



شماره ۱۰۷، تابستان ۱۳۹۴

پژوهش‌های آبخیزداری

(پژوهش و سازندگی)

مقایسه مدل ترکیبی موجک - نروفازی و نروفازی در پیش بینی رواناب ناشی از ذوب برف (مطالعه موردی: حوزه آبخیز سد لتیان)

• فاطمه صدیقی

دانشگاه تربیت مدرس

• مهدی وفاخواه

دانشگاه تربیت مدرس (نویسنده مسئول)

• تاریخ دریافت: آذرماه ۱۳۹۲ تاریخ پذیرش: آذرماه ۱۳۹۳

Email: vafakhah@modares.ac.ir

چکیده

فرآیند بارش-رواناب پدیده‌ای فیزیکی است که بررسی آن به سبب تاثیرپذیری از پارامترهای مختلف، دشوار می‌باشد. تاکنون روش‌های مختلفی برای تحلیل این پدیده ارائه شده است. پژوهش حاضر با هدف بررسی کارآمدی مدل ترکیبی موجک-نروفازی و نروفازی در شبیه‌سازی فرآیند بارش-رواناب با دخالت دادن ارتفاع آب معادل برف در حوزه آبخیز لتیان واقع در استان تهران صورت گرفته است. بدین منظور ۹۲ تصویر سنجنده مودیس در طی سه سال آبی ۸۳-۱۳۸۲ تا ۸۵-۱۳۸۴ از سایت ناسا دریافت گردید و سطح پوشش برف در هر یک از تصاویر استخراج و میزان ارتفاع آب معادل برف در طی سال‌های مورد نظر محاسبه شد. همچنین داده‌های ارتفاع بارندگی، درجه حرارت و دبی در سال‌های مورد نظر در دسترس بوده که برای مدل‌سازی استفاده شد. نتایج نشان داد مدل ترکیبی موجک - نروفازی با ورودی باران، دما و آب معادل برف با یک روز تاخیر با ریشه میانگین مربعات خطا ۰/۰۰۶ و ضریب تبیین ۰/۹۷ نسبت به مدل نروفازی با تفکیک خوشه‌ای با ورودی باران، دما و آب معادل برف بدون تاخیر با ریشه میانگین مربعات خطا ۰/۰۵۹ و ضریب تبیین ۰/۶۲ و شبکه نروفازی با تفکیک شبکه‌ای با ورودی باران، دما و آب معادل برف با ریشه میانگین مربعات خطا ۰/۰۵۹ و ضریب تبیین ۰/۶۵ دارای عملکرد بهتری بوده است. همچنین نتایج نشان داد دخالت دادن آب معادل برف باعث افزایش دقت مدل شده است.

کلمات کلیدی: بارش - رواناب، شبکه عصبی-فازی تطبیقی، آب معادل برف، سطح پوشش برف، حوزه آبخیز لتیان

Watershed Management Research (Pajouhesh & Sazandegi) No 107 pp: 84-96

Comparison of Hybrid Wavelet- Adaptive Neuro-fuzzy Inference System and Adaptive Neuro-fuzzy Inference System for Snowmelt- Runoff Prediction (Case Study: Latyan Dam Watershed)

By: F. Sedighi, Tarbiat Modares University. M. Vafakhah, Assistant Professor of Tarbiat Modares University. (Corresponding Author; Tel: +98-122-6253101)

Rainfall-runoff process is physical phenomena that their investigation is very difficult due to effectiveness of different parameters. Various methods have so far introduced to analyze these phenomena. This study has been aimed to investigate performance of wavelet-adaptive neuro-fuzzy inference system (wavelet-ANFIS) and adaptive neuro-fuzzy inference system (ANFIS) for simulation of rainfall-runoff process involved with snow water equivalent (SWE) in Latyan watershed located in Tehran province. For this reason, 92 MODIS images have provided by NASA website during three water years 2003-2005, snow cover area in all images has been extracted and finally SWE values have been calculated for the mentioned years. Also, the rainfall, temperature and discharge data for the mentioned years is available which has been used for modeling. The results showed that wavelet-ANFIS with rainfall, temperature and discharge inputs and 1-day delay these inputs with root mean (RMSE) of 0.006 and coefficient of determination (R2) of 0.97 had more efficiency than ANFIS by grid partitioning with rainfall, temperature and discharge inputs with RMSE of 0.059 and R2 of 0.62 and ANFIS by subtractive clustering with rainfall, temperature and discharge inputs with RMSE of 0.059 and R2 of 0.65. The results Also showed that SWE involvement causes to increase the accuracy of models.

Keywords: ANFIS, Wavelet-ANFIS hybrid model, Rainfall-runoff, Latyan watershed

مقدمه

متحرک (ARMA) و شبکه عصبی مصنوعی (ANN)، سیستم استنتاج عصبی-فازی تطبیقی (ANFIS)، الگوریتم ژنتیک (GP) و ماشین بردار پشتیبان (SVM) با استفاده از مشاهدات طولانی مدت دبی ماهانه بررسی کردند. نتایج این تحقیق نشان داد که به ترتیب سیستم استنتاج عصبی-فازی تطبیقی، الگوریتم ژنتیک و ماشین بردار پشتیبان برای پیش‌بینی دبی ماهانه کارایی بالاتری دارند. کروتولوس (۲۰۱۰) در تحقیقی شبکه عصبی مصنوعی (ANN) و سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) را برای پیش‌بینی دبی روزانه حوزه‌های آبخیز آهکی مورد استفاده قرار دادند و قابلیت آنها را با هم مقایسه کردند. نتایج نشان داد که مدل ANFIS عملکرد بهتری را نسبت به مدل ANN برای پیش‌بینی دبی اوج نشان می‌دهد. زارع‌ابنیه و بیات‌ورکشی (۲۰۱۰) در مطالعه‌ای کاربرد مدل‌های تجربی، شبکه عصبی مصنوعی سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) در برآورد رواناب حوزه آبخیز زاینده رود بررسی نمودند. نتایج نشان داد که مدل‌های هوشمند از دقت مناسبی در برآورد رواناب نسبت به مدل‌های تجربی برخوردار بودند. وفاخواه و همکاران (۲۰۱۱) رواناب حاصل از ذوب برف به کمک شبکه عصبی مصنوعی و نروفازی در حوزه آبخیز طالقان واقع در استان البرز را شبیه‌سازی کردند و به این نتیجه رسیدند که شبکه عصبی مصنوعی دارای کارایی بالاتری نسبت به نروفازی در پیش‌بینی جریان بوده و دخالت دادن ارتفاع آب معادل برف در دو ایستگاه باعث افزایش کارایی ساختار شبکه شده است. دستورانی و همکاران (۲۰۱۱) در مطالعه‌ای کارایی شبکه عصبی مصنوعی و سیستم استنتاج

برف یکی از اشکال مهم بارش در حوزه آبخیز سدلتیان بوده که در تامین منابع آب آشامیدنی و کشاورزی به صورت جریان‌های تاخیری در فصول پربابی و جریان‌های کمینه در فصول کم‌آبی و تولید انرژی نقش ارزنده ایفا می‌کند از سوی دیگر رواناب حاصل از ذوب برف به دلیل نقش تاخیری آن، منبع اصلی تغذیه سفره‌های آب زیرزمینی و در برخی از موارد به دلیل هم‌زمانی با بارش‌های بهاره منشاء بروز سیلاب‌های مخرب با حجم جریان بیش از ظرفیت رودخانه‌ها می‌شود. فرآیند بارش- رواناب، فرآیندی غیرخطی و از حیث زمانی و مکانی کاملاً تصادفی می‌باشد و تشریح آن با مدل‌های ساده به راحتی امکانپذیر نیست (وفاخواه و همکاران، ۲۰۱۱). مطالعات مختلفی با استفاده از سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) در هیدرولوژی انجام شده است. نایاک و همکاران (۲۰۰۴) کاربرد سیستم استنتاج عصبی-فازی تطبیقی (ANFIS) را در مدل‌سازی جریان رودخانه‌ی Baitarani در هند مورد بررسی قرار دادند. آنها همچنین به منظور مقایسه‌ی عملکرد مدل‌ها، یک مدل شبکه عصبی مصنوعی و یک مدل خودهمبسته میانگین متحرک (ARMA) را نیز برای همان حوزه توسعه دادند که عملکرد بهتر مدل ANFIS هم از لحاظ روند ساخت و هم از لحاظ نتایج را نشان داد. فرات (۲۰۰۶) کارایی و توانایی سیستم استنتاج عصبی-فازی تطبیقی را در پیش‌گویی جریان رودخانه با سری داده‌های طولانی مورد بررسی قرار داد و نتیجه گرفت که مدل ساخته شده بر پایه رواناب دو روز قبل بهترین کارایی را دارد. وانگ (۲۰۰۹) در تحقیقی مدل خودهمبسته میانگین

WANFIS برای پیش‌بینی دبی ماهانه استفاده کردند. نتایج نشان داد که این مدل می‌تواند نتایج مطلوب در شبیه‌سازی و پیش‌بینی دبی ماهانه ارائه دهد. الهی و برقی (۲۰۱۰) در مطالعه‌ای مدل‌سازی بارش-رواناب را از طریق مدل ترکیبی موجک- شبکه عصبی مصنوعی در حوزه آبخیز ليقوان چای انجام دادند. نتایج نشان داد که این روش نسبت به روش شبکه عصبی مصنوعی کارایی بالاتری را دارا می‌باشد. نورانی و همکاران (۲۰۱۱) نیز در مطالعه‌ای دو مدل ترکیبی ANN-SARIMAX و WANFIS را برای مدل‌سازی بارش-رواناب در دو حوزه آبخیز واقع در آذربایجان غربی استفاده کردند. نتایج نشان داد که مدل WANFIS نتایج نسبتاً مناسب‌تری دارد. با توجه به این که تاکنون در تحقیقات صورت گرفته از روش ترکیبی موجک- نروفازی (WANFIS) به منظور مدل‌سازی بارش-رواناب و لحاظ آب معادل برف به‌منظور تخمین رواناب ناشی از ذوب برف به‌کار برده نشده است. هدف از تحقیق حاضر امکان تخمین دقیق رواناب با استفاده از شبکه عصبی- فازی تطبیقی و روش ترکیبی موجک- نروفازی (WANFIS) با دخالت دادن آب معادل برف در حوزه آبخیز لتیان که تحت تاثیر برف است مدنظر قرار گرفته است.


مواد و روش‌ها

ویژگی‌های منطقه تحقیق

حوزه آبخیز رودک در محدوده طول جغرافیایی $25^{\circ} 51'$ تا $46^{\circ} 51'$ و عرض جغرافیایی $50^{\circ} 35'$ تا $36^{\circ} 00'$ با مساحت تقریبی ۴۳۶ کیلومترمربع در استان تهران قرار گرفته است. این حوزه آبخیز شامل زیرحوزه‌های آبخیز گرمابدر، میگون، آهار، امامه و رودک می‌باشد. این آبخیز کوهستانی بوده و دارای تغییرات ارتفاعی ۱۷۰۰ تا ۴۲۱۲ متر با افزایش ارتفاع به سمت شمال و دارای ارتفاع میانگین ۲۸۳۰ متر و شیب میانگین ۴۵/۶٪ است.

عصبی-فازی تطبیقی به منظور مدل‌سازی بارش-رواناب در حوضه سدزاینده-رود، مورد ارزیابی قرار دادند. نتایج نشان داد که شبکه عصبی مصنوعی و سیستم استنتاج عصبی- فازی تطبیقی در شرایط مختلف و با ترکیب‌های مختلف پارامترهای ورودی، نتایج متفاوتی از خود نشان می‌دهند. پوستی‌زاده و همکاران (۲۰۱۱) کاربرد شبکه عصبی مصنوعی را با سیستم استنتاج فازی در پیش‌بینی جریان رودخانه زاینده‌رود مقایسه نمودند. نتایج این تحقیق حاکی از برتری سیستم استنتاج عصبی-فازی تطبیقی نسبت به شبکه عصبی مصنوعی می‌باشد.

علی‌رغم انعطاف‌پذیری مناسب ANN و ANFIS در مدل‌سازی یک فرایند هیدرولوژیکی نظیر بارش-رواناب، گاهی اوقات در زمانی که نوسانات واحد بسیار متغیر بوده و فرایند هیدرولوژیکی فیزیکی در بازه گسترده‌ای از مقیاس‌ها که از یک روز تا چندین دهه در تغییر است، انجام می‌گیرد کمبودی احساس می‌شود. در چنین وضعیتی، اگر پیش‌پردازش داده‌های ورودی و یا خروجی انجام نپذیرد، ممکن است مدل‌های ANN و ANFIS قادر به عمل کردن از طریق استفاده از این داده‌های متغیر نباشند (کوناس و همکاران، ۲۰۰۶). به منظور غلبه بر کمبود ذکر شده، ترکیب ANN و ANFIS با روش‌های دیگر نظیر مدل‌های ترکیبی می‌تواند انتخاب مناسبی باشد. ایده اصلی ترکیب مدل در پیش‌بینی استفاده از امتیازات منحصر به فرد هر یک از مدل‌هاست تا بدینوسیله الگوهای مختلف را از درون داده‌ها بتوان استخراج کرد. یافته‌های نظری و تجربی هر دو این موضوع را پیشنهاد می‌دهند که ترکیب کردن مدل‌های متفاوت می‌تواند راه مناسبی برای بهبود پیش‌بینی باشد (ژانگ، ۲۰۰۳). مطالعات مختلفی با استفاده از مدل ترکیبی موجک-نروفازی (WANFIS) در هیدرولوژی نظیر مطالعات ابراهیمی و بارانی (۲۰۰۵)، ابراهیمی و بارانی (b) (۲۰۰۵)، نورانی و همکاران (۲۰۰۸) و نورانی و همکاران (۲۰۰۹) انجام شده است. هویفانگ گو و همکاران (۲۰۰۹) در مطالعه‌ای از مدل



شکل ۱- موقعیت حوزه آبخیز رودک در ایران با اقتباس از زینیوند (۲۰۰۳)

روش پژوهش

استخراج سطح پوشش برف از تصاویر سنجنده MODIS ابتدا تصاویر رقومی ماهواره MODIS منطقه از سایت ناسا (<http://ladsweb.nascom.nasa.gov>) (NASA) با فرمت HDF دریافت، ذخیره و در محیط پردازشگر ENVI وارد، خوانده و نمایش داده شد. پردازش تصاویر رقومی ماهواره‌های که به کمک رایانه انجام شد، شامل مراحل پیش پردازش و آماده‌سازی داده‌ها، طبقه بندی داده‌ها و استخراج اطلاعات و پردازش نهایی می‌باشد. ژئورفرنس کردن تصاویر با استفاده از جعبه ابزار نرم افزار ENVI به صورت خودکار انجام گرفت. تصحیحات جوی بر روی تصاویر با استفاده از میزان بازتابش امواج از دریاچه سدلتیان صورت گرفت. سعی بر آن شد که از تصاویری استفاده شود که فاقد پوشش ابر بر روی منطقه مورد مطالعه باشد. برای تهیه نقشه پوشش برف الگوریتمی به وسیله هال و همکاران (۲۰۰۱) با استفاده از باندهای با قدرت تفکیک زمینی ۵۰۰ متر به منظور جدا نمودن برف از ابر ارائه شده است. الگوریتم استفاده شده برای تهیه نقشه پوشش برف بر این اساس می‌باشد که برف در طول موج مرئی (۰/۵ تا ۰/۷ میکرومتر) دارای انعکاس زیاد و در طول موج کوتاه مادون قرمز (۱ تا ۴ میکرومتر) دارای انعکاس کم است (هال و همکاران، ۲۰۰۱). از باندهای ۴ و ۶ به طور اتوماتیک برای استخراج شاخص برفی تفاضلی نرمال شده (NDSI) و بر اساس معادله (۱) محاسبه می‌گردد.

$$NDSI = \frac{MODIS_{Band4} - MODIS_{Band6}}{MODIS_{Band4} + MODIS_{Band6}} \quad (1)$$

در این رابطه: NDSI شاخص برفی تفاضلی نرمال شده، MODIS_{Band4} تصویر باند چهارم سنجنده MODIS پس از انجام تصحیحات رادیومتریک و MODIS_{Band6} تصویر باند شش سنجنده MODIS پس از انجام تصحیحات رادیومتریک است. از این شاخص می‌توان برای تفکیک برف و یخ از یکدیگر و همچنین برای جداسازی برف از ابرهای ارتفاع بالای اتمسفر نظیر ابرهای کومولونیمبوس استفاده نمود. در واقع، این شاخص معیاری برای محاسبه مقدار نسبی خواص تفاضلی است که از بازتابش بین باندهای مرئی و مادون قرمز طول موج کوتاه برف حاصل می‌شود. علی‌رغم ارزش بالای شاخص NDSI، در مواردی هدفهای تیره مانع طبقه‌بندی صحیح برف می‌شوند. لذا با توجه به مطالعات هال و همکاران (۲۰۰۱) و کلایین و همکاران (۱۹۹۸) الگوریتم پوشش برف در صورتی یک پیکسل را برف تلقی خواهد نمود که شرایط مندرج در ذیل محقق شده باشد. (۱) باند دو دارای بازتابش بیش از ۱۱ درصد باشد. (۲) باند چهار دارای بازتابش برابر یا بیشتر از ۱۰ درصد باشد. (۳) در مجموع باید مقدار NDSI بیشتر از ۰/۴ برآورد گردد. لازم به توضیح است که نقشه برفی نهایی در فرمت باینری بوده و از منطق بولین پیروی میکند و در این مدل، کل تصویر به دو پهنه برفی و بدون برف طبقه‌بندی می‌گردد.

استخراج سطح پوشش برف در روزهای بدون تصویر ماهواره بعد از استخراج سطح پوشش برف در زمانهای مختلف با استفاده از تصاویر سنجنده MODIS، سطح پوشش برف در روزهای بدون تصویر، با استفاده از عمق تجمعی ذوب برف ($M\Delta$) به دست آمد. عمق تجمعی ذوب برف ($M\Delta$) تابعی از فاکتور درجه - روز () و تعداد درجه روز بالای درجه روز بحرانی ($+T$) است و در بازه زمانی بین t_1 ، t_2 از رابطه ۲ به دست می‌آید.

$$\Delta M(t_1, t_2) = \sum_{t_1}^{t_2} (aT^+) \quad t_1 \langle t_x \langle t_2 \quad (2)$$

$$a = 1/1 \frac{\rho_s}{\rho_w} \quad (3)$$

در این رابطه چگالی برف و چگالی آب می‌باشد و در صورت بارش برف جدید مقدار فاکتور درجه روز (a) اصلاح و وارد مدل گردید. فرض کنید دو تصویر ماهواره‌ای در زمان‌های t_A و t_E موجود است و سطح پوشش برف استخراج شده با استفاده از این دو تصویر t_1 SCA و t_2 SCA می‌باشد. اگر در فاصله زمانی بین t_A و t_E دما پایین‌تر از دمای بحرانی باشد، ذوب برف متوقف می‌شود که در این صورت سطح پوشش برف در زمان t_x از رابطه ۴ به دست می‌آید.

$$SCA(t_x) = SCA(t_{x-1}) - \frac{SCA(t_1) - SCA(t_2)}{\Delta M(t_1, t_A) + \Delta M(t_E, t_2)} \Delta M(t_{x-1}, t_x)$$

در این رابطه: SCA t_x = سطح پوشش برف در زمان t_x ،

$$SCA(t_{x-1}) = \text{سطح پوشش برف در زمان } t_{x-1}$$

$$SCA(t_1) = \text{سطح پوشش برف در زمان } t_1$$

$$SCA(t_2) = \text{سطح پوشش برف در زمان } t_2$$

$$\Delta M(t_1, t_A) = \text{سطح پوشش برف در زمان } t_1, t_A$$

$$\Delta M(t_E, t_2) = \text{عمق تجمعی ذوب برف در بین زمان } t_E \text{ و } t_2$$

$$\Delta M(t_{x-1}, t_x) = \text{عمق تجمعی ذوب برف در بین زمان } t_{x-1} \text{ و } t_x$$

تعیین آب معادل برف

آمار آب معادل برف ایستگاه برف‌سنجی امامه در طی سالهای ۱۳۸۲ تا ۱۳۸۵ از شرکت تحقیقات منابع آب دریافت شد. به منظور تعیین ارتفاع آب معادل برف در روزهای فاقد اندازه‌گیری از رابطه رگرسیونی هشت تاریخ مختلف ارتفاع آب معادل برف اندازه‌گیری شده و سطح پوشش برف استفاده گردید.

داده‌های هواشناسی و آب‌سنجی

آمار بارندگی روزانه از شرکت تحقیقات منابع آب در ایستگاه‌های هواشناسی (رودک، امامه، گلوکان (کمرخانی)، راحت‌آباد، آهار، گرمابدر، شمشک، رودبار قصران) و آمار دمای روزانه در ایستگاه‌های هواشناسی (امامه، راحت‌آباد، گلوکان) و دبی روزانه در ایستگاه آب‌سنجی رودک در طی سالهای ۱۳۸۲ تا ۱۳۸۵ دریافت شد. به منظور تعیین متوسط روزانه بارندگی و دما حوزه آبخیز از چندضلعی‌های تیسن استفاده شد.

تعیین متغیرهای ورودی

انتخاب داده‌ها اولین گام در ساختن مدل مناسب به منظور مدل‌سازی بارش - رواناب است. به طور کلی داده‌های ورودی به مدل شامل داده‌های مربوط به مشاهدات بارندگی روزانه، دمای روزانه و ارتفاع آب معادل برف روزانه و تاخیرهای زمانی مربوط به آنها است. بدین منظور با استفاده از نمودار خودهمبستگی جزئی تاخیرهای لازم برای مدل‌سازی متغیرهای ورودی به شبکه در نرم‌افزار STATISTICA به دست آمد (جدول ۱).

با توجه به جدول ۱ بارندگی، درجه حرارت و آب معادل برف هر کدام با یک روز تاخیر معنی‌دار می‌باشد. با بررسی بیشتر صورت گرفته در نهایت ورودی‌ها به شرح جدول ۲ مورد استفاده قرار گرفت.

جدول ۱- ضرایب خودهمبستگی جزئی در تاخیرهای مختلف

تاخیر	۱	۲	۳	۴	۵
بارندگی (mm)	۰/۴۱	-۰/۰۴	۰/۰۸	۰/۰۱۴	۰/۰۱۱
درجه حرارت (C°)	۰/۹۸	۰/۱۲	۰/۰۷	۰/۰۲۵	۰/۰۲۸
آب معادل برف (mm)	۰/۹۸	-۰/۰۵	-۰/۰۲	-۰/۰۲	-۰/۰۱

جدول ۲- ضرایب خودهمبستگی جزئی در تاخیرهای مختلف

ورودی مدل	ورودی مدل
$Q_t = f(R_t, R_{t-1}, R_{t-2})$	$Q_t = f(R_t)$
$Q_t = f(R_t, M_t)$	$Q_t = f(R_t, R_{t-1})$
$Q_t = f(R_t, R_{t-1}, T_t, T_{t-1}, M_t, M_{t-1})$	$Q_t = f(R_t, T_t)$
$Q_t = f(R_t, R_{t-1}, M_t, M_{t-1})$	$Q_t = f(R_t, R_{t-1}, T_t, T_{t-1})$
$Q_t = f(R_t, R_{t-1}, R_{t-2}, R_{t-3}, T_t, T_{t-1}, T_{t-2}, T_{t-3})$	$Q_t = f(R_t, R_{t-1}, R_{t-2}, T_t, T_{t-1}, T_{t-2})$
	$Q_t = f(R_t, T_t, M_t)$

آنالیز موجک

تبدیل موجک یکی از تبدیل‌های ریاضی کارآمد در زمینه پردازش سیگنال می‌باشد. اصولاً تبدیل‌های ریاضی برای به دست آوردن اطلاعات اضافی از سیگنال که از خود سیگنال قابل دستیابی نیستند استفاده می‌شوند. برای پردازش سیگنال، شمار زیادی از تبدیلات ریاضی می‌تواند مورد استفاده باشد که در میان آنها تبدیل فوریه مشهورترین به شمار می‌آید. تبدیل فوریه برای تبدیل یک سیگنال از قلمرو زمانی به قلمرو فرکانسی به کار می‌رود به عبارت دیگر پس از اعمال تبدیل فوریه، در صورت رسم تابع تبدیل شده، یک محور نشانگر فرکانس و محور دیگر نشانگر شدت یا دامنه (Amplitude) خواهد بود (شکل ۲). این شکل می‌تواند نشان دهد که از هر فرکانس، چه مقدار در سیگنال اولیه وجود دارد تبدیل فوریه اطلاعات مربوط به فرکانس‌های موجود در یک سیگنال را ارائه می‌کند، در حالی که از زمان رخ دادن یک فرکانس خاص هیچ اطلاعاتی به دست نمی‌دهد. اگر سیگنال از نوع ایستا (Stationary) باشد، به این اطلاعات نیازی

در این جدول: R_t و R_{t-2} و R_{t-1} به ترتیب بارندگی همان‌روز، یک روز پیشین و دو روز پیشین؛ T_{t-2} ، T_{t-1} ، T_t به ترتیب دمای همان‌روز، یک روز پیشین و دو روز پیشین؛ M_{t-1} ، M_t به ترتیب آب معادل برف همان‌روز و یک‌روز پیشین و Q_t دبی همان‌روز می‌باشد.

نرمال‌سازی داده‌ها

به منظور نرمال‌سازی داده‌ها از رابطه ۵ استفاده شد.

$$N_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (5)$$

که در آن: N_i = مقادیر استاندارد شده، X_i = مقادیر واقعی، X_{\min} = حداقل مقادیر واقعی و X_{\max} = حداکثر مقادیر واقعی می‌باشد که این رابطه ورودی‌ها را بین ۰ و ۱ نرمال می‌نماید.

زیر سری زمانی با مقیاس‌های مختلف را دارد، استفاده نمود و با مطالعه زیر سری‌های زمانی منتهی از سری زمانی کلی، رفتار کوچک مقیاس و بزرگ مقیاس یک فرآیند هیدرولوژیکی را مورد آنالیز قرار داد (الهی و برقی، ۲۰۱۰).

توابع موجک دارای انواع بسیاری هستند که مهمترین و پرکاربردترین آنها Haar، db4، Morlet و symlet می‌باشند (شکل ۴) (مالات، ۱۹۹۸). در این تحقیق از نوع و سطح موجکهای ذکر شده در جدول ۳ استفاده گردید.


نیست. در این حالت محتوای فرکانسی سیگنال در طول زمان تغییر نمی‌کند و محتوای فرکانسی ارائه شده توسط تبدیل فوریه، برای تمام طول سیگنال معتبر می‌باشد. در مواردی که سیگنال غیرایستا می‌باشد، آگاهی داشتن از زمان رخ دادن یک فرکانس خاص، اهمیت می‌یابد. با توجه به آن که سیگنال فرآیندهای هیدرولوژیکی عموماً غیرایستا بوده و محدوده وسیعی از مقیاس (از چند دقیقه تا چندین سال) را شامل می‌شوند به همین دلیل از تبدیل موجک به منظور رفع بعضی از کاستی‌های تبدیل فوریه استفاده می‌شود لذا می‌توان از تبدیل موجک (شکل ۳) که قابلیت تجزیه سری زمانی را به چندین



شکل ۲ - طرح شماتیک تبدیل فوریه (الهی و برقی، ۲۰۱۰)



شکل ۳ - طرح شماتیک تبدیل موجک (الهی و برقی، ۲۰۱۰)



شکل ۴ - الف) تابع موجک Haar ب) تابع موجک db4 پ) تابع موجک Meyer ت) تابع موجک Mexican hat

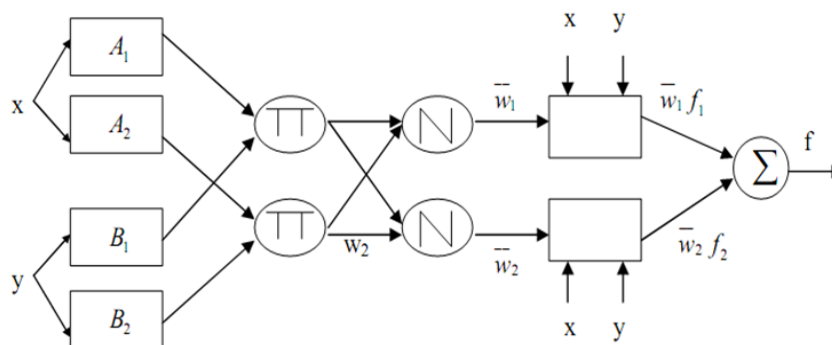
جدول ۳- نوع و سطح موجک های به کار گرفته شده در مدل ترکیبی موجک نروفازی

موجک مادری	زیرکلاس	سطح
Coif	Coif 1, Coif 2, Coif3, Coif4	Level 6,7,8,9,10, 5
Db	db 5, db 6, db 7, db 8, db 9, db 10	Level 6,7,8,9,10, 5
haar	haar	Haar6,7,8,9,10, 5
dmey	dmey	Dmey6,7,8,9,10, 5
bior	bior 1.1, bior 1.3, bior 1.5	Level 1,2,3
rbio	rbio 1, rbio 3, rbio 5,	Level 1,2,3
sym	10 sym, 9 sym, 8 sym, 7 sym, 6 sym, 5 sym	Level 6,7,8,9,10, 5

با تابع ورودی تفاوت دو سیگموئید و تابع خروجی خطی و برای غیر فازی نمودن از تابع میانگین متحرک استفاده گردید. نوع تابع فازی ساز زنگوله‌ای شکل استفاده گردید.

ساختار سیستم عصبی- فازی تطبیقی

در طراحی مدل نروفازی، از شبکه عصبی چندلایه پیش‌خور (MFNN) با الگوریتم یادگیری پس انتشار خطا و سیستم استنتاج فازی ساگنو



شکل ۵ - ساختار ANFIS مورد استفاده در این تحقیق

دسته‌بندی داده‌ها

در این تحقیق داده‌های متوسط بارندگی روزانه (P) بر حسب میلیمتر، متوسط دمای روزانه (t) بر حسب درجه سانتی‌گراد، ارتفاع آب معادل برف روزانه (M) بر حسب میلیمتر و هم‌چنین متوسط دبی روزانه (Q) بر حسب متر مکعب بر ثانیه در ایستگاه هیدرومتری رودک در سالهای ۱۳۸۲ تا ۱۳۸۵ به مدت سه سال آبی و کلا ۱۰۹۶ داده در ایستگاه هیدرومتری استفاده گردید. کل داده‌ها به دو دسته آموزش و آزمون تقسیم شد به طوری که ۷۰٪ داده‌ها برای آموزش (۷۶۸ داده) و ۳۰٪ برای آزمون (۳۳۰ داده) استفاده گردید.

معیارهای ارزیابی عملکرد شبکه‌ها

به منظور مقایسه نتایج حاصل مدل نروفازی با مقادیر واقعی در مرحله آزمون و مقایسه آن با مدل ترکیبی موجک- نروفازی و انتخاب بهترین مدل، از شاخص‌های آماری استفاده می‌شود. ضریب تبیین مقادیر مشاهده‌ای و برآوردی رایج‌ترین شاخص مقایسه‌ای است. با این وجود ضریب تبیین یک شاخص کلی بوده و نمی‌تواند شاخص مناسبی باشد (خان و کولیبالی، ۲۰۰۶) بنابراین در این تحقیق علاوه بر ضریب تبیین، دو شاخص دیگر ریشه میانگین مربع خطا (RMSE) (رابطه ۶) و ضریب کارایی نش- ساتکلیف (CE) (رابطه ۷) مورد استفاده قرار گرفت:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Q_o - Q_E)^2} \quad (۶)$$

$$CE = 1 - \frac{\sum_{i=1}^n (Q_o - Q_E)^2}{\sum_{i=1}^n (Q_o - \bar{Q}_o)^2} \quad (۷)$$

که در آن: Q_o و Q_E : به ترتیب دبی‌های مشاهده‌ای و محاسبه‌ای،

Q_{Ave-E} : میانگین دبی‌های محاسبه‌ای و Q_{Ave} : متوسط دبی‌های مشاهده‌ای است.

نتایج و بحث

مدلهای پیش‌بینی رواناب حاصل از ذوب برف

جدول ۴ خصوصیات آمار توصیفی داده‌های ورودی و خروجی مورد استفاده را نشان می‌دهد. بر اساس روش تحقیق ارائه شده مدل‌های پیش‌بینی به دست آمد (جدول ۵ تا ۷).

جدول ۴- خصوصیات آمار توصیفی داده‌های ورودی و خروجی

پارامتر	دسته	تعداد داده	میانگین	انحراف معیار	میزان ماکزیمم	میزان مینیمم
بارندگی (mm)	آموزش	۷۶۸	۲/۰۸	۵/۴۷	۶۸/۹۰	۰
	آزمون	۳۲۸	۲/۰۱	۵/۲۱	۳۱/۶۷	۰
	کل داده	۱۰۹۶	۲/۰۶	۵/۳۹	۶۸/۹۰	۰
درجه حرارت (C)	آموزش	۷۶۸	۱۰/۹۴	۸/۴۶	۲۹/۲۶	-۵/۴۵
	آزمون	۳۲۸	۱۱/۳۲	۹/۸۸	۲۶/۹۲	-۹/۳۲
	کل داده	۱۰۹۶	۱۱/۰۶	۹/۰۳	۲۹/۲۶	-۹/۳۲
آب معادل برف (mm)	آموزش	۷۶۸	۸۰/۸۷	۱۱۳	۲۹۲/۶۸	۰
	آزمون	۳۲۸	۷۹/۴۲	۱۱۲/۰۱	۲۹۲/۲۳	۰
	کل داده	۱۰۹۶	۸۰/۴۳	۱۱۲/۶۶	۲۹۲/۶۸	۰
دبی ($m^3 s^{-1}$)	آموزش	۷۶۸	۸/۹۹	۱۰/۲۱	۱۱۹	۲/۳۲
	آزمون	۳۲۸	۹/۹۸	۹/۳۶	۳۸/۷	۲/۱۷
	کل داده	۱۰۹۶	۹/۲۸	۹/۹۷	۱۱۹	۲/۱۷

جدول ۵- مدل‌های با ورودی‌های مختلف برای پیش‌بینی رواناب با استفاده از مدل ترکیبی موجک - نروفازی

ورودی		موجک		آمورش		آزمون	
				CE	RMSE	RMSE	CE
	Rt,Tt,Mt	2coif4		۰/۹۹	۰/۰۲۹	۰/۰۰۶	۰/۹۹
	Rt,Mt	2coif4		۰/۹۷	۰/۰۵۵	۰/۰۱۳	۰/۹۹
	Rt,Tt	4coif4		۰/۹۸۶	۰/۰۴۱	۰/۰۰۶	۰/۹۹
	Rt	2coif4		۰/۹۶	۰/۰۵۹	۰/۰۱۴	۰/۹۹
	Rt, Rt-1,Tt,Tt-1,Mt,Mt-1	4coif4		۰/۹۹	۰/۰۱۲	۰/۰۰۶	۰/۹۹
	Rt,Rt-1, Mt, Mt-1	4 2coif		۰/۹۸	۰/۰۴۲	۰/۰۱۱	۰/۹۹
	Rt,Rt-1, Tt, Tt-1	2coif3		۰/۹۹	۰/۰۱۴	۰/۰۰۶	۰/۹۹
	Rt, Rt-1	2coif3		۰/۹۷	۰/۰۵۷	۰/۰۱۹	۰/۹۹
	Rt, Rt-1,Rt-2, Tt, Tt-1, Tt-2	2coif4		۰/۹۹	۰/۰۲۳	۰/۰۰۶	۰/۹۹
	Rt, Rt-1, Rt-2	2sy3		۰/۹۷۷	۰/۰۴۶	۰/۰۲	۰/۹۹
	Rt, Rt-1, Rt-2, Rt-3,Tt,Tt-1, Tt-2,Tt-3	4coif4		۰/۹۹	۰/۰۰۸۲	۰/۰۰۷	۰/۹۹

با توجه به جدول ۶ مدل شبکه عصبی- فازی تطبیقی با ورودی باران، دما، آب معادل برف با یک روز تاخیر با ریشه میانگین مربعات خطا ۰/۰۵۹ و ضریب کارایی ۰/۶۵ نسبت به سایر مدل‌های نروفازی عملکرد بهتری داشته است.

با توجه به جدول ۵ مدل ترکیبی موجک شبکه عصبی- فازی تطبیقی با ورودی باران، دما، آب معادل برف با یک روز تاخیر با ریشه میانگین مربعات خطا ۰/۰۰۶ و ضریب کارایی ۰/۹۹ نسبت به سایر مدل‌های موجک- نروفازی عملکرد بهتری داشته است.

جدول ۶- مدل با ورودی های مختلف برای پیش‌بینی رواناب با استفاده از مدل نروفازی (تقسیم‌بندی خوشه‌ای)

آزمون		آمورش		ورودی
CE	RMSE	RMSE	CE	
۰/۰۸۱	۰/۴۴۷	۰/۰۷۶	۰/۴۶۷	Rt
۰/۰۸۱	۰/۴۶۵	۰/۰۶۹	۰/۵۶۰	Rt, Rt-1
۰/۰۹۷	۰/۱۸۵	۰/۰۶۵	۰/۶۱۰	Rt, Rt-1, Rt-2
۰/۱۱۰	-۰/۰۷۵	۰/۰۶۳	۰/۶۳۳	Rt, Rt-1, Rt-2, Rt-3
۰/۰۷۷	۰/۵۵۶	۰/۰۶۴	۰/۶۲۹	Rt, Tt
۰/۰۷۶	۰/۵۶۲	۰/۰۵۴	۰/۷۲۹	Rt, Rt-1, Tt, Tt-1
۰/۰۸۴	۰/۴۳۷	۰/۰۴۸	۰/۷۹۱	Rt, Rt-1, Rt-2
۰/۱۰۳	۰/۱۴۸	۰/۰۳۹	۰/۸۵۸	Rt, Rt-1, Rt-2, Rt-3
۰/۰۶۸	۰/۶۰۶	۰/۰۵۲	۰/۷۴۸	Rt, tt, Mt
۰/۰۵۹	۰/۶۵۶	۰/۰۳۳	۰/۸۹۹	Rt, Rt-1, Tt, Tt-1, Mt, Mt-1
۰/۰۷۴	۰/۵۲۹	۰/۰۶۱	۰/۶۵۷	Rt, Mt
۰/۰۷۹	۰/۴۶۴	۰/۰۵۳	۰/۷۳۹	Rt, Rt-1-, Mt, Mt-1-

جدول ۷- مدل با ورودی های مختلف برای پیش‌بینی رواناب با استفاده از مدل نروفازی (تقسیم‌بندی شبکه‌ای)

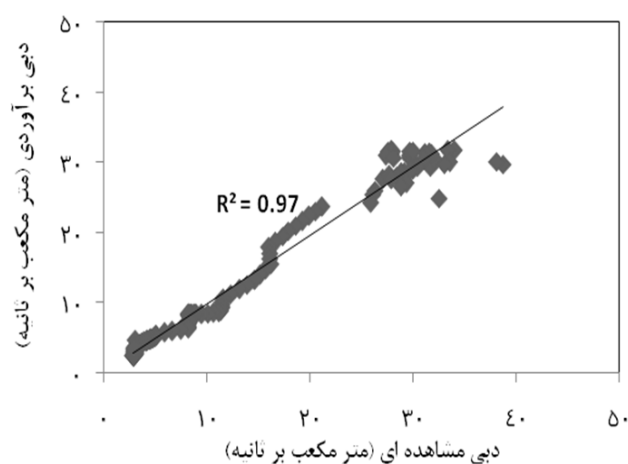

آزمون		آمورش		ورودی
RMSE	CE	RMSE	CE	
۰/۰۸۳	۰/۰۱۶	۰/۰۷۹	۰/۱۶۷	Rt
۰/۰۸۳	۰/۰۲۴	۰/۰۷۷	۰/۲۰	Rt, Rt-1
۰/۰۸۳	۰/۰۲۷	۰/۰۷۶	۰/۲۳۱	Rt, Rt-1, Rt-2
۰/۰۸۳	۰/۰۲۸	۰/۰۷۶	۰/۲۴۲	Rt, Rt-1, Rt-2, Rt-3
۰/۰۷۶	۰/۱۶	۰/۰۶۶	۰/۴۰۹	Rt, Tt
۰/۰۷۴	۰/۱۹۳	۰/۰۵۸	۰/۵۳	Rt, Rt-1, Tt, Tt-1
۰/۰۷۱۱	۰/۲۴	۰/۰۵۶	۰/۵۷	Rt, Rt-1, Rt-2
۰/۰۶۹	۰/۳۰	۰/۰۵۴	۰/۵۹	Rt, Rt-1, Rt-2, Rt-3
۰/۰۵۹	۰/۶۵	۰/۰۴۷	۰/۷۰۵	Rt, Tt, Mt
۰/۱۳	۰/۴۳۵	۰/۰۴۶	۰/۷۰۵	Rt, Rt-1, Tt, Tt-1, Mt, Mt-1
۰/۰۷۴	۰/۱۶۸	۰/۰۶۶	۰/۴۰۹	Rt, Mt
۰/۰۷۲	۰/۲۲۰	۰/۰۶۴	۰/۴۴۸	Rt, Rt-1, Mt, Mt-1

داشته است. جدول ۸ و اشکال ۶ تا ۱۱ بهترین مدل‌های شبیه‌سازی رواناب را نشان می‌دهند.

با توجه به جدول ۷ مدل شبکه عصبی-فازی تطبیقی با ورودی باران، دما، آب معادل برف با ریشه میانگین مربعات خطا ۰/۰۵۹ و ضریب کارایی ۰/۶۴ نسبت به سایر مدل‌های نروفازی عملکرد بهتری


جدول ۸- بهترین مدل‌های شبیه‌سازی برای پیش‌بینی رواناب

مدل	ورودی	آمورش		آزمون	
		CE	RMSE	CE	RMSE
موجک- نروفازی	Rt, Rt-1, Tt, Tt-1, Mt, Mt-1	۰/۹۹	۰/۰۱۲	۰/۹۹	۰/۰۰۶
نروفازی (شبکه‌ای)	Rt, Rt-1, Tt, Tt-1, Mt, Mt-1	۰/۸۸	۰/۰۳	۰/۶۵	۰/۰۵۹
نروفازی (خوشه‌ای)	Rt, Tt, Mt	۰/۷۰	۰/۰۴۷	۰/۴۵	۰/۰۵۹




شکل ۷- پراکنش داده‌های دبی مشاهده‌ای و برآوردی مدل نروفازی (شبکه‌ای)

شکل ۶- پراکنش داده‌های دبی مشاهده‌ای و برآوردی مدل موجک-نروفازی




شکل ۸- پراکنش داده‌های دبی مشاهده‌ای و برآوردی مدل نروفازی (خوشه‌ای)

صحيح تری داشته است. در ضمن دومین حداکثر دبی مشاهده‌ای (۳۸/۱ متر مکعب بر ثانیه) را نیز مدل ترکیبی موجک-نروفازی (۳۰/۱۰ درصد کمتر)، شبکه عصبی-فازی تطبیقی (شبکه‌ای) (۳۶/۷۶ درصد کمتر) و مدل نروفازی (خوشه‌ای) (۲۶/۸۱ متر مکعب بر ثانیه) (۲۹/۶۳ درصد کمتر) برآورد کرده با توجه به نتایج حاصله مشخص می‌گردد که مدل شبکه عصبی فازی تطبیقی (شبکه‌ای) نسبت به دو مدل دیگر پیش‌بینی صحیح‌تری انجام داده است.




شکل ۱۰- مقایسه دبی مشاهده ای با دبی برآوردی مدل نروفازی (شبکه ای)

با توجه به اشکال ۶ تا ۸ اولین حداکثر دبی مشاهده‌ای (۳۸/۷ متر مکعب بر ثانیه) در مرحله آزمون را بهترین مدل ترکیبی موجک عصبی-فازی تطبیقی به میزان ۲۹/۷۶ (۲۳/۱ درصد کمتر)، بهترین مدل شبکه عصبی-فازی تطبیقی (شبکه‌ای) به میزان ۳۶/۳۷ (۶/۰۲ درصد کمتر) متر مکعب بر ثانیه، مدل نروفازی (خوشه‌ای) (۲۸/۰۰ درصد کمتر) برآورد کرده است که با توجه به این نتایج مدل شبکه عصبی-فازی تطبیقی (شبکه‌ای) نسبت به دو مدل دیگر پیش‌بینی



شکل ۹- مقایسه دبی مشاهده ای با دبی برآوردی مدل موجک-نروفازی



شکل ۱۱- مقایسه دبی مشاهده‌ای با دبی برآوردی مدل نروفازی (خوشه ای)

باران، دما و آب معادل برف با ریشه میانگین مربعات خطا $0/059$ و ضریب تبیین $0/65$ دارای عملکرد بهتری بوده است که نشان می‌دهد مدل موجک-نروفازی نسبت به مدل نروفازی (شبکه‌ای) و نروفازی (خوشه‌ای) پیش‌بینی دقیق‌تری داشته است که با نتایج نورانی و همکاران (۲۰۰۹)، هویفانگ‌گو و همکاران (۲۰۰۹) و نورانی و همکاران (۲۰۱۱) هم‌خوانی دارد. همچنین نتایج این تحقیق نشان داد که دخالت دادن آب معادل برف باعث افزایش دقت پیش‌بینی رواناب می‌گردد. به‌طور کلی می‌توان نتیجه گرفت که استفاده از مدل ترکیبی موجک-نروفازی و استفاده از آب معادل برف باعث افزایش دقت پیش‌بینی رواناب در حوزه‌های آبخیز تحت تاثیر برف می‌گردد. پیشنهاد می‌گردد از نتایج این تحقیق برای مدل‌سازی بارش-رواناب استفاده شود. همچنین از سایر روش‌های مدل‌سازی از قبیل سیستم پشتیبان بردار و همچنین الگوریتم‌های فراابتکاری از قبیل الگوریتم

نتیجه‌گیری

مدل‌های عصبی-فازی تطبیقی و مدل ترکیبی موجک-نروفازی به دلیل قدرت مدل‌سازی روابط غیر خطی پیچیده و عدم نیاز به پارامترهای زیاد در چند دهه اخیر کاربرد زیادی در بررسی رابطه بارش-رواناب پیدا کرده‌اند. در جدول ۸ به ترتیب بهترین ساختار موجک-نروفازی با توجه به ریشه میانگین مربعات خطا، ضریب تعیین و ضریب کارایی با ورودی‌های مختلف آورده شده است. با توجه به جدول ۸ مدل موجک-نروفازی با ورودی باران، دما و آب معادل برف با یک روز تاخیر با ریشه میانگین مربعات خطا $0/006$ و ضریب تبیین $0/97$ نسبت به مدل نروفازی با ورودی باران، دما و آب معادل برف بدون تاخیر با ریشه میانگین مربعات خطا $0/059$ و ضریب تبیین $0/62$ و شبکه نروفازی (تفکیک خوشه‌ای) با ورودی

10. Khan, S.M., Coulibaly, P., and Dibike, Y., (2006). Uncertainty analysis of statistical downscaling methods. *Journal of Hydrology*, 382-357:(1)319.
11. Klein, A.G., Hall, D.K., and Seidel, G.A. (1998). Aloritm Intercomparison for Accuracy Assessment of the MODIS Snow-mapping Algorithm. 55th Annual Eastern Snow Conference. New Hampshire, June 3-2 Jackson.
12. Kurtulus, B., Moutmaz, R. (2010). Modeling daily discharge responses of a large karstic aquifer using soft computing methods: Artificial neural network and neuro-fuzzy. *Journal of Hydrology*, 111-101:(1)381.
13. Mallat, S.G. (1998). A Wavelet tour of signal processing. Academic Press. Diego. P:557.
14. Nayak, P. C., Sudheer, K. P., Rangan, D. M. and Ramasastri, K.S. (2004). A Neuro-Fuzzy Computing Technique for Modeling Hydrological Time Series. *Journal of Hydrology*, 66-52 :(1)291.
15. Nourani, V., Hasanzadeh, Y., Komasi, M. and Sharghi, A. (2008). Rainfall-runoff modeling by hybrid wavelet-ANN model. 4th National Congress on Civil Engineering. University of Tehran. (In Persian)
16. Nourani, V., Kisi, O., Komasi, M. (2011). Two hybrid Artificial Intelligence approaches for modeling rainfall-runoff process. *Journal of Hydrology*, 59-41:(1)402.
17. Nourani, V., Salehi, K., Abolvaset, N. and Salehi, M. (2009). Rainfall-runoff modeling using wavelet-ANFIS and comparison with wavelet-ANN and ANFIS methods. 8th International Congress on Civil Engineering.
18. Pustizadeh, N., Najafi, N. (2011). Discharge Prediction by Comparing Artificial Neural Network with Fuzzy Inference System (Case study: Zayandehrud River). *Iran-Water Resources Research*, 97-92:(2)7. (In Persian)
19. Vafakhah, M., Mohseni Saravi, M., Mahdavi, M. and Alavipanah, S. K. (2011). Snowmelt runoff prediction by using artificial neural network and adaptive neuro-fuzzy inference system in Taleghan Watershed. *Iran-Watershed Management Science & Engineering*, 35-23:(14)5. (In Persian)
20. Wang, W., Van Gelder, P.H.A.J.M., Vrijling, J.K., Ma, J. (2006). Forecasting Daily Stream Flow using Hybrid ANN Models. *Journal of Hydrology*, -1)324 399-383:(4).
- ژنتیک به منظور مدل‌سازی بارش-رواناب استفاده شود و نتایج آن با تحقیق حاضر مقایسه گردد.
- ### منابع مورد استفاده
1. Cannas, B., Fanni, A., See, L., Sias, G. (2006). Data preprocessing for river flow forecasting using neural networks: wavelet transforms and data partitioning. *Physics and Chemistry of the Earth*, 1171-1164:(18)31.
 2. Dastorani M., Darani H., Talebi A. and Moghadamnia A. (2011). The performance of ANNs and ANFIS for rainfall-runoff modeling inside Zaiandeh-rood watershed. *Journal Water and Wastewater*, -114:(4)80 125. (In Persian)
 3. Ebrahimi, L. and Barani, G. (2005b), Wavelet-based analysis of input discharges into a Vanyar dam reservoir of Tabriz. Second National Conference Watershed, Water Recourses and Soil Management. Shahid Bahonar University of Kerman. p. 2342-2335. (In Persian)
 4. Ebrahimi, L. and Barani, G. (2005a), An introduction for wavelet-ANN hybrid model for prediction of droughts in dam watersheds". Second National Conference Watershed, Water Recourses and Soil Management. Shahid Bahonar University of Kerman. pp. 2359-2354. (In Persian)
 5. Elahi, R. and Borghaei, M. (2010). Wavelet-ANN hybrid model for rainfall-runoff simulation. 5th National Congress on Civil Engineering. Ferdowsi University of Mashhad. (In Persian)
 6. Firat, M. and Güngör, M. (2006). River Flow Estimation Using Adaptive Neuro Fuzzy Inference System, *Mathematics and Computers in Simulation*. 62-52:(3)11.
 7. Hall, D. K., Riggs, G.A., Salomonson, V.V. (2001). Algorithm theoretical Basis Document (ATBD) for the MODIS Snow and Sea Ice Mapping Algorithms, Available at: http://modis.gsfc.nasa.gov/data/atbd/atbd_mod10.pdf
 8. Huifang, G., Zengchuan, D., Xixia, M. (2009). WANFIS Model for Monthly Runoff Forecast" Joint International Convention of 8th IAHS Scientific Assembly and 37th IAH Congress Water. A vital resource under stress-How Science can help, September 12-6, ,Hyderabad, India.
 9. Jang, J.-S. R. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE Trans. System Management in Cybernetics*, 685-665:(3)23.

basin scale. Water Resource Management, -2271:(11)23
2287.

23. Zhang, G.P. (2003).Time series forecasting
using hybrid ARIMA and neural network model.
Neurocomputing 175-50:159.

21. Zare Abyaneh, H., and Bayat Varkeshi, M. (2011).
Evaluation of artificial intelligent and empirical models
in estimation of annual runoff. Journal of Water and
Soil,, 379-365:(2)25. (In Persian)

22. Zeinivand, H. and De Smedt, F. (2009). Hydrological
modeling of snow accumulation and melting on river

■ ■ ■ ■ ■ ■ ■ ■ ■ ■ ■