

بررسی قابلیت پارامتر Cprecip در منظور کردن اثر برف بر پیش بینی دبی روزانه رودخانه به وسیله شبکه عصبی و شبکه عصبی فازی

سیدمحمد سیدعباسی^{۱*}، مهدی گوران اوریمی^۲، علی فریدحسینی^۳ و محمدباقر شریفی^۴

S_mmehti_abasi@yahoo.com

*۱- نویسنده مسئول، کارشناسی ارشد برق کنترل، دانشگاه فردوسی مشهد

۲- کارشناس ارشد عمران سازه هیدرولیک، دانشگاه فردوسی مشهد

۳- استادیار گروه مهندسی آب، دانشگاه فردوسی مشهد

۴- استادیار گروه عمران دانشکده مهندسی، دانشگاه فردوسی مشهد

تاریخ پذیرش: ۱۳۹۰/۱۰/۲۰

تاریخ دریافت: ۱۳۸۹/۱۲/۲۲

چکیده

یکی از پارامترهای موثر در پیش بینی دبی خصوصاً در حوضه‌های برفگیر، پارامتر برف می‌باشد. آب معادل برف متداول‌ترین پارامتری است که در مدل‌سازی جریان رودخانه‌ها، به منظور وارد کردن تأثیر برف در مدل استفاده می‌شود. در این مقاله سعی شده است با توجه به عدم دسترسی به پارامتر آب معادل برف در درصد قابل توجهی از حوضه‌ها، پارامترهای باران تجمعی و باران تجمعی مازندران جایگزین آب معادل برف شوند. پارامتر باران تجمعی، بارندگی تجمعی از اول نوامبر تا اول آپریل و معرف برف انباشته شده می‌باشد که در بهار ذوب می‌شود. پارامتر باران تجمعی مازندران با انجام تغییراتی بر روی پارامتر باران تجمعی (جهت سازگاری آن با حوضه‌های مازندران) به دست می‌آید. نتایج مدل‌سازی نشان داد که پارامتر باران تجمعی قابلیت جایگزینی پارامتر آب معادل برف را دارد و پارامتر باران تجمعی مازندران با توجه به انطباق بیشتر با حوضه‌های این ناحیه، کارایی بیشتری نسبت به پارامتر باران تجمعی دارد.

کلید واژه‌ها: پیش بینی دبی، برف، شبکه عصبی مصنوعی، شبکه عصبی فازی.

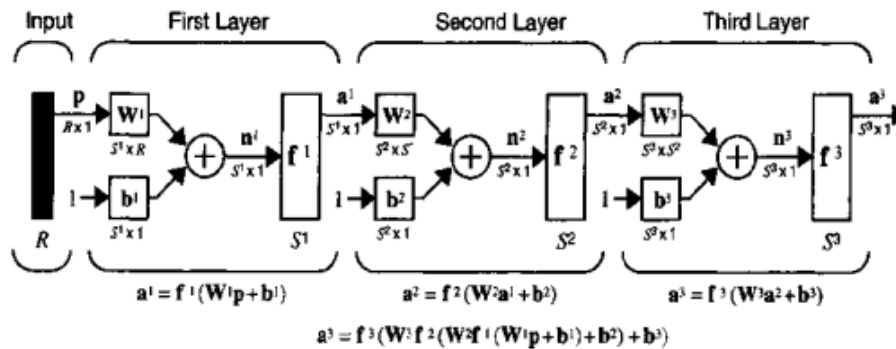
مقدمه

و خروجی هستند، خصوصاً در شرایطی که روابط پیچیده و غیر خطی هستند (۳، ۱۶، ۱۷).
با توجه به تحقیقاتی که در گذشته انجام شده است یکی از پارامترهای موثر در پیش بینی دبی خصوصاً در حوضه‌های برفگیر، پارامتر برف است. آبی که از ذوب برف ذخیره شده در حوضه رودخانه‌ها حاصل می‌شود، تأثیر قابل ملاحظه‌ای بر دبی روزانه رودخانه‌ها دارد (۴، ۵، ۶). آب معادل برف^۳ متداول‌ترین پارامتری است که در مدل‌سازی جریان رودخانه‌ها، به منظور وارد کردن تأثیر برف در مدل استفاده می‌شود. از طرفی اطلاعات آماری پارامتر آب معادل برف در درصد قابل ملاحظه‌ای از حوضه‌ها یا موجود نیست یا بازه آماری آن برای مدل‌سازی کافی نیست. در نتیجه نیاز به استفاده از پارامتر جایگزینی که در دسترس باشد احساس می‌شود. از پارامتر باران تجمعی^۴ (که معرف برف انباشته شده است) به عنوان ورودی مدل برای پیش بینی جریان حوضه وینیپگ^۵ کانادا استفاده کردند (۱۵، ۱۸).

در نگرش جدید جهانی، آب کالایی اقتصادی-اجتماعی و به عنوان نیاز اولیه انسان محسوب می‌شود. نظر به اهمیت و محدودیت منابع آب در عصر حاضر، مدیریت این منابع از اهمیت ویژه‌ای برخوردار است. در زمینه مهندسی رودخانه به ویژه در مواردی که مسئله برداشت آب از رودخانه مطرح است، آگاهی از کمیت آب اهمیت ویژه‌ای دارد. با توجه به اهمیت مسئله پیش بینی دبی رودخانه‌ها استفاده از امکانات رایانه‌ای و جدیدترین نوآوری‌های موجود در این زمینه ضروری است. نظیر مدل‌های آماری، هیدرولیکی و هیدرولوژیک در پیش بینی جریان رودخانه‌ها، از اواسط دهه ۱۹۹۰ استفاده از مدل‌های هوش مصنوعی نظیر شبکه‌های عصبی مصنوعی^۱ و یا شبکه‌های عصبی فازی^۲ مرسوم گردید (۱۱، ۱۲). در شرایطی که مدل‌های مفهومی هیدرولیکی و هیدرولوژیک در مرحله واسنجی با مشکل مواجه بوده و نسبت به تغییرات پارامترهای ورودی حساس هستند و برخی مدل‌های تجربی و آماری فاقد قدرت تعمیم دهی لازم می‌باشند، مدل‌های هوش مصنوعی ابزار مناسبی برای ایجاد رابطه بین مقادیر ورودی

3- Snow water equivalent
4- Cumulative precipitation
5- Winipeg

1- Artificial neural networks
2- Fuzzy neural network



شکل ۱- ساختار شبکه عصبی مصنوعی

عصبی فازی به صورت شماتیک در شکل (۲) نشان داده شده است. همان‌طور که از شکل پیداست، ساختار شبکه از پنج لایه تشکیل شده است:

لایه یک: این لایه، لایه ورودی می‌باشد که بیان‌کننده توابع عضویت فازی می‌باشد. شکل تابع عضویت و میزان هم‌پوشانی آن‌ها دلخواه بوده و توسط کاربر تعیین می‌شود:

$$\mu_A(X) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2b_i}} \quad (1)$$

که در اینجا x برابر ورودی است. لایه دو: در این لایه مقادیر سیگنال‌های ورودی به هر گره در هم ضرب شده و حاصل که وزن قانون‌ها می‌باشد، به دست می‌آید:

$$w_i = \mu_{A_i}(X_1) \mu_{B_i}(X_2) \quad (2)$$

لایه سه: گره‌های این لایه عمل محاسبه وزن نسبی قوانین را انجام می‌دهد:

$$\bar{w}_i = \frac{w_i}{\sum_{i=1}^n w_i}, i = 1, 2, \dots, n \quad (3)$$

لایه چهار: این لایه، لایه قوانین نامیده می‌شود که قوانین از ورودی‌ها به این لایه به دست می‌آیند:

$$z_i = \bar{w}_i f_i = \bar{w}_i (p_1^1 x_1 + q_i^1 x_2 + r_i^1) \quad (4)$$

هدف اصلی این مقاله بررسی تأثیر پارامتر باران تجمعی و مقایسه آن با پارامتر آب معادل برف در مدل سازی بوسیله دو ابزار مختلف شبکه عصبی و شبکه عصبی فازی است.

مواد و روش‌ها

شبکه عصبی


شبکه‌های عصبی مصنوعی در واقع از ساختار درهم و توده‌ای مغز پستانداران الهام گرفته شده است که در آن میلیون‌ها سلول عصبی (نورون) از طریق ارتباطاتی که با یکدیگر دارند (سیناپس‌ها)، به حل مسائل یا ذخیره‌سازی اطلاعات می‌پردازند (۱). ساختار اصلی شبکه‌های عصبی مصنوعی بر اساس دو جزء اصلی گره‌ها (نورون‌ها) و ارتباطات وزن‌دار (سیناپس‌ها) می‌باشد (شکل ۱).

یادگیری در سیستم‌های طبیعی به صورت تطبیقی اتفاق می‌افتد. بدین معنی که در اثر یادگیری، در سیناپس‌ها تغییراتی رخ می‌دهد. عین همین مسئله نیز در مورد شبکه‌های عصبی مصنوعی نیز صادق است. در این شبکه‌ها یادگیری از طریق مثال انجام می‌شود. بدین معنی که اغلب (و نه همواره) مجموعه‌ای از ورودی‌ها و خروجی‌های درست به شبکه عصبی داده می‌شود و شبکه عصبی با استفاده از این مثال‌ها، وزن‌های ارتباطات خود را به گونه‌ای تغییر می‌دهد که در صورت دادن ورودی‌های جدید پاسخ‌های درستی را تولید کند. در واقع دانش شبکه عصبی در وزن ارتباطات آن ذخیره می‌شود.

شبکه عصبی فازی

از زمانی که پروفیسور لطفی زاده برای اولین بار تئوری منطق فازی را برای سیستم‌های پیچیده ارائه داد، این نظریه به طور گسترده‌ای در مسائل مختلف با موفقیت استفاده شده است. راجر^۱ اولین بار با مد نظر قرار دادن توانایی تئوری فازی و شبکه عصبی، مدل سیستم استنتاج تطبیقی عصبی فازی را ارائه داد (۱۳). مدل استنتاج تطبیقی عصبی فازی شبکه‌ای چند لایه، متشکل از گره‌ها و کمان‌های اتصال دهنده گره‌ها می‌باشد (۹، ۱۰). ساختار مدل شبکه

1- Roger



شکل ۲- ساختار شبکه عصبی فازی

شکلی، معرف برف انباشته شده تا زمان جاری می‌باشد که طی زمان ذخیره شده و در بهار ذوب می‌شود [۱۸].

بارندگی تجمعی از اول نوامبر مخصوص مازندران

پارامتر باران تجمعی مخصوص حوضه وینپیگ کانادا و با توجه به شرایط جوی آن طراحی شده است. به همین منظور نیاز برای انجام تغییراتی در آن به منظور استفاده از آن در حوضه های مازندران احساس می شود. در حوضه وینپیگ کانادا برف در تمام سال موجود می‌باشد، در حالی که در حوضه های مازندران برف‌ها به جز در مناطقی خاص و محدود، تا اواخر بهار ذوب می‌شوند. به همین دلیل در پارامتر باران تجمعی مازندران بعد از اینکه بارندگی تجمعی از دهم آبان تا دوازدهم فروردین محاسبه شد، این مقدار به صورت خطی کاهش داده می‌شود به شکلی که در دهم خرداد به صفر می‌رسد.

نرمال سازی

با توجه به دامنه وسیع داده‌های مورد استفاده در این تحقیق، برای نرمال کردن الگوها از رابطه (۶) استفاده شده است:

$$x_n = \frac{X - X_{Min}}{X_{Max} - X_{Min}} \quad (6)$$

که در آن :

X_n : معرف داده‌های نرمال شده،

X : معرف داده‌های مشاهده‌ای خام،

X_{Max} : معرف حداکثر داده‌های مشاهده‌ای خام و

X_{Min} : معرف حداقل داده‌های مشاهده‌ای خام می‌باشد.

لایه پنجم: این لایه آخرین لایه شبکه می‌باشد و از یک گره تشکیل شده است. تنها گره این لایه وظیفه جمع بندی تمامی ورودی‌های به این گره را بر عهده دارد:

$$z = \sum_i \overline{w_i} f_i \quad (5)$$

یکی از مشخصه‌های هر مدل شبکه عصبی فازی نوع تابع عضویت در نظر گرفته شده برای ورودی‌های مدل می‌باشد. توابع عضویت انواع متفاوتی دارند، از آن جمله می‌توان به توابع دوزنقه‌ای، مثلثی و تابع زنگوله‌ای گوس اشاره کرد.

آب معادل برف

ذوب برف بخش عمده‌ای از دبی پایه رودخانه‌هایی که حوضه برفگیر دارند را تأمین می‌نماید، مضافاً اینکه برف به واسطه انباشت و ذوب نقش مهمی در رفتار سیلابی این رودخانه‌ها دارد. در چنین شرایطی آب معادل برف به عنوان متداول‌ترین متغیر برای پیش بینی‌های هیدرولوژیکی به شمار می‌آید. آب معادل برف عبارت است از ارتفاع آبی که در اثر ذوب برف به وجود می‌آید (۱۵).

باران تجمعی از اول نوامبر

زلاند و بورن^۱ برای بهبود عملکرد شبکه عصبی مورد استفاده جهت پیش بینی دبی ورودی در حوضه وینپیگ کانادا از پارامتر باران تجمعی استفاده کردند. پارامتر باران تجمعی بارندگی تجمعی از اول نوامبر (دهم آبان) تا اول آپریل (دوازدهم فروردین) می‌باشد که به

1- Zealand and Burn



شکل ۳- موقعیت و حوضه آبریز رودخانه تاجن معیارهای سنجش خطا و دقت

هر چه مقدار جذر متوسط مربع خطاها به صفر نزدیکتر باشد، نشان دهنده نزدیکتر بودن مقادیر مشاهده شده و محاسبه شده به یکدیگر و دقیق‌تر بودن جواب‌ها در هر مرحله است.
(ج) ضریب کارایی^۳:

$$R^2 = 1 - \frac{\sum_{i=1}^n (obs - forc)^2}{\sum_{i=1}^n (\overline{obs - forc})^2} \quad (9)$$

هر چه مقدار ضریب کارایی به یک نزدیکتر باشد، نشان دهنده نزدیکتر بودن مقادیر مشاهده شده و محاسبه شده به یکدیگر و دقیق‌تر بودن جواب‌ها در هر مرحله است.

مطالعه موردی

جهت بررسی کارایی پارامتر باران تجمعی در منظور کردن اثر برف در پیش بینی جریان رودخانه به وسیله شبکه عصبی و شبکه عصبی فازی، از اطلاعات مربوط به رودخانه سفیدرود استفاده شده است (۲). رودخانه سفید رود، شاخه اصلی رودخانه تاجن است که آب مخزن سد شهید رجایی ساری را تأمین می‌کند. سد شهید رجایی (سلیمان تنگه) در ۴۱ کیلومتری جنوب شهر ساری و در نزدیکی

دقت پیش بینی به وسیله معیارهای سنجش و دقت مورد بررسی قرار می‌گیرد. معیارهای مورد استفاده در این مقاله در هر یک از آزمون‌ها مشتمل بر سه معیار زیر است:
(الف) ضریب همبستگی^۱:

$$CORR = \frac{\sum_{i=1}^n ((obs - \overline{obs}) * (forc - \overline{forc}))}{\sqrt{\sum_{i=1}^n (obs - \overline{obs})^2 * \sum_{i=1}^n (forc - \overline{forc})^2}} \quad (7)$$

که در آن \overline{obs} میانگین obs ها (میزان جریان مشاهده‌ای) و \overline{forc} میانگین $forc$ ها (میزان جریان پیش بینی شده توسط شبکه) و n برابر تعداد داده‌ها در مرحله تست می‌باشد.
هر چه مقدار ضریب همبستگی به یک نزدیکتر باشد، نشان دهنده نزدیکتر بودن مقادیر مشاهده شده و محاسبه شده به یکدیگر و دقیق‌تر بودن جواب‌ها در هر مرحله است (۱۴).
(ب) جذر متوسط مربع خطاها^۲:

$$RMSE = \frac{\sqrt{\sum_{i=1}^n (obs - forc)^2}}{n} \quad (8)$$

3- Coefficient of Efficiency

1- Correlation Coefficient
2- Root Mean Square Error

جدول ۱ - نتایج مدل الگوهای ورودی مختلف با مدل سازی شبکه عصبی و شبکه عصبی فازی

روش پیش بینی	ورودی	ضریب همبستگی	ضریب کارایی	جذرمی متوسط مربع خطاها
شبکه عصبی	الگوی اول	۰/۹۶۰۸	۰/۹۱۹۹	۰/۴۹۳۱
شبکه عصبی فازی		۰/۹۶۳۷	۰/۹۲۲۳	۰/۴۸۵۹
شبکه عصبی	الگوی دوم	۰/۹۶۱۹	۰/۹۲۰۹	۰/۴۹۰۳
شبکه عصبی فازی		۰/۹۶۴	۰/۹۲۳	۰/۴۸۳۶
شبکه عصبی	الگوی سوم	۰/۹۶۲۵	۰/۹۲۶۲	۰/۴۷۳۶
شبکه عصبی فازی		۰/۹۶۵۲	۰/۹۲۶۷	۰/۴۷۱۹

نتایج

در این تحقیق جهت راحتی و سرعت بیشتر در انجام سعی و خطا و پیدا کردن شبکه‌های بهینه، دو برنامه برای مدل سازی شبکه‌های عصبی و عصبی فازی در محیط برنامه نویسی مطلب نوشته شده است. برای پیش بینی جریان رودخانه از شبکه عصبی MLP سه لایه با قانون آموزش مارکوارت لوبنرگ^۱ استفاده شده است و در طراحی مدل شبکه عصبی فازی از شبکه عصبی چند لایه پیشخور با الگوریتم یادگیری پس انتشار خطا و سیستم استنتاج فازی تاکاگی سوگونو^۲ استفاده شد. سپس به کمک این دو برنامه و داده‌های مربوط به رودخانه سفیدرود، اقدام به آموزش و نهایتاً تست مدل‌ها گردیده است.

نتایج ضریب کارایی شبکه‌های عصبی و عصبی فازی برای الگوهای مختلف ورودی برای مدل سازی جریان رودخانه سفیدرود، در جدول (۱) آورده شده است. همچنین نمودارهای حاصل از شبیه سازی مرحله تست در شکل‌های (۴) الی (۹) آورده شده است.

نتیجه‌گیری و پیشنهادها

در این تحقیق کارایی مدل‌های شبکه عصبی و شبکه عصبی فازی در پیش بینی دبی روزانه رودخانه سفیدرود مورد بررسی قرار گرفت. نتایج نشان دهنده کارایی مناسب‌تر مدل شبکه عصبی فازی نسبت به مدل شبکه عصبی می‌باشد. همچنین با توجه به ثابت بودن پارامترهای ورودی باران و دبی و میزان تأخیر آنها در هر سه الگو، با مقایسه ضرایب کارایی الگوهای اول و دوم مشاهده می‌شود که پارامتر باران تجمعی قابلیت جایگزینی پارامتر آب معادل برف را در حوضه‌های برفگیر دارد و با توجه به مقایسه ضرایب کارایی الگوهای دوم و سوم مشاهده می‌شود که پارامتر باران تجمعی مازندران انطباق بیشتری با حوضه مازندران نسبت به پارامتر باران تجمعی دارد.

روستای افراچال قرار دارد. رودخانه سفید رود از دامنه‌های جنوبی رشته کوه‌های البرز سرچشمه گرفته است و بعد از ملحق شدن به رودخانه تجن در انتها به دریای خزر می‌ریزد. در شکل (۳) موقعیت و حوضه آبریز رودخانه تجن نشان داده شده است. در این مقاله از تاریخ ۱۳۸۱/۹/۲۴ تا تاریخ ۱۳۸۵/۱/۱۴، ۱۳۸۵/۱۲/۰۰ سری داده برای آموزش و از تاریخ ۱۳۸۵/۱/۱۵ تا تاریخ ۱۳۸۶/۹/۳ ۶۰۰ داده برای تست شبکه انتخاب شده است. با توجه به تأثیر ترکیب پارامترهای ورودی در نتایج تحقیق و مدل سازی برای مدل سازی جریان رودخانه سفیدرود تجن از سه الگوی زیر برای پیش بینی دبی روز بعد استفاده شده است (۷، ۸):

$$Q(t+1) = f\{SWE(t), P(t), P(t-1), Q(t), Q(t-1)\} \quad (10)$$

$$Q(t+1) = f\{CPrecp(t), P(t), P(t-1), Q(t), Q(t-1)\} \quad (11)$$

$$Q(t+1) = f\{MAZ-CPrecp(t), P(t), P(t-1), Q(t), Q(t-1)\} \quad (12)$$

که در روابط فوق:

Q : متوسط دبی روزانه

P : متوسط بارندگی روزانه

SWE : متوسط آب معادل برف روزانه

Cprecip : بارندگی تجمعی از اول نوامبر روزانه t : گام زمانی محاسباتی برحسب روز

MAZ- Cprecip : بارندگی تجمعی از اول نوامبر مخصوص حوضه مازندران روزانه


به عنوان مثال در الگوی سوم مقدار دبی فردا به پارامترهای بارندگی تجمعی حوضه مازندران در امروز و متوسط بارندگی روزانه امروز و روز گذشته و مقدار دبی در امروز و روز گذشته بستگی دارد.

1- Marcoart Lonberg


2- Takagi Sugono

پارامتر باران تجمعی مازندران در مدل سازی جریان سایر رودخانه های مازندران بررسی گردد آیا فرضی که در ساخت آن با توجه به شرایط حوضه های مازندران استفاده شده است علاوه بر رودخانه تجن در سایر رودخانه های این حوضه برقرار می باشد یا خیر؟


با توجه به کارایی پارامتر باران تجمعی در پیش بینی دبی پیشنهاد می‌شود که کارایی آن در دیگر حوضه‌های کشور مورد بررسی قرار گیرد و با تغییر در این پارامتر، پارامتر باران تجمعی منطبق با سایر حوضه‌های کشور به دست آورده شود. همچنین با استفاده کردن از




شکل ۴- هیدروگراف مقایسه‌ای و منحنی پراکندگی داده‌های مشاهده‌ای و پیش بینی شده برای الگوی اول در مرحله صحت سنجی با استفاده از شبکه عصبی




شکل ۵ - هیدروگراف مقایسه‌ای و منحنی پراکندگی داده‌های مشاهده‌ای و پیش بینی شده برای الگوی اول در مرحله صحت سنجی با استفاده از شبکه عصبی فازی




شکل ۶- هیدروگراف مقایسه‌ای و منحنی پراکندگی داده‌های مشاهده‌ای و پیش‌بینی شده برای الگوی دوم در مرحله صحت‌سنجی با استفاده از شبکه عصبی



شکل ۷- هیدروگراف مقایسه‌ای و منحنی پراکندگی داده‌های مشاهده‌ای و پیش‌بینی شده برای الگوی دوم در مرحله صحت‌سنجی با استفاده از شبکه عصبی فازی



شکل ۸- هیدروگراف مقایسه‌ای و منحنی پراکندگی داده‌های مشاهده‌ای و پیش‌بینی شده برای الگوی سوم در مرحله صحت‌سنجی با استفاده از شبکه عصبی



شکل ۹ - هیدروگراف مقایسه‌ای و منحنی پراکنندگی داده‌های مشاهده‌ای و پیش‌بینی شده برای الگوی سوم در مرحله صحت‌سنجی با استفاده از شبکه عصبی فازی

منابع

- ۱- کیا، م. ۱۳۸۷. شبکه‌های عصبی در MATLAB. انتشارات کیان رایانه سبز.
- ۲- بی‌نام. ۱۳۸۸. گزارش آماری رودخانه سفیدرود، امور مطالعات بررسی منابع آب، سازمان آب منطقه‌ای استان مازندران.
- 3- Adamowski, J. and K. Sun. 2010. Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds. *Journal of Hydrology*, 390: 85-91.
- 4- Birikundavyi, R., Labib, H. and J. Rousselle. 2002. Performance of neural networks in daily stream flow forecasting. *Journal of Hydrologic Engineering*, 25:32-398.
- 5- Culibaly, P. and F. Anctill. 2001. Multivariate reservoir inflow forecasting using temporal neural network with stopped training approach. *Journal of Hydrology Engineering*, 5: 115-123.
- 6- Culibaly, P. and F. Anctill. 2000. Daily reservoir inflow forecasting using artificial neural network with stopped training approach. *Journal of Hydrology*, 230: 244-257.
- 7- Dibike, Y. B. and D. P. Solomatine. 2001. River flow forecasting using artificial neural networks. *Phys. Chem. Earth., B(26)*: 1-7.
- 8- Kentel, E. 2009. Estimation of river flow by artificial neural networks and identification of input vectors susceptible to producing unreliable flow estimates. *Journal of Hydrology Engineering*, 14:1-8.
- 9- Lin, C. T. and G. Lee. 1996. *Neural fuzzy systems: A neural-fuzzy synergism to intelligent Systems*. Ed. prentice Hall.
- 10- Magaly, A. and P. Canuto. 2001. Combining neural networks and fuzzy logic for applications in character recognition. A Thesis Submitted to the University of Kent at Canterbury for the Degree of doctor of Philosophy In the subject of Electronic Engineering.
- 11- Rajurkar, M. P. U. C. Kothyari. 2004. Modeling of the daily rainfall-runoff relationship with artificial neural network. *Journal of Hydrology*, 285:96-113.
- 12- Renner, M. 2009. Verification of ensemble flow forecasts for the river Rhine. *Journal of Hydrology* . 376: 463-475.

- 13- Roger, J. 1993. ANFIS: Adaptive-network-based fuzzy inference system. Ieee Transaction, 23: 34-43.
- 14- Sajjad .A, Slobodan P. Simonovic . 2005. An artificial neural network model for generating hydrograph from hydro-meteorological parameters. Journal of Hydrology, 315: 36-251.
- 15- Salas, J. M. Markus. 2000. Streamflow forecasting based on artificial neural networks. Artificial Neural Networks in Hydrology. 79:23-51.
- 16- Toth, E. and A. Brath. 2007. Multistep ahead streamflow forecasting: Role of calibration data in conceptual and neural network modeling, Water Resources Research, 43: 27-35.
- 17- Vos, N. J. 2008. Multiobjective training of artificial neural networks for rainfall-runoff modeling. water Resources Research, 44: 80-91.
- 18- Zealand, C. and D. Burn. 1999. Short term streamflow forecasting using artificial neural networks. Journal of Hydrology, 214:32-48.