1}^K, \ldots,\right. \\ \left. Q_{dq}^K, Q_a^J, Q_{d1}^J, \ldots Q_{dq}^J\right) \end{aligned} \quad (۴)$$

که Q_a^M و Q_{dq}^M نیز زیرسری تقریب و زیرسری جزء رواناب در سطح q در زیرحوضه M می باشند. بطور مشابه دیگر زیرسری‌های زمانی نیز مرتبط به زیرحوضه‌های K و J می باشند. در گام دوم، بدلیل حجم انبوهی از داده ها، ابزار خوشه بندی جهت خوشه بندی مکانی-زمانی زیرسری های همگن بکار گرفته شد و در گام آخر، بمانند سناریوی اول، ابزار MI جهت انتخاب نماینده مناسب از هر خوشه برای ورود به مدل های هوش مصنوعی برای پیش¬بینی رواناب زیرحوضه I استفاده گردید. بطور مشابه، برای پیش بینی رواناب زیرحوضه های F و B از روابط (۵ و ۶) استفاده گردید. ابزارهای مورد نیاز برای دو سناریوی مورد نظر در بخش¬های ذیل توضیح داده شده اند.

www.SID.ir

$$Q_t^F = f_n\,(I_t^F, Q_a^I, Q_{d1}^I, \ldots, Q_{dq}^I) \quad (۵)$$

$$Q_t^B = f_n\,(I_t^B, Q_a^F, Q_{d1}^F, \ldots, Q_{dq}^F, Q_a^N, Q_{d1}^N, \ldots, Q_{dq}^N, Q_a^O, Q_{d1}^O, \ldots, Q_{dq}^O) \quad (۶)$$

۲-۳- تبدیل موجک و آنتروپی شانون

در این تحقیق از تبدیل موجک گسسته برای تفکیک سری های زمانی به زیرسری ها با فرکانس های متفاوت استفاده گردید [۱۸]:

$$g_{m,n}(t) = \frac{1}{\sqrt{a_0^m}}\, g^*\left(\frac{t - nb_0a_0^m}{a_0^m}\right) \quad (۷)$$

در رابطه فوق $g(t)$ تابع موجک مادر و $g^*(t)$ تابع مختلط و مرکب می باشد. m و n اعداد صحیحی هستند که به ترتیب میزان مقیاس و انتقال موجک را کنترل می نمایند. همچنین a_0 گام مقیاس کوچک ویژه برای پارامتر انتقال ($a_0>1$) و b_0 پارامتر انتقال موقعیت ($b_0>0$) می باشند. معمولی ترین حالت برای پارامترهای رابطه فوق مقادیر مقادیر $a_0=2$ و $b_0=1$ هستند که این مقیاس لگاریتمی با توان دو برای انتقال و مقیاس تحت عنوان آرایش شبکه دوتایی نامیده می شود. همچنین آنتروپی شانون برای انتخاب زیر سری-های زمانی غالب بکار گرفته شد. شانون آنتروپی (محتوای اطلاعاتی) را به صورت ریاضی و با استفاده از توزیع احتمالاتی داده¬ها فرمول¬بندی کرده و آن را به عنوان معیار سنجش بی¬نظمی، آشفتگی، عدم قطعیت و اطلاعات معرفی کرد. اگر X متغیر تصادفی گسسته با مقادیر $x1,x2,\ldots,xN$ و احتمالات متناظر $p1,p2,\ldots,pN$ باشد، آنتروپی شانون از رابطه ۹ محاسبه می‌شود [۱۹]:

$$H(X) = H(P) = \sum_{i=1}^{N} - p(x_i)\log[p(x_i)] \quad (۸)$$

که در این رابطه $H(X)$ آنتروپی X است که تابع آنتروپی شانون نیز نامیده می شود. MI نیز به صورت زیر تعریف می شود [۲۰]:

$$MI(X, Y) = H(X) + H(Y) - H(X, Y) \quad (۹)$$

$H(X,Y)$ نیز آنتروپی مشترک می‌باشد:

$$H(A, B) = -\sum_{a\in A}\sum_{b\in B} p_{AB}(a,b)\log p_{AB}(a,b) \quad (۱۰)$$

۲-۴- نقشه خود سازمانده

SOM یک الگوریتم جدید و موثر برای تجسم و خوشه‌بندی اطلاعات با ابعاد بزرگ است. این ابزار مجموعه‌ای از داده‌های با بعد بالا را با بر روی یک شبکه منظم کم بعد نگاشت می‌دهد، این ابزار توانایی تبدیل روابط آماری پیچیده و غیرخطی داده‌های با بعد بالا را به روابط ساده هندسی در صفحه نمایش کم بعد داده‌ها دارا است (داده‌ها با ویژگی‌های مختلف را در نقشه‌های ۲ بعدی نشان می‌دهد) [۲۱]. برای خوشه‌بندی SOM در دو مرحله برای کاهش ابعاد فضای ورودی مدل بکار گرفته شده‌است. در مرحله‌ی اول SOM دو بعدی برای بدست آوردن دید کلی نسبت به ساختار سری‌ها و تعیین تعداد تقریبی خوشه‌ها استفاده شده است. سپس

www.SID.ir

در مرحله‌ی دوم برای اطمینان از خوشه بندی تعیین شده از یک SOM یک بعدی با اندازه‌ی تعیین شده در مرحله‌ی اول استفاده شد تا سری‌ها خوشه بندی شوند. در SOM دو مرحله‌ای، در ابتدا لایه‌ی خروجی یا Kohonen ۶ در ۶ درنظر گرفته شد و سپس در مرحله‌ی دوم SOM یک بعدی با اندازه ۶ در ۱ برای بدست آوردن بهترین ساختار خوشه بندی بکار گرفته شد.

۲-۵- ابزارهای مدلسازی

دراین تحقیق از شبکه عصبی مصنوعی با ساختار سه لایه FFNNs بر پایه ترکیب خطی از متغیرهای ورودی است که با یک تابع محرک غیرخطی تبدیل می یابد استفاده گردیده است که این ساختار از شبکه به این دلیل شبکه پیشرو نامیده می شود که چگونگی ارتباط میان نرون ها به گونه ای است که از لایه ورودی به لایه مخفی و از این لایه به لایه خروجی اتصال می یابند و درون یک لایه نیز نرون ها به یکدیگر ارتباط پیدا نمی کنند [۲۲]. همچنین برای مدل SVM از نوع حاشیه نرم با الگوریتم حداقل مربعات LSSVM استفاده شده است که برخلاف سایر انواع شبکه‌های عصبی (ANFIS, RBF, MLP) به‌جای اینکه خطای مدل‌سازی یا طبقه‌بندی را کمینه کنند، ریسک عملیاتی را به‌عنوان تابع هدف در نظر می‌گیرند و مقدار بهینه آن را محاسبه می‌کند. اگر فرض بر طبقه‌بندی یک مجموعه داده به دو گروه باشد، در واقع کاری که شبکه عصبی SVM انجام می‌دهد، ریسک عدم طبقه‌بندی صحیح را بصورت سری کمیت‌های عددی بیان کرده، سپس مقدار کمینه آن را محاسبه می کند؛ اما یک شبکه عصبی MLP هر موقع تفکیک درست باشد یا مقدار خطای تفکیک کمینه باشد آن را به‌عنوان راه حل ارائه می کند. ماشین بردار پشتیبان الگوریتمی است که نوع خاصی از مدل های خطی را می‌یابد که حداکثر حاشیه ابر صفحه را حاصل می کنند. حداکثر کردن حاشیه ابر صفحه منجر به حداکثر شدن تفکیک بین دسته ها می‌شود. به نزدیکترین نقاط آموزشی به حداکثر حاشیه ابر صفحه، بردارهای پشتیبان اطلاق می گردد و تنها از این بردارها برای مشخص کردن مرز بین دسته ها استفاده می شود. قواعد تصمیم گیری که تعریف می‌شود و توسط یک صفحه بهینه که طبقات تصمیم گیری باینری را تفکیک می کند، به صورت رابطه (۱۱) است [۲۳].

$$y = \sum_{i=1}^{N} \gamma e_i K(X.X_i) + b \qquad (۱۱)$$

که در آن y خروجی معادله، ei ارزش طبقه نمونه آموزشی Xi و . نشان دهنده ضرب داخلی و γ ضریب کرنل است. بردارهای x=(x1,x2,...,xn) نشان دهنده یک داده ورودی و بردارهای Xi بردارهای پشتیبان هستند. در این تحقیق، از SVM نوع حاشیه نرم با الگوریتم حداقل مربعات LSSVM استفاده شده است. در هسته مدل LSSVM نیز از کرنل RBF با پارامتر σ استفاده گردیده است زیرا این نوع کرنل بالاترین میزان کارایی را در مدل های هیدرولوژیکی داشته است [۲۳].

$$K(X.X_i) = \exp\left(\frac{\|x - x_i\|^2}{2\sigma^2}\right) \qquad (۱۲)$$

۲-۶- معیار کارایی مدل

یک مدل مناسب نتایج قابل قبولی از نظر ضریب تبیین DC[1] و جذر میانگین مربعات خطا RMSE[2] در مراحل آموزش و صحت‌سنجی نشان می‌دهد؛ بنابراین برای ارزیابی کارایی مدل، روابط (۱۳ و ۱٤) جهت مقایسه‌ی عملکرد مدل‌های مختلف ارائه شده است [11]:

1 Determination Coefficient
2 Root Mean Square Error

www.SID.ir

$$DC = 1 - \frac{\sum_{i=1}^{N}(O_{obs_i} - O_{com_i})^2}{\sum_{i=1}^{N}(O_{obs_i} - \overline{O}_{obs})^2} \quad (۱۳)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{N}(O_{obs_i} - O_{com_i})^2}{N}} \quad (۱۴)$$

در این روابط T، O_{obs_i}، O_{com_i} و $\overline{O}_{obs_i}$ به ترتیب تعداد مشـــاهداتی، داده‌های مشـــاهداتی، داده‌های محاســـباتی و میانگین داده‌های مشاهداتی است.

۳- نتایج و بحث

نتایج مدلسازی چند ایستگاهه با استفاده از داده-های زیرحوضه های LRW با استفاده از دو سناریوی مجزا در بخش های زیر شرح داده شده اند. نتایج حاصل از مدل-های FFNN و LSSVM نیز در هر دو سناریو مقایسه شدند.

۳-۱- نتایج سناریوی یک

در مدل های داده محور FFNN و LSSVM، انتخاب داده-های مناسب نقش بسزایی در افزایش کارایی مدل در هر دو بخش آموزش و صحت سنجی دارد، ضمن اینکه از بیش برازش مدل نیز جلوگیری به عمل می آید. بدین منظور، معیار MI جهت انتخاب ورودی های مناسب و همینطور زمان تأخیر بهینه برای پیش بینی رواناب زیرحوضه ها بکار گرفته شد. جدول (۲) نتایج آنالیز حساسیت با استفاده از معیار MI را برای مدلسازی چند ایستگاهه نشان می دهد. نتایج مدلسازی چند ایستگاهه برای زیرحوضه‌های داخلی I و F و خروجی حوضه LRW (ایستگاه B) در جدول (۲) ارائه شده است. همانطور که قبلاً اشاره شد، برای هر مدل، ورودی های غالب (جدول ۲، ستون چهارم) بوسیله ضریب MI انتخاب گردید. به علاوه بوسیله برازش FFNN و LSSVM های مختلف برای تمامی زیرحوضه های LRW (یک مدل هوش مصنوعی برای هر زیرحوضه بطور مجزا)، بروز رسانی سری های زمانی رواناب در آینده امکان پذیر خواهد بود. از طرف دیگر، برای درک بیشتر پدیده بارش-رواناب و ارزیابی ورودی های مدلهای محاسبات نرم چند ایستگاهه، جریان رواناب در حوضه آبریز LRW بررسی گردید. با توجه به وسعت نسبتاً کوچک حوضه آبریز LRW میانگین بارش در زیرحوضه ها تقریباً یکسان است. بنابراین نحوه تفاوت جریان رواناب در زیرحوضه ها متاثر از جنس خاک یعنی کاربری و پوشش زمین خواهد بود که بر اساس نوع کاربری زمین بیشترین و کمترین میزان نفوذ آب در خاک با توجه به فیزیک خاک به این ترتیب می باشد: جنگل، چراگاه، مزرعه، شهر [۲۴]. پس با توجه به شرایط کلی و نوع چیدمان جنس خاک (شکل ۳)، بایستی زیر حوضه های بالادست یعنی M، K، J و I کمترین میزان رواناب خروجی نسبت به مساحتشان و زیر حوضه های پایین دست پایین دست N و O دارای بیشترین میزان رواناب خروجی نسبت به مساحتشان باشند. اما با توجه به جدول (۱) و دسته بندی پوشش زمین این امر در عمل مشاهده نمی گردد. پس می توان استنباط کرد که عدم انطباق میزان رواناب خروجی نسبت به مساحت هر زیر حوضه با نوع پوشش آن زیر حوضه در حوضه آبریز LRW منشا انسانی دارد بطوریکه در زیرحوضه های با زمین کشاورزی و چراگاه های بالا، میزان استفاده و ذخیره آب جهت مصارف کشاورزی بالا بوده که همین امر باعث کاهش میزان رواناب خروجی شان شده است در حالی که در شرایط طبیعی بدلیل کمبود مناطق جنگلی، رواناب خروجی در این مناطق باید افزایش می‌یافت. علاوه بر این، انتخاب ورودی مدل های چند ایستگاهه با استفاده از معیار MI با ژئومورفولوژی حوضه آبریز LRW مطابقت دارد. در مدل اول، برای پیش‌بینی رواناب زیرحوضه I، رواناب زیرحوضه های K و J در زمان t بدون زمان تأخیر انتخاب شدند که این امر به دلیل

www.SID.ir

نزدیکی ایستگاه های K و J با ایستگاه F و همینطور شیب بالا میان این ایستگاه¬ها بود؛ اما، رواناب زیرحوضه M با یک روز تأخیر توسط MI انتخاب گردید. در مدل دوم، رواناب زیرحوضه I با یک روز تأخیر برای پیش بینی رواناب زیرحوضه F وارد مدلهای هوش مصنوعی گردید. در مدل سوم، بدلیل شیب کم کانال و فاصله زیاد بین ایستگاههای F و B، رواناب زیرحوضه F با دو روز تأخیر وارد مدل شد. همینطور، زیرحوضه های نزدیک خروجی (N و O)، بدون تأخیر برای پیش بینی رواناب خروجی حوضه آبریز LRW وارد مدل های هوش مصنوعی گردیدند. مقایسه نتایج پیش بینی چند ایستگاهه رواناب (جدول ۲) نشان می دهد مدلهای FFNN و LSSVM نتایج قابل قبول و تقریبا یکسانی را نشان دادند. یک روش پیش پردازش مناسب همانند سناریوی دو می تواند توانایی مدل چند ایستگاهه را بهبود بخشد. در بخش بعدی نتایج مدلسازی چند ایستگاهه توسط سناریوی دو ارائه می شود.

۳-۲- نتایج سناریوی دو

در این سناریو برای مد نظر قرار دادن الگوی فصلی در مدلسازی چند ایستگاهه، از تبدیل موجک استفاده شد. در این میان، انتخاب مادرموجک مناسب، یک چالش در مدلسازی ترکیبی موجک-هوش مصنوعی به شمار می رود. وظیفه مادر موجک کشف شباهت مابین تابع موجک مورد استفاده و سری زمانی مورد تحلیل می باشد که بدلیل شباهت مادر موجک coif2 به سری های زمانی رواناب حوضه آبریز LRW نسبت به مادر موجک های دیگر نظیر db2 و db5، این مادر موجک در این تحقیق مورد استفاده قرار گرفت. علاوه بر این، انتخاب سطح تفکیک مناسب نیز در کاربرد تبدیل موجک دارای اهمیت خاصی است که در این مطالعه بدلیل مد نظر قرار دادن اکثر مدها نمود و عدم آسیب به روند خوشه بندی، سطح تفکیک ۸ برای تجزیه سری های زمانی رواناب زیرحوضه ها انتخاب گردید. سطح تجزیه ۸ شامل ۸ زیرسری جز به عنوان حالت 2^1 روزه (d1 - اولین زیر سری با فرکانس بالا)، حالت 2^2 روزه (d2 - دومین زیر سری)، 2^3 روزه (d3 - سومین زیر سری تقریبا هفتگی)، حالت 2^4 روزه (d4 - چهارمین زیر سری)، حالت 2^5 روزه (d5 – پنجمین زیر سری و تقریبا ماهانه)، حالت 2^6 روزه (d6 – ششمین زیر سری)، حالت 2^7 روزه (d7 – هفتمین زیر سری) و حالت 2^8 روزه (d8 - هشتمین زیر سری) و به همراه زیر سری تقریب می باشد.

جدول ۲: نتایج پیش‌بینی چند ایستگاهه رواناب در سناریوی یک توسط FFNN و LSSVM.

Model	Station (sub-basin)	Output	selected input variables	Network structure	DC		RMSE (normalized)	
					Calibration	Verification	Calibration	Verification
FFNN	I	Q_t^I	I_t^I, Q_t^J Q_t^K , Q_{t-1}^M	(4.5.1) [a]	۰/۷۸	۰/۷۰	۰/۰۲۸	۰/۰۳۲
	F	Q_t^F	I_t^F, Q_{t-1}^I	(2.8.1)	۰/۷۷	۰/۶۸	۰/۰۲۹	۰/۰۳۳
	B	Q_t^B	I_t^B, Q_t^N Q_t^O , Q_{t-2}^F	(4.4.1)	۰/۸۰	۰/۷۳	۰/۰۲۶	۰/۰۳۱
LSSVM	I	Q_t^I	I_t^I, Q_t^J Q_t^K , Q_{t-1}^M	(7.2)[b]	۰/۷۲	۰/۷۰	۰/۰۳۱	۰/۰۳۲
	F	Q_t^F	I_t^F, Q_{t-1}^I	(5.5)	۰/۷۰	۰/۷۰	۰/۰۳۳	۰/۰۳۲
	B	Q_t^B	I_t^B, Q_t^N Q_t^O , Q_{t-2}^F	(7.4)	۰/۷۹	۰/۷۴	۰/۰۲۷	۰/۰۳۰

www.SID.ir

[a] The first, second and third numbers represent input variable, hide neurons and output variable, respectively.
[b] RBF-Kernel structure (γ.σ).

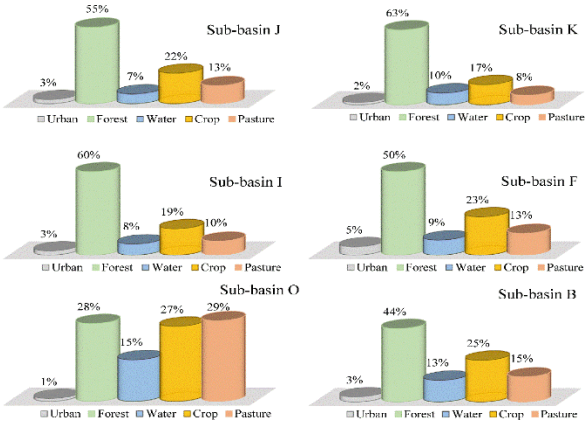

شکل ۳: کاربری حوضه آبریز LRW [۱۷].

گام بعدی در سناریوی دوم، انتخاب ورودی مناسب برای مدل های هوش مصنوعی از میان انبوه داده-های برازش و کاهش دقت پیش بینی گردد. بر این اساس در این مرحله تلاش گردید تا زیرسری های غالب از میان داده ها جهت ورود به مدل های هوش مصنوعی انتخاب گردد که این امر توسط ابزارهای SOM و MI انجام شد. بعد از تجزیه سری های زمانی رواناب زیرحوضه ها این زیرسری ها توسط ابزار SOM خوشه بندی شد تا زیرسری های همگن در یک خوشه قرار گیرند. این نوع خوشه بندی قبلاً در دیگر تحقیقات انجام پذیرفته است [۱۲]. بعد از خوشه بندی، معیار MI برای انتخاب زیرسری غالب از هر خوشه بکار گرفته شد. بمانند سناریوی اول، زیرسری که بیشترین مقدار MI را با خروجی مدل داشته باشد به عنوان ورودی به مدل هوش مصنوعی انتخاب گردید. ورودی های منتخب جهت مدلسازی چند ایستگاهه در جدول (۳) آورده شده است. در مدل اول، برای پیش بینی رواناب زیرحوضه I، زیرحوضه J با چهار زیرسری زمانی رواناب و زیرحوضه K با دو زیرسری رواناب شرکت کردند و از زیرحوضه M، هیچ زیرسری انتخاب نگردید. در مدل دوم، برای پیش-بینی رواناب زیرحوضه F، زیرحوضه I با چهار زیرسری زمانی رواناب انتخاب شدند. در مدل سوم نیز برای پیش-بینی رواناب زیرحوضه B، زیرحوضه F با بیشترین مقدار رواناب با چهار زیرسری زمانی رواناب و زیرحوضه های O و N نیز هرکدام با یک زیرسری زمانی رواناب برگزیده شدند. همانطور که ملاحظه می شود بر اساس مشخصات زیرحوضه ها، زیرحوضه های نزدیک خروجی مدل زیرسری های با فرکانس بالا و زیرحوضه¬های دور از خروجی حوضه با زیرسری های با فرکانس پایین در مدلسازی چند ایستگاهه شرکت نمودند. نتایج مدلسازی‌های چند ایستگاهه بوسیله FFNN و LSSVM در جدول (۳) برای سناریوی دو ارائه شده است.

علاوه بر سناریوهای یک و دو، روش هایFNN و LSSVM بدون پیش‌پردازش های انجام شده با شاخص MI، خوشه‌بندی و تبدیل موجک نیز برای ایستگاه خروجی طبق رابطه (۱۵) انجام گردید و نتایج نشان داد که روش مذکور بدون هیچگونه پیش پردازش با ضریب تبیین صحت سنجی ۰/۶۸ کارایی کمتری نسبت به دو سناریوی مطرح شده در این مقاله دارد.

$$Q_t^B = f_n\left(I_t^B, Q_t^F, Q_{t-1}^F, Q_{t-2}^F, Q_t^N, Q_{t-1}^N, Q_t^O, Q_{t-1}^O\right) \quad (۱۵)$$

www.SID.ir

جدول ۳: نتایج پیش‌بینی چند ایستگاهه رواناب در سناریوی دو توسط FFNN و LSSVM.

Model	Station (sub-basin)	Output	Input variables selected via SOM-MI	Network structure	DC		RMSE (normalized)	
					Calibration	Verification	Calibration	Verification
FFNN	I	Q_t^I	Q_a^K , Q_{d1}^J, Q_{d8}^J , Q_{d3}^J, Q_{d2}^J , Q_{d7}^K, I_t^I	(7.9.1)	۰/۸۸	۰/۸۳	۰/۰۲۱	۰/۰۲۴
	F	Q_t^F	Q_a^I , Q_{d8}^I, Q_{d3}^I , Q_{d7}^I, I_t^F	(5.7.1)	۰/۹۰	۰/۸۴	۰/۰۱۹	۰/۰۲۴
	B	Q_t^B	Q_a^F , Q_{d4}^N, Q_{d8}^F , Q_{d3}^O, Q_{d7}^F , Q_{d6}^F, I_t^B	(7.8.1)	۰/۸۹	۰/۸۴	۰/۰۲۰	۰/۰۲۴
LSSVM	I	Q_t^I	Q_a^K , Q_{d1}^J, Q_{d8}^J , Q_{d3}^J, Q_{d2}^J , Q_{d7}^K, I_t^I	(4.3)	۰/۸۶	۰/۸۵	۰/۰۲۲	۰/۰۲۳
	F	Q_t^F	Q_a^I , Q_{d8}^I, Q_{d3}^I , Q_{d7}^I, I_t^F	(9.3)	۰/۸۵	۰/۸۴	۰/۰۲۳	۰/۰۲۴
	B	Q_t^B	Q_a^F , Q_{d4}^N, Q_{d8}^F , Q_{d3}^O, Q_{d7}^F , Q_{d6}^F, I_t^B	(4.2)	۰/۸۶	۰/۸۶	۰/۰۲۲	۰/۰۲۲

۴- جمع بندی و نتیجه گیری

پیش بینی رواناب چند ایستگاهه حوضه آبریز LRW واقع در آمریکا بر اساس داده های روزانه بارش-رواناب زیرحوضه ها با استفاده از مدل های هوش مصنوعی FFNN و LSSVM انجام شد. این مدلسازی چند ایستگاهه برای پیش بینی رواناب زیرحوضه های درون حوضه و خروجی حوضه آبریز با استفاده از دو سناریوی فصلی و مارکف صورت گرفت. اما قبل از مدلسازی، نحوه جریان رواناب در حوضه آبریز LRW بررسی گردید و بر اساس داده¬های آماری و نوع کاربری زمین استنباط گردید زیرحوضه¬هایی که میزان چراگاه¬ها و مزارع بالایی دارند دارای بیشترین استفاده و ذخیره آب هستند.

مقایسه نتایج حاصل از مدلسازی چند ایستگاهه حوضه آبریزLRW ، تفاوت های دو سناریوی مارکف و فصلی را نشان می دهد. نتایج مدل های هوش مصنوعی نشان داد که سناریوی ۲ (فصلی) دقت بیشتری در پیش بینی رواناب نسبت به سناریوی یک (مارکف) دارا می باشد که این امر بدلیل در نظر گرفتن الگوی فصلی پدیده رواناب در سناریوی دو و همینطور انتخاب ورودی های بهینه می‌باشد. بنابراین، مدل های موجک-هوش مصنوعی که با SOM-MI ترکیب شده اند یک روش مناسب و کارآمد در مدلسازی چند ایستگاهه بارش-رواناب می باشد. بدین ترتیب که سری های زمانی زیرحوضه¬ها توسط تبدیل موجک تجزیه گشته، سپس زیرسری های همگن توسط ابزار SOM خوشه بندی گردیده و در گام بعدی از هر خوشه زیرسری غالب توسط MI برای ورود به مدل های هوش مصنوعی انتخاب شدند. پیشنهاد می گردد مدلسازی چند ایستگاهه برای مدلسازی دیگر پدیده های هیدرولوژیکی نیز بکار برده شود.

www.SID.ir

۵- مراجع

1- Ghafari, G. A., and Vafakhah, M., 2013, **Simulation of Rainfall-Runoff Process using Artificial Neural Network and Adaptive Neuro-Fuzzy Interface System (Case Study: Hajighoshan watershed)**, Journal of Watershed Management Research, 4(8), 120-136. (In Persian)

2- Pournemat Roudsari, A., Qaderi, K. and Karimi-Googhari, S., 2014, **Rainfall Runoff Modeling using Group Method of Data Handling (GMDH) and Artificial Neural Network (ANN) in Polrood Basin**, Journal of Watershed Management Research, 5(10), 68-84. (In Persian)

3- Kwin, C. T., Talei A., Alaghmand S. and Chua L. H. C., 2016, **Rainfall-Runoff Modeling Using Dynamic Evolving Neural Fuzzy Inference System with Online Learning**, Procedia Engineering 154, 1103-1109.

4- Chadalawada, J., Havlicek V. and Babovic V., 2016, **Genetic Programming Based Approach Towards Understanding the Dynamics of Urban Rainfall-Runoff Process**, Procedia Engineering, 154, 1093-1102.

5- Nourani, V., 2017, **An Emotional ANN (EANN) Approach to Modeling Rainfall-Runoff Process**, Journal of Hydrology, 544, 267-277.

6- Pournemat Roudsari, A., Khashei-Siuki A. and Karimi-Googhari, S., 2015, **Daily Rainfall-Runoff Modeling with Least Square Support Vector Machine (LS-SVM)**, Journal of Water and Soil Conservation, 21(6), 293-304. (In Persian)

7- Haghizadeh, A., Mohammadlou, M. and Noori F., 2015, **Simulation of Rainfall-Runoff Process Using Multilayer Perceptron and Adaptive Neuro-Fuzzy Interface System and Multiple Regression (Case Study: Khorramabd Watershed)**, Iranian Journal of Eco Hydrology, 2(2), 233-243. (In Persian)

8- Gizaw, M. S. and Gan, T. Y., 2016, **Regional Flood Frequency Analysis Using Support Vector Regression under Historical and Future Climate**, Journal of Hydrology, 538, 387-398.

9- Hosseini, S. M. and Mahjouri, N., 2016, **Integrating Support Vector Regression and A Geomorphologic Artificial Neural Network For Daily Rainfall-Runoff Modeling**, Journal of Hydrology, 38, 329-345.

10- Nourani, V., Baghanam, A. H., Adamowski, J. and Kisi, O., 2014, **Applications of Hybrid Wavelet–Artificial Intelligence Models in Hydrology: A Review**, Journal of Hydrology, 514, 358-377.

11- Nourani, V. and Andalib, G., 2015, **Daily and Monthly Suspended Sediment Load Predictions Using Wavelet Based Artificial Intelligence Approaches**, Journal of Mountain Science, 12(1), 85-100.

12- Nourani, V. and Parhizkar, M., 2013, **Conjunction of SOM-Based Feature Extraction Method and Hybrid Wavelet-ANN Approach for Rainfall–Runoff Modeling**, Journal of Hydroinformatics, 15, 829-848.

13- Chang, F. J., Chang, L. C., Huang, C. W. and Kao, I. F., 2016, **Prediction of Monthly Regional Groundwater Levels Through Hybrid Soft-Computing Techniques**, Journal of Hydrology, 541, 965-976.

www.SID.ir

14- Nourani, V., Khanghah, T. R. and Baghanam, A. H., 2015, **Application of entropy concept for input selection of Wavelet-ANN based rainfall-runoff modeling**, Journal of Environmental Informatics, 26, 52-70.
15- Nourani, V. and Komasi, M., 2013, **A Geomorphology-Based ANFIS Model for Multi-Station Modeling of Rainfall–Runoff Process**, Journal of Hydrology, 490, 41-55.
16- Lee, W. K. and Resdi, T. A. T., 2016, **Simultaneous Hydrological Prediction at Multiple Gauging Stations Using the NARX Network for Kemaman Catchment, Terengganu, Malaysia**, Hydrological Sciences Journal, 61, 2930-2945.
17- Bosch, D. D., Sullivan, D. G. and Sheridan, J. M., 2006, **Hydrologic Impacts of land-use Changes in Coastal Plain Watersheds**. Transactions of the ASABE, 49(2), 423-432.
18- Mallat, S. G., 1998, **A Wavelet Tour of Signal Processing**, second edition Academic Press, San Diego.
19- Shannon, C. E., 1948, **A mathematical theory of communications I and II**, Bell System Technical Journal, 27, 379-443.
20- Yang, H. H., Vuuren, S. V., Sharma, S. and Hermansky, H., 2000, **Relevance of Time-Frequency Features For Phonetic and Speaker-Channel Classification**, Speech Communication, 31, 35-50.
21- Kohonen, T., 1997, **Self-Organizing Maps**, Springer-Verlag, Berlin, Heidelberg.
22- Kim, T. and Valdes, J. B., 2003, **Nonlinear Model for Drought Forecasting Based on a Conjunction of Wavelet Transforms and Neural Networks**, Journal of Hydrologic Engineering, 6, 319-328.
23- Suykens, J. A. K. and Vandewalle, J., 1999, **Least Square Support Vector Machine Classifiers**, Neural Processing Letters, 9 (3), 293-300.
24- Price, K., Jackson, C. R. and Parker, A. J., 2010, **Variation of Surficial Soil Hydraulic Properties Across Land Uses In The Southern Blue Ridge Mountains, North Carolina, USA**, Journal of Hydrology, 383, 256-268.

www.SID.ir