



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

غلامرضا عندلیب<sup>۱\*</sup>، وحید نورانی<sup>۲</sup>، حسین منیری فر<sup>۳</sup>، الناز شرقی<sup>۴</sup>

<sup>۱\*</sup> دکتری مهندسی آب و سازه‌های هیدرولیکی، گروه مهندسی آب، دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران  
(gholamreza.andalib@gmail.com)

<sup>۲</sup> استاد، گروه مهندسی آب، دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران

<sup>۳</sup> کارشناسی ارشد مهندسی سازه، گروه مهندسی سازه، دانشکده مهندسی عمران، دانشگاه تبریز، تبریز، ایران

<sup>۴</sup> 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 پیش‌بینی چند ایستگاه رواناب با استفاده از تبدیل موجک و شبکه عصبی مصنوعی خودسازمانده و مدل‌های هوش مصنوعی در حوضه آبریز Little River Watershed (LRW) انجام گردید. بطوریکه سری‌های زمانی رواناب توسط تبدیل موجک تجزیه‌گشته و سپس زیرسری‌های تجزیه‌شده توسط شبکه عصبی مصنوعی خودسازمانده خوشه‌بندی 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 پیش‌بینی رواناب خروجی حوضه آبریز LRW بکار گرفته شدند. مدلسازی چند ایستگاه بارش-رواناب بر اساس خاصیت فصلی بودن انجام شده و با مدلسازی چند ایستگاه 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 پیش‌بینی رواناب چند ایستگاه را نسبت به مدل‌های هوش مصنوعی که از خاصیت مارکف بهره می‌برند تا ۲۳ درصد بهبود می‌بخشد. بطور کلی، استفاده از خاصیت فصلی بودن پدیده‌ها به همراه کاهش ابعاد ورودی‌ها، می‌تواند به مدل‌های هوش مصنوعی در جهت استفاده از اطلاعات خالص داده‌های مشاهداتی کمک کند.

### کلمات کلیدی

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



# 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<sup>1\*</sup>, Vahid Nourani<sup>2</sup>, Hosein Monirifar<sup>3</sup>, Elnaz Sharghi<sup>4</sup>

<sup>1\*</sup> Ph.D. of Water and Hydrualic Structure, Department of Water Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran (gholamreza.andalib@gmail.com)

<sup>2</sup> Professor, Department of Water Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran

<sup>3</sup> M.Sc. of Structural Engineering, Department of Structural Engineering, Faculty of Civil Engineering, University of Tabriz, Tabriz, Iran

<sup>4</sup> 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.



## ۱- مقدمه

بدون تردید مدل‌سازی دقیق فرآیند بارش-رواناب یکی از عوامل اساسی برای تصمیم‌گیری‌های مدیریتی در حوضه آبریز می‌باشد و اطلاعات مهمی برای صاحب-نظران و تصمیم‌گیرندگان عرصه مدیریت منابع آب جهت حفظ و افزایش این منبع حیات ارائه می‌کند. از طرفی عدم قطعیت بالا در پدیده‌های هیدرولوژیکی نظیر بارش-رواناب، الزام به استفاده از روش‌های محاسبات نرم در این نوع پدیده‌ها را آشکار می‌سازد. از این رو، تاکنون روش-های محاسبات نرم متعددی از جمله مدل‌های هوش مصنوعی برای شبیه‌سازی پدیده بارش-رواناب مورد استفاده قرار گرفته است. برای مثال [۱] به شبیه‌سازی 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 مدل‌سازی 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 حوضه‌های آبریز لایز هول کریک و حوضه آبریز مازل استفاده نمود. در این راستا، شبکه عصبی مصنوعی ANN و ماشین بردار پشتیبان SVM به عنوان روش‌های محاسبات نرم توانایی‌های خود را در مدل‌سازی و پیش‌بینی روند غیرخطی رواناب نشان داده‌اند [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 انعطاف‌پذیر مدل‌های SVM و ANN، این مدل‌ها نقایصی را در مواجهه با سیگنال‌های هیدرولوژیکی، که عموماً ناپایستا بوده و محدوده وسیعی از مقیاس (از چند دقیقه تا چند دهه) را شامل می‌شود، از خود نشان می‌دهند. از این رو، در چنین شرایطی پیش‌پردازش زمانی و یا مکانی داده‌ها قبل از اعمال آنها به مدل‌های SVM و ANN برای غلبه بر این مشکل ضروری به نظر می‌رسد. تبدیل موجک زیرسری‌های مفیدی از سری اصلی بدست می‌دهد که این زیرسری‌ها با استخراج اطلاعات سودمند در مقیاس‌های مختلف، توانایی مدل را در پیش‌بینی کمیت مورد نظر بالا می‌برند. تبدیل موجک با تجزیه سری‌های زمانی، به کمک ضرایب جزئی، به تفسیر ساختار سری و دریافت اطلاعات مفید در مورد تاریخچه آن کمک می‌کند [۱۰] و [۱۱]. در این مقاله، مدل‌های ترکیبی موجک-شبکه عصبی WANN و موجک-ماشین بردار پشتیبان WSVM برای مدل‌سازی چند ایستگاه بارش-رواناب استفاده شده‌اند. با این حال در هر گونه اطلاعات استخراج شده در مدل‌سازی ممکن است برخی از ورودی‌ها آلوده به نویز باشند و یا با متغیرهای خروجی رابطه معنی‌داری نداشته باشند. بنابراین، تعیین ورودی‌های غالب و حاوی اطلاعات مفید یکی از چالش‌های ضروری در روند توسعه مدل‌های WANN و WSVM است. بدین منظور، برای تعیین ورودی‌های مدل‌های WANN و WSVM، از شبکه عصبی مصنوعی خودسازمانده SOM و مفاهیم اطلاعات مشترک MI استفاده شده است. SOM به عنوان یک ابزار خوشه‌بندی قوی یک نوع سیستم شبکه عصبی بدون نظارت است و به تازگی در زمینه‌های مختلف مهندسی آب به طور گسترده استفاده شده است [۱۲] و [۱۳]. از سوی دیگر، معیار MI به عنوان یک معیار غیر خطی برای داده‌ها و اطلاعات می‌تواند یک ابزار ارزشمند در انتخاب ورودی مناسب زیرسری‌های زمانی تجزیه شده توسط موجک باشد [۱۴]. در مجموع، بر اساس اهمیت ورودی‌های مدل برای به دست آوردن الگوی کلی از فرآیند بارش-رواناب، مشارکت داده‌های موثر حوضه آبریز از اهمیت بسیاری برخوردار است. بنابراین، شناسایی و استفاده زمانی-مکانی از اطلاعات زیرحوضه‌ها به عنوان یک تجزیه و تحلیل چند ایستگاه می‌تواند پیش‌بینی رواناب در حوضه آبریز را بهبود بخشد. لازم به ذکر است که مدل‌های چند ایستگاه در برخی دیگر از زمینه‌های هیدرولوژی مورد استفاده واقع شده‌اند [۱۵] و [۱۶]. بر اساس آخرین تحقیقات و بررسی‌های انجام شده توسط محققین، تاکنون مدل‌سازی چند ایستگاه پدیده بارش-رواناب با پیش‌پردازش زمانی-مکانی در حوضه آبریز تاکنون انجام نگرفته است. بر همین اساس، تلاش این مقاله نه تنها پیش‌بینی رواناب خروجی حوضه آبریز بلکه اطلاع یافتن از وقایع درون حوضه آبریز

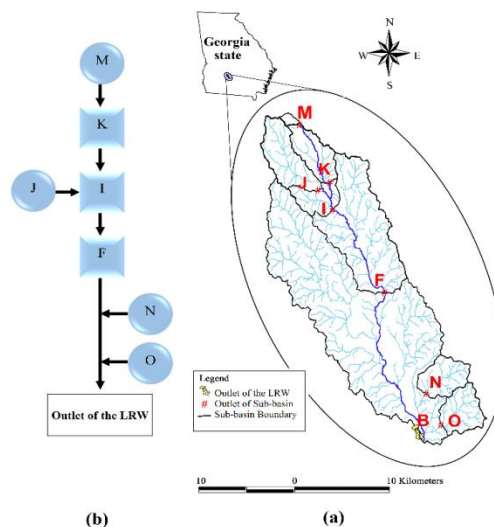


نیز می باشد. یعنی پیش‌بینی میزان رواناب در درون حوضه نیز صورت خواهد گرفت. جهت توضیح بیشتر، از زیرحوضه های ابتدایی و مولد جهت پیش بینی رواناب زیرحوضه های میانی و از زیرحوضه های میانی جهت پیش‌بینی رواناب خروجی حوضه بهره گرفته خواهد شد که این کار سبب آماده شدن بستر مناسب جهت اطلاع یافتن از مقادیر رواناب در قسمت‌های مختلف حوضه را فراهم می‌سازد. برای این منظور در این مقاله برای مدلسازی چند ایستگاه 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 سری‌های 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 می‌باشد 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 آبخشاری حوضه آبریز LRW [۱۷].



جدول ۱: مشخصات آماری حوضه آبریز LRW.

Sub-basins	Average		Channel slope %	Mean runoff×100 / area	Drainage area (km <sup>2</sup> )
	Runoff (m <sup>3</sup> /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 ایستگاه بارش-رواناب استفاده شد. هدف مدل‌سازی چند ایستگاه 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 ایستگاه به هیدرولوژیست‌ها 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 ایستگاه 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 ایستگاه 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 O، F و N محاسبه شد. بدین ترتیب الگوی پیش بینی چند ایستگاه با سه گام مدل‌سازی بمانند مخازن آبشاری مرتبط تکمیل می گردد. ذکر این نکته نیز ضروری است که با استفاده از مدل‌سازی چند ایستگاه می توان داده های مفقود شده سری های زمانی در ایستگاه های هیدرومتری آسیب دیده را نیز ترمیم کرد. مدل‌سازی چند ایستگاه با استفاده از سناریوی مارکف و فصلی در بخش های زیر شرح داده شده است (شکل ۲).



شکل ۲: مراحل سناریوی یک و سناریوی دو.



### ۲-۲-۱- سناریوی اول

در سناریوی اول، خاصیت مارکف پدیده بارش-رواناب اساس مدلسازی چند ایستگاه 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.

$$Q_t^I = f_n (I_t^I, Q_t^M, \dots, Q_{t-p_M}^M, Q_t^K, \dots, Q_{t-p_K}^K, Q_t^J, \dots, Q_{t-p_J}^J) \quad (1)$$

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 ایستگاه تلقی می گردد. 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 می باشند 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 زیرحوضه های O, F, N توسط رابطه ۳ پیش بینی شدند.

$$Q_t^F = f_n (I_t^F, Q_t^I, \dots, Q_{t-p_I}^I) \quad (2)$$

$$Q_t^B = f_n (I_t^B, Q_t^F, \dots, Q_{t-p_F}^F, Q_t^N, \dots, Q_{t-p_N}^N, Q_t^O, \dots, Q_{t-p_O}^O) \quad (3)$$

### 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 سری های زمانی زیرحوضه ها با توجه به حذف اطلاعات زائد بصورت ذیل بوده است، برای پیش بینی رواناب زیرحوضه I سه گام پشت سر گذاشته شد. در گام اول، سری های زمانی رواناب زیرحوضه های M, K و J توسط تبدیل موجک در سطح q جهت رفع نالیستایی و استخراج خاصیت فصلی سری های زمانی تجزیه شدند، بطوریکه رواناب زیرحوضه I به زیرسری های زیرحوضه های بالادستی مرتبط گردید:

$$Q_t^I = f_n (I_t^I, Q_a^M, Q_{dq}^M, \dots, Q_{dq}^M, Q_a^K, Q_{dq}^K, \dots, Q_{dq}^K, Q_a^J, Q_{dq}^J, \dots, Q_{dq}^J) \quad (4)$$

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 زیرسری های زمانی نیز مرتبط به زیرحوضه های 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.



$$Q_t^F = f_n(I_t^F, Q_a^I, Q_{d1}^I, \dots, Q_{dq}^I) \quad (5)$$

$$Q_t^B = f_n(I_t^B, Q_a^F, Q_{d1}^F, \dots, Q_{dq}^F, Q_a^N, Q_{d1}^N, \dots, \quad (6)$$

$$Q_{dq}^N, Q_a^O, Q_{d1}^O, \dots, Q_{dq}^O)$$

### ۳-۲- 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]:

$$g_{m,n}(t) = \frac{1}{\sqrt{a_0^m}} g^*\left(\frac{t - nb_0 a_0^m}{a_0^m}\right) \quad (7)$$

در رابطه فوق  $g(t)$  تابع موجک مادر و  $g^*(t)$  تابع مختلط و مرکب می باشد.  $m$  و  $n$  اعداد صحیح 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  $a_0=2$  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  $x_1, x_2, \dots, x_N$  و احتمالات متناظر  $p_1, p_2, \dots, p_N$  باشد، آنتروپی شانون از رابطه ۹ محاسبه می شود [۱۹]:

$$H(X) = H(P) = -\sum_{i=1}^N p(x_i) \log[p(x_i)] \quad (8)$$

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]:

$$MI(X, Y) = H(X) + H(Y) - H(X, Y) \quad (9)$$

$H(X, Y)$  نیز آنتروپی مشترک می باشد:

$$H(A, B) = -\sum_{a \in A} \sum_{b \in B} p_{AB}(a, b) \log p_{AB}(a, b) \quad (10)$$

### ۴-۲- نقشه خود سازمانده

SOM یک الگوریتم جدید و موثر برای تجسم و خوشه بندی اطلاعات با ابعاد بزرگ است. این ابزار مجموعه ای از داده های با بعد بالا را بر روی یک شبکه منظم کم بعد نگاشت می دهد، این ابزار توانایی تبدیل روابط آماری پیچیده و غیرخطی داده های با بعد بالا را به روابط ساده هندسی در صفحه نمایش کم بعد داده ها دارا است (داده ها با ویژگی های مختلف را در نقشه های ۲ بعدی نشان می دهد) [۲۱]. برای خوشه بندی SOM در دو مرحله برای کاهش ابعاد فضای ورودی مدل بکار گرفته شده است. در مرحله اول SOM دو بعدی برای بدست آوردن دید کلی نسبت به ساختار سری ها و تعیین تعداد تقریبی خوشه ها استفاده شده است. سپس



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 در نظر 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

در این 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) به جای 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 می‌کند؛ اما یک شبکه عصبی MLP هر موقع تفکیک درست باشد یا مقدار خطای تفکیک کمینه باشد آن را به‌عنوان راه حل ارائه می‌کند. ماشین بردار پشتیبان الگوریتمی است که نوع خاصی از مدل های خطی را می‌یابد که حداکثر حاشیه ابر صفحه را حاصل می‌کنند. حداکثر کردن حاشیه ابر صفحه منجر به حداکثر شدن تفکیک بین دسته‌ها می‌شود. به نزدیکترین نقاط آموزشی به حداکثر حاشیه ابر صفحه، بردارهای پشتیبان اطلاق می‌گردد و تنها از این بردارها برای مشخص کردن مرز بین دسته‌ها استفاده می‌شود. قواعد تصمیم‌گیری که تعریف می‌شود و توسط یک صفحه بهینه که طبقات تصمیم‌گیری باینری را تفکیک می‌کند، به صورت رابطه (۱۱) است [۲۳].

$$y = \sum_{i=1}^N \gamma e_i K(X, X_i) + b \quad (11)$$

که در آن  $y$  خروجی معادله،  $e_i$  ارزش طبقه نمونه آموزشی  $X_i$  و  $\gamma$  ضریب کرنل است. بردارهای  $x = (x_1, x_2, \dots, x_n)$  نشان دهنده یک داده ورودی و بردارهای  $X_i$  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  $\sigma$  استفاده گردیده است زیرا این نوع کرنل بالاترین میزان کارایی را در مدل های هیدرولوژیکی داشته است [۲۳].

$$K(X, X_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad (12)$$

## 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 ۱۴) جهت مقایسه‌ی عملکرد مدل‌های مختلف ارائه شده است [11]:

1 Determination Coefficient

2 Root Mean Square Error



$$DC = 1 - \frac{\sum_{i=1}^N (O_{obs_i} - O_{com_i})^2}{\sum_{i=1}^N (O_{obs_i} - \bar{O}_{obs})^2} \quad (13)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (O_{obs_i} - O_{com_i})^2}{N}} \quad (14)$$

در این روابط  $T$ ،  $O_{obs_i}$ ،  $O_{com_i}$  و  $\bar{O}_{obs}$  به ترتیب تعداد مشاهداتی، داده‌های مشاهداتی، داده‌های محاسباتی و میانگین داده‌های مشاهداتی است.

### ۳- نتایج و بحث

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

#### ۳-۱- نتایج سناریوی یک

در مدل های داده محور FFNN و LSSVM، انتخاب داده‌های مناسب نقش بسزایی در افزایش کارایی مدل در هر دو بخش آموزش و صحت سنجی دارد، ضمن اینکه از بیش برآزش 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 ایستگاه نشان می دهد. نتایج مدل‌سازی چند ایستگاه 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 برآزش 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 ایستگاه، 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 متأثر 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 ایستگاه 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



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 مدل های 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 (O و N)، بدون تأخیر برای پیش بینی رواناب خروجی حوضه آبریز LRW وارد مدل های هوش مصنوعی گردیدند. مقایسه نتایج پیش بینی چند ایستگاه رواناب (جدول ۲) نشان می دهد مدل های FFNN و LSSVM نتایج قابل قبول و تقریباً یکسانی را نشان دادند. یک روش پیش پردازش مناسب همانند سناریوی دو می تواند توانایی مدل چند ایستگاه را بهبود بخشد. در بخش بعدی نتایج مدلسازی چند ایستگاه توسط سناریوی دو ارائه می شود.

### ۳-۲- نتایج سناریوی دو

در این سناریو برای مد نظر قرار دادن الگوی فصلی در مدلسازی چند ایستگاه، 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 ۲<sup>۱</sup> روزه (d1 - اولین زیر سری با فرکانس بالا)، حالت ۲<sup>۲</sup> روزه (d2 - دومین زیر سری)، ۲<sup>۳</sup> روزه (d3 - سومین زیر سری تقریباً هفتگی)، حالت ۲<sup>۴</sup> روزه (d4 - چهارمین زیر سری)، حالت ۲<sup>۵</sup> روزه (d5 - پنجمین زیر سری و تقریباً ماهانه)، حالت ۲<sup>۶</sup> روزه (d6 - ششمین زیر سری)، حالت ۲<sup>۷</sup> روزه (d7 - هفتمین زیر سری) و حالت ۲<sup>۸</sup> روزه (d8 - هشتمین زیر سری) و به همراه زیر سری تقریب می باشد.


جدول ۲: نتایج پیش بینی چند ایستگاه 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) <sup>a</sup>	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) <sup>b</sup>	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



<sup>a</sup> The first, second and third numbers represent input variable, hidden neurons and output variable, respectively.

<sup>b</sup> RBF-Kernel structure ( $\gamma, \sigma$ ).



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 مدل سازی چند ایستگاه 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 مدل سازی چند ایستگاه شرکت نمودند. نتایج مدل سازی های چند ایستگاه بوسیله FFNN و LSSVM در جدول (۳) برای سناریوی دو ارائه شده است.

علاوه بر سناریوهای یک و دو، روش های FNN و LSSVM بدون پیش پردازش های انجام شده با شاخص MI، خوشه بندی 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.

$$Q_t^B = f_n(I_t^B, Q_t^F, Q_{t-1}^F, Q_{t-2}^F, Q_t^N, Q_{t-1}^N, Q_t^O, Q_{t-1}^O) \quad (15)$$



جدول ۳: نتایج پیش‌بینی چند ایستگاه 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	$Q_t^I$	$Q_a^K, Q_{d1}^J, Q_{d8}^J, Q_{d3}^J, Q_{d2}^K, Q_{d7}^K, I_t^I$	(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	$Q_t^I$	$Q_a^K, Q_{d1}^J, Q_{d8}^J, Q_{d3}^J, Q_{d2}^K, Q_{d7}^K, I_t^I$	(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 ایستگاه 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 مدل سازی چند ایستگاه 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 مدل سازی، 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 مدل سازی چند ایستگاه حوضه آبریز LRW، 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 می باشد. بنابراین، مدل های موجک-هوش مصنوعی که با SOM-MI ترکیب شده اند یک روش مناسب و کارآمد در مدل سازی چند ایستگاه 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 مدل سازی چند ایستگاه برای مدل سازی دیگر پدیده های هیدرولوژیکی نیز بکار برده شود.



##### 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.



- 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.