

روندیابی سیل رودها با بهره‌وری از شبیه‌های شبکه‌ی عصبی مصنوعی تکاملی

حسین فتحیان^{۱*}، محمد نیکو^۲، مهدی نیکو^۳

تاریخ دریافت: ۱۳۸۹/۰۲/۱۱ تاریخ پذیرش: ۱۳۸۹/۰۸/۱۸

چکیده

یکی از روش‌های پیش‌بینی سیل در رودخانه‌ها به منظور مدیریت و کنترل سیل در آن، روندیابی سیل می‌باشد. امروزه تکنیک جدید استفاده از مدل شبکه‌های عصبی مصنوعی تکاملی (EANN)^۴ که مبتنی بر هوش مصنوعی می‌باشد، کاربرد گسترده‌ای در زمینه‌های مختلف علمی به‌ویژه مهندسی آب پیدا کرده است. در این تحقیق به روندیابی سیل در رودخانه کارون، بازه اهواز- فارسیات، با استفاده از مدل‌های شبکه عصبی مصنوعی تکاملی پیش رونده^۵ (FF)، پرسپترون چندلایه^۶ (MLP) و توابع شعاعی^۷ (RBF) پرداخته شد. برای تعیین تعداد و تاخیر زمانی موثر داده‌های ورودی در مدل‌های شبکه عصبی مصنوعی از روش همبستگی عرضی خطی (Linear Cross Correlation) بین سری‌های زمانی ورودی‌ها و خروجی‌ها استفاده شد. با استفاده از الگوریتم ژنتیک ساختار مدل‌های شبکه عصبی مصنوعی از نظر تعداد گره‌ها در لایه پنهان شبکه‌های عصبی مصنوعی بهینه گردید. نتایج نشان می‌دهد که روش همبستگی عرضی به خوبی تعداد و تاخیر زمانی موثر داده‌های ورودی را تعیین می‌نماید. علاوه بر این مقایسه خروجی مدل‌ها با مقادیر واقعی نشان می‌دهد که مدل MLP انتخاب شده نسبت به مدل‌های MIKE11 و ماسکینگام از توانایی، انعطاف‌پذیری و دقت بیشتری در پیش‌بینی و روندیابی سیلاب در رودخانه کارون برخوردار می‌باشد.

واژه‌های کلیدی: روندیابی سیل، شبکه‌ی عصبی مصنوعی تکاملی، گروه زمانی، الگوریتم ژنتیک.

۱- استادیار گروه مهندسی آب، دانشکده کشاورزی و منابع طبیعی، دانشگاه آزاد اسلامی واحد اهواز، اهواز، ایران.

۲- کارشناسی ارشد مهندسی عمران-آب، دانشگاه آزاد اسلامی، واحد اهواز، باشگاه پژوهشگران جوان، اهواز، ایران. mn.we86@iauhvaz.ac.ir

۳- کارشناسی ارشد مهندسی عمران-سازه، دانشگاه آزاد اسلامی، واحد اهواز، باشگاه پژوهشگران جوان، اهواز، ایران. m.nikoo@iauhvaz.ac.ir

* نویسنده‌ی مسؤل: h_fathian@iauhvaz.ac.ir

4 -Evolutionary Artificial Neural Network

5 -Feed Forward

6 -Multi Layer Perceptron

7 -Radial Basic Function

مقدمه

یکی از مهم‌ترین ویژگی‌های مدیریت حوضه‌ی رود، مدیریت سیل‌ها است. شدت زیان‌های اقتصادی مرتبط با سیل‌ها، نقش مدیریت سیلاب را برجسته می‌نماید. یک سامانه‌ی هشداردهنده‌ی سیل مؤثر که براساس پیش‌بینی رویدادها عمل می‌کند، می‌تواند به‌طور اساسی این زیان‌ها را کاهش دهد. در حل مسائل سیل، شدت بارش و ویژگی‌های آب‌شناسی سطح حوضه، عوامل بسیار مناسبی می‌باشند، چه عواملی مانند بارش قبلی، نفوذپذیری خاک، شیب زمین و غیره، نقش مؤثری را در روان گشتن یا نگشتن مقدار معینی بارش را در زمانی مشخص ایفا می‌کنند (گوپاکومار، ۲۰۰۲).

تأثیرگذاری عوامل مختلف و وجود رابطه‌ی غیرخطی بین آنها، پیش‌بینی بدهی جریان را امری پیچیده می‌کند. بسیاری از روش‌هایی که امروزه در شبیه‌سازی گروه‌های زمانی و پیش‌بینی جریان مورد استفاده قرار می‌گیرند، رابطه‌ی خطی را بین متغیرها فرض می‌کنند. شبکه‌های عصبی مصنوعی در زمینه‌های فراوانی، از جمله منابع آب، به‌طور موفقیت‌آمیزی به کار گرفته شده‌اند. آزموده‌ها و مطالعات اخیر نشان داده‌اند که شبکه‌های عصبی مصنوعی می‌توانند جایگزین مطمئنی برای شبیه‌سازی فرآیند بارش - رواناب (جهانگیر و همکاران، ۱۳۸۴) پیش‌بینی جریان (یزدانی، ۱۳۸۴) و بدهی ورودی به مخزن (محمدی، ۱۳۸۵) باشند. کولیبالی و همکاران^۱ (۲۰۰۰) شبیه‌سازی مبتنی بر شبکه‌های عصبی پرسپترون چندلایه‌ای با الگوریتم پس انتشار خطا را نشان دادند. دولینگ^۲ و وارس^۳ (۲۰۰۲)، برای پیش‌بینی آبدهی آبدهی ماهانه‌ی رود از شبکه‌ی پرسپترون چندلایه‌ای استفاده کرده و به این نتیجه رسیدند که شبکه‌ی عصبی در برآورد آبدهی ماهانه، به‌خصوص در فصل‌های بهار و تابستان، به‌عنوان یک ابزار بسیار کارآمد قابل استفاده است. باودن^۴ و همکاران (۲۰۰۴) به معرفی دو روش برای تعیین ورودی در شبیه‌های شبکه‌ی عصبی مصنوعی پرداختند. روش نخست یک الگوریتم گام به گام بر مبنای

معیار اطلاعات متقابل جزئی (PMI) بوده و روش دوم شامل یک طرح خودسازماندهی (SOM) برای کاهش ابعاد فضای ورودی‌ها و یک شبیه دورگ الگوریتم ژنتیک، شبکه‌ی عصبی و وایازی معمولی برای تعیین ورودی‌های مؤثر می‌باشد. مندوزا^۵ و همکاران (۲۰۰۴)، برای پیش‌بینی پیش‌بینی روزانه‌ی جریان در رود زالاس^۶ در شمال غربی اسپانیا از شبیه آماری سنتی و شبکه‌های عصبی مصنوعی^۷ مصنوعی^۸ (ANNs) استفاده کرده و آنها را با هم مقایسه مقایسه نمودند. مقایسه‌ی نتایج نشان می‌دهد که عملکرد شبکه‌های عصبی مصنوعی بهتر از شبیه آماری می‌باشد. کیگیزوگلا^۹ و همکاران (۲۰۰۳) برای پیش‌بینی جریان روزانه‌ی رودها، شبکه‌ی عصبی پرسپترون چندلایه‌ای با الگوریتم آموزشی انتشار برگشتی پیش‌رونده و الگوریتم ژنتیک را به کار برد. نتایج شبیه‌سازی‌ها نشان داد که شبیه شبکه‌های عصبی مصنوعی تکاملی (EANN) در مقایسه با شبیه‌های آماری متداول پیش‌بینی‌ها را بهتر انجام می‌دهد. کولیبالی^{۱۰} و همکاران (۲۰۰۰)، برای پیش‌بینی جریان ورودی به آبگیر سدی واقع در حوضه‌ی چوت دو^{۱۱} برای یک تا هفت روز آینده در فصل بهار، عملکرد شبیه شبکه‌ی عصبی را با شبیه گروه زمانی^{۱۱} مقایسه کردند. هدف اصلی این تحقیق، بررسی توانایی شبکه‌های عصبی تکاملی در شبیه‌سازی الگوهای مناسب و پیش‌بینی جریان روزانه‌ی رود کارون است. بدین منظور و با استفاده از روش همبستگی عرضی خطی، تأخیر زمانی مؤثر دو فرانسج بده و مقیاس را در ایستگاه آبسنجی بالادست (اهواز) بر روی ایستگاه آبسنجی پایین دست (فارسیات) تعیین کرده و از نتایج حاصل به‌عنوان فرانسج‌های ورودی در شبکه‌های عصبی تکاملی استفاده می‌شود. سپس ساختار بهینه‌ی شبیه‌های شبکه عصبی مصنوعی پیش‌رونده^{۱۲}، پرسپترون چندلایه‌ای^{۱۳}، تابع پایه‌ای شعاعی^۱ با کاربرد روش الگوریتم ژنتیک تعیین می‌گردد.

5 - Mendeza

6 - Xallas River

7- Artificial Neural Networks

8- Cigizoglu

9 -Coulibaly

10 - Chute-Du-Diable

11- Time Series Model

12- Feed Forward

13 - Multilayer Perceptron

1 - Coulibaly

2 - Dolling

3- Varas

4 -Bowden

گروه‌های زمانی

تحلیل گروه‌های زمانی به‌طور نظری و عملی از سال ۱۹۷۰ به بعد برای پیش‌بینی و مهار کردن سیل به سرعت توسعه پیدا کرده است. این تحلیل معمولاً به داده‌هایی مربوط می‌شود که مستقل نبوده و به‌طور متوالی به هم وابسته‌اند. همین وابستگی بین مشاهدات متوالی است که مورد توجه قرار می‌گیرد که بیشتر کاربرد آن در پیش‌بینی است. توابع گروه‌های زمانی برای یک مجموعه از داده که به‌طور متوالی به‌دست آمده‌اند، به‌صورت زیر نمایش داده می‌شود (وندال^۲، ۱۹۸۳):

$$y_t = \alpha_0 + \alpha_1 T^1 + \alpha_2 T^2 + \dots + \alpha_n T^n \quad (1)$$

که در آن y_t متغیر وابسته حاصل از مشاهدات گروه‌های زمانی، $\alpha_0, \alpha_1, \alpha_2, \dots, \alpha_n$ ضرایب توابع خودهمبستگی، و T متغیر مستقل زمانی می‌باشد. ضرایب $\alpha_0, \alpha_1, \alpha_2, \dots, \alpha_n$ را از طریق تابع خود همبستگی ACF^۳ با استفاده از نرم‌افزارهای آماری مانند MINITAB می‌توان به دست آورد. برای آن که بتوان تأثیر یک گروه زمانی را بر روی گروه زمانی دیگر به‌دست آورد، باید از تابع همبستگی عرضی^۴ استفاده کرد که در این حالت بازه‌ی زمانی مؤثر به‌صورت زیر به‌دست می‌آید. (گیوین و همکاران^۵، ۲۰۰۴)

$$-(10 + \sqrt{n}) \leq K \leq +(10 + \sqrt{n}) \quad (2)$$

که در آن K ، تأخیر زمانی^۶ مؤثر در گروه زمانی پایین دست و n ، تعداد داده‌های مشاهده‌ای در گروه‌های زمانی می‌باشد.

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی یکی از پویاترین حوزه‌های تحقیقاتی در دوران معاصر می‌باشند که توجه افراد بسیاری را از رشته‌های گوناگون علمی را به خود جلب کرده‌اند. فعالیت‌های تحقیقاتی اخیر در زمینه شبکه‌های عصبی نشان داده‌اند که این روش توانایی بسیار بالایی را به دلیل تشابه در حل مسائل پیچیده در کلیه‌ی رشته‌های

مهندسی دارد. با مغز انسان، شبکه‌های عصبی توانایی لازم را در یادگیری داشته و قادر به به کار بردن و استفاده از آزموده‌های به‌دست آمده در مسائل نو و مشابه می‌باشند. شبکه‌های عصبی مصنوعی با وجود این که با سامانه عصبی طبیعی کاملاً قابل مقایسه نیستند، ویژگی‌هایی دارند که آنها را در بعضی از کاربردها، مانند تفکیک الگو و یا هرجا که نیاز به یادگیری با یک نگاهت خطی و یا غیرخطی باشد، ممتاز می‌نمایند. می‌توان از ویژگی‌ها و قابلیت‌های شبکه‌های عصبی مصنوعی به مواردی همچون قابلیت یادگیری و تطبیق‌پذیری با اطلاعات موجود، قابلیت تعمیم‌دهی، پردازش موازی ورودی‌های شبکه و در نتیجه، افزایش سرعت پردازش، تحمل‌پذیری بالای خطاها و ... اشاره کرد (منهاج، ۱۳۸۱).

از اواخر دهه‌ی ۹۰، شبکه‌های عصبی مصنوعی در مسائل آب‌شناسی و زمین و آب‌شناسی مثل شبیه‌سازی بارش و رواناب، پیش‌بینی جریان رودها، شبیه‌سازی آب‌های زیرزمینی، کیفیت آب، مدیریت آب، پیش‌بینی بارش و گروه‌های زمانی و غیره کاربردی گسترده یافته‌اند. از میان کاربردهای فوق که برای شبکه‌های عصبی مصنوعی ذکر شدند، روندیابی سیل در مطالعات آب‌های سطحی از اهمیت بالایی برخوردار است. شبکه‌های عصبی مصنوعی یک سامانه‌ی پردازشگر اطلاعات توده‌ای هستند که به‌صورت موازی قرار گرفته و عملکردی شبیه شبکه‌ی عصبی مغز انسان دارند. اصول زیر نشانگر اساس شبکه‌های عصبی مصنوعی می‌باشند:

۱. پردازش داده‌ها در واحدهای منفردی بنام گره صورت می‌گیرد. ۲. نشانه‌های بین گره‌ها از طریق خطوط ارتباطی انتقال می‌یابند. ۳. وزن نسبت داده شده به هر خط ارتباطی نشانگر قدرت ارتباطی آن است. ۴. هر گره به‌طور معمول دارای توابع فعال‌سازی^۷ و تبدیگر برای تعیین نشانه‌های خروجی از داده‌های ورودی شبکه می‌باشد. (منهاج، ۱۳۸۱)

ساختار شبکه‌های عصبی مصنوعی به‌وسیله‌ی الگوی ارتباط بین گره‌ها، روش تعیین وزن‌های ارتباطی و تابع فعالیت، معرفی می‌شود، ساختار عادی یک شبکه‌ی عصبی مصنوعی، معمولاً از لایه‌ی ورودی، لایه‌های میانی (پنهان)


7 - Activation Function

1 - Radial basic function
2- Vandaele
3 - Auto Correlation Function
4 - Cross Correlation Function
5- Gavin
6 -Lag

در ساختار شبکه‌های عصبی مصنوعی می‌توان از توابع تبدیلگر (تحریر) گوناگون اکسان اریب^۳، اکسان خطی^۴، اکسان تانژانت هذلولی خطی^۵، اکسان S شکل خطی^۶، اکسان تانژانت هذلولی^۷ و اکسان S شکل^۸ استفاده کرد. یکی از انواع مهم این توابع، تابع سیگموئید می‌باشد:

$$f(t) = \frac{1}{1 + \exp(-tn)} \quad (۴)$$

که در آن $f(t)$ تابع تبدیلگر، n ورودی خالص یاخنی عصبی و t تقریبی است که بیانگر طول قسمت خطی نمودار تابع تبدیلگر است. به طوری که اگر t بزرگ باشد قسمت خطی تابع به صورت عمودی درآمده و در واقع تابع به شکل یک تابع حدی دو مقداره در می‌آید و اگر t کوچک باشد، تابع به شکل یک S کشیده در امتداد محور افقی در خواهد آمد که در شکل (۲) نشان داده شده است.



شکل (۲): تابع تحریر سیگموئید

برای ارزیابی دقت شبیه شبکه عصبی مصنوعی معمولاً دو معیار میانگین مربع خطاها^۹ و Γ مورد استفاده قرار می‌گیرند که میانگین مربع خطاها به صورت زیر محاسبه می‌شود (منهاج، ۱۳۸۱):

$$MSE = \frac{\sum_{j=0}^P \sum_{i=0}^N (d_{ij} - y_{ij})^2}{N \times P} \quad (۵)$$


NMSE متوسط خطای مربعات بهنجار شده می‌باشد که به وسیله‌ی رابطه‌ی زیر بیان می‌شود (منهاج، ۱۳۸۱):

$$NMSE = \frac{P \times N \times MSE}{\sum_{j=0}^P \left(N \sum_{i=0}^N d_{ij}^2 - \left(\sum_{i=0}^N d_{ij} \right)^2 \right)} \quad (۶)$$

و لایه‌ی خروجی تشکیل شده است (شکل ۱). لایه‌ی ورودی یک لایه‌ی انتقال‌دهنده و وسیله‌ای برای تهیه کردن داده‌هاست. آخرین لایه یا لایه‌ی خروجی، شامل مقادیر پیش‌بینی شده به وسیله‌ی شبکه می‌باشد؛ بنابراین، خروجی شبیه را معرفی می‌کند. لایه‌های میانی یا مخفی، که از گره‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌ها می‌باشند. شمار لایه‌های مخفی و شمار گره‌ها در هر لایه مخفی به طور معمول به وسیله‌ی روش آزمون و خطا مشخص می‌شود. گره‌های لایه‌های مجاور در شبکه به طور کامل باهم در ارتباط‌اند. ممکن است ورودی‌های هر گره از متغیرهای ورودی یا از خروجی گره‌های دیگر حاصل شود. هر گره دارای یک تابع تبدیلگر^۱ است. ورودی‌ها به شکل یک بردار $X (X_1 \text{ و } X_2 \dots \text{ و } X_n)$ بوده و هر ورودی به وسیله‌ی یک وزن به گره پردازشگر مربوط می‌شود و در نهایت تسلسلی از وزن‌ها به شکل بردار وزن $W (W_1 \text{ و } W_2 \dots \text{ و } W_n)$ به گره مورد نظر مرتبط می‌گردد؛ وزن ارتباطی از گره لایه‌ی پیشین به لایه‌ی مزبور را نشان می‌دهد. خروجی گره که y نامیده می‌شود، طبق رابطه‌ی (۳) محاسبه می‌گردد:

$$y = \sum f(x.w - b) \quad (۳)$$

که در آن، x داده‌های ورودی، w بردار وزن، b مقدار آستانه یا اریب بودن^۲ می‌باشند. درون هر گره پردازشگر تابع تبدیلگر، تولیدکننده‌ی خروجی‌های آن گره به شمار می‌رود (بیل و جکسون).

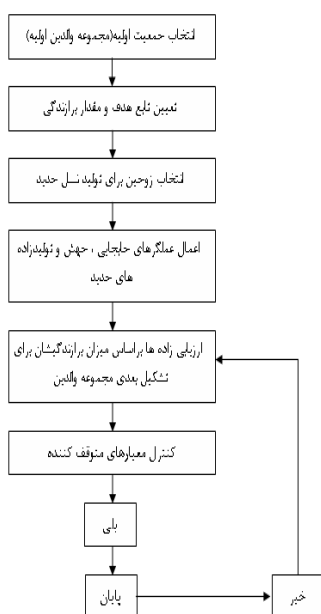


شکل (۱): یک نمونه از شبیه شبکه عصبی مصنوعی با سه لایه

- 3- Biasaxon
- 4- Linearaxon
- 5- Lineartanhaxon
- 6- Linearsigmohidaxon
- 7- Tanhaxon
- 8- Sigmohidaxon
- 9- Mean Square Error

- 1- Transfer function
- 2- Bias

از میان انواع مختلف پیوند، پیوند یکنواخت مورد استفاده قرار گرفته است، سپس نوبت به اعمال عملگر جهش می‌رسد، هدف از این کار ایجاد پراکندگی بیشتر در محدوده‌ی کاوش فضای طراحی است. در انجام فرایند جهش، با انتخاب نرخ ثابت جهش، برای کلیه ذره‌های کروموزوم‌های جمعیت عدد تصادفی تولید می‌گردد. اگر عدد تصادفی تولید شده از نرخ جهش کوچکتر باشد، مقدار آن ذره عوض یعنی مقدار صفر به یک و بالعکس تبدیل می‌شود. الگوریتم ژنتیک، هنگامی که برخی ضوابط مانند تعداد معینی تولید نسل و یا میانگین انحراف معیار عملکرد اشخاص جمعیت تامین شود، به پایان می‌رسد. در شکل (۳) فرایند کلی حل مسئله در الگوریتم ژنتیک به‌طور خلاصه نشان داده شده است (گیوین و همکاران، ۲۰۰۴):



شکل ۳. فرایند حل مسائل بهینه سازی با کاربرد الگوریتم ژنتیک.

منطقه‌ی مورد مطالعه

رود کارون به طول ۸۹۰ کیلومتر از چهار شاخه‌ی اصلی خراسان، آب ونک، آب کیار و بازفت تشکیل شده و از ارتفاعات مختلفی همچون کوه‌های شمالی اردکان فارس، جنوب و غرب بروجن سرچشمه می‌گیرد. منطقه‌ی مورد مطالعه رود کارون بازه‌ی اهواز تا فارسیات، به طول ۶۰ کیلومتر می‌باشد که در شکل (۴) نشان داده شده است. در این تحقیق داده‌های ۱۸ سال بده و مقیاس روزانه‌ی ایستگاه‌های آسنجی اهواز و فارسیات از تاریخ ۱۳۶۸/۱/۱

که در آن، P تعداد خروجی عناصر پردازش شده، N تعداد نمونه‌ها در مجموعه‌ی داده‌ها، y_{ij} خروجی شبکه برای نمونه i در عنصر پردازش شده‌ی j، d_{ij} خروجی مورد نظر برای نمونه‌ی i در عنصر پردازش شده‌ی j می‌باشد. میانگین مربع خطاها اختلاف بین مقادیر مشاهده شده و محاسبه شده را نشان می‌دهد. کمترین مقدار MSE بالاترین صحت پیشگویی را بیان می‌کند. همچنین r نشانگر میزان بازدهی شبکه می‌باشد که به صورت زیر ارائه می‌گردد:

$$r = \frac{\sum_i (x_i - \bar{x})(d_i - \bar{d})}{\sqrt{\frac{\sum_i (d_i - \bar{d})^2}{N}} \sqrt{\frac{\sum_i (x_i - \bar{x})^2}{N}}} \quad (7)$$

که x_i خروجی شبکه، d_i خروجی مورد نظر، \bar{x} میانگین خروجی شبکه و \bar{d} میانگین خروجی مورد نظر می‌باشد. بهترین جواب برای شبیه‌سازی ایجاد خواهد شد که r و MSE به ترتیب به سوی یک و صفر میل کنند (منهاج، ۱۳۸۱).


روش بهینه‌سازی الگوریتم ژنتیک

الگوریتم ژنتیک الهام گرفته از طبیعت بوده و تکامل طبیعت با فرضیه‌ی داروین، اساس شکل‌گیری آن می‌باشد، که در آن بهترین‌ها حق بقا را دارند. روش کار به این صورت است که در فرایند تکثیر، کروموزوم‌هایی با شایستگی بالا بخت تکرار بیشتری را در جمعیت منتخب پیدا می‌کنند که این کار به‌وسیله‌ی فرایند انتخاب صورت می‌پذیرد. بدین منظور روش‌های متنوعی مطرح شده است که "چرخ گردان" معروف‌ترین آنهاست. همچنین از انتخاب نخبه‌گرا نیز استفاده شده است که در هر نسل تعدادی از براننده‌ترین افراد بدون تغییر به نسل بعد منتقل می‌شوند. پس از تکمیل فرایند انتخاب، نوبت به اعمال عملگر منتخب به‌منظور تولید جمعیت فرزندان می‌رسد. در انجام فرایند پیوند، با انتخاب مقدار ثابت نرخ پیوند، به ترتیب برای هر کروموزوم یک عدد تصادفی تولید می‌گردد. اگر عدد تصادفی تولید شده از نرخ پیوند کمتر باشد، این کروموزوم انتخاب می‌شود تا به کروموزوم‌های بعدی که شرایط فوق را دارند، آمیزش کند. در این روش،


دارد. با استفاده از تابع همبستگی عرضی^۲ می توان تأخیر زمانی موثر را بین گروه‌های زمانی بده و مقیاس را در ایستگاه‌های اهواز و فارسیات به دست آورد. با توجه به این که هر فصل به طور متوسط ۹۰ روز است، بنابراین متغیر π در معادله‌ی (۲) برابر با ۹۰ بوده و خواهیم داشت:

$$-19 \leq K \leq +19 \quad (۸)$$

بنابراین در هر فصل در بازه‌ی ۱۹ روز، تا روزی را در نظر می‌گیریم که ضریب همبستگی در آن بیشتر از ۰/۵ باشد. نتایج حاصل از همبستگی عرضی بین داده‌های بده و مقیاس در جدول (۲) نشان داده شده‌اند. با ترسیم نمودار ستونی فراوانی داده‌های مربوط به تأخیر زمانی بده و مقیاس در طول دوره‌ی آماری در شکل‌های (۵) و (۶)، می‌توان دریافت که تأخیر زمانی برابر با دو روز بیشترین فراوانی را دارد، بنابراین، تأخیر زمانی موثر مربوط به مقادیر بده و مقیاس بین ایستگاه اهواز و فارسیات برابر با دو روز قبل در نظر گرفته می‌شود.



شکل (۵): نمودار ستونی فراوانی تأخیر زمانی فراسنج بده



شکل (۶): نمودار ستونی فراوانی تأخیر زمانی فراسنج مقیاس
بنابراین ورودی‌های شبکه عصبی تکاملی شامل فراسنج‌های بده و مقیاس از زمان t تا $t-2$ می‌باشند.

تا ۱۳۸۶/۱۲/۱ مورد استفاده قرار گرفته‌اند، که ۷۰٪ داده‌های ورودی برای آموزش، ۱۵٪ داده‌ها برای ارزیابی همزمان با آموزش شبکه و ۱۵٪ داده‌ها برای آزمون شبیه‌های شبکه عصبی مصنوعی تکاملی در نظر گرفته شده‌اند.



شکل (۴): نقشه‌ی GIS مربوط به رود کارون،

بازه‌ی اهواز-فارسیات

تعیین داده‌های ورودی بهینه با کاربرد روش همبستگی عرضی

از آن جا که رابطه‌ی همبستگی عرضی خطی بین گروه‌های زمانی بده و مقیاس در ایستگاه‌های آبسنجی اهواز و فارسیات در طول دوره‌ی آماری ۱۸ سال از دقت پایینی برخوردار است، بنابراین، داده‌ها به تفکیک فصل‌های سال دسته بندی می‌شوند. بدین ترتیب، ۷۲ بازه‌ی زمانی فصلی در طول دوره‌ی آماری خواهیم داشت. برای آن که بتوان یک رابطه‌ی خطی بین دو گروه زمانی بده و مقیاس ایستگاه آبسنجی اهواز و فارسیات تعیین کرد، از ضریب پیرسن^۱ استفاده می‌شود، هر اندازه این ضریب به عدد یک نزدیکتر باشد، همبستگی خطی بین دو گروه زمانی بیشتر است. با استفاده از نرم افزار SPSS، ضریب پیرسن برای دو فراسنج بده و مقیاس در بازه‌ی اهواز - فارسیات تعیین شد که در جدول (۱) آمده است. با توجه به جدول (۱) می‌توان نتیجه گرفت که در همه‌ی فصل، یک همبستگی خطی بین گروه‌های زمانی بده و مقیاس در ایستگاه‌های آبسنجی اهواز و فارسیات وجود

جدول (۳): ساختار بهینه‌ی شبیه‌های FF و MLP و RBF

ردیف	نام شبیه	تعداد گره‌های لایه پنهان اول	تعداد گره‌های لایه پنهان دوم	تابع انتقال	الگوریتم یادگیری شبکه
1	FF	8	5	LinearAxon	Step
2	MLP	8	-	TanhAxon	Momentum
3	RBF	13	-	TanhAxon	Momentum

همچنین، جداول (۴) تا (۶) نتایج حاصل از آموزش، ارزیابی همزمان با آموزش و آزمون هر یک از شبیه‌های با ساختار بهینه را که در جدول (۳) آمده‌اند نشان می‌دهد. به منظور تشخیص عملکرد شبیه‌ها و تعیین بهترین شبیه، معیار NMSE یا r حاصل از آزمون شبیه‌ها با یکدیگر مقایسه می‌شوند. همان‌طور که در جداول (۴) تا (۶) ملاحظه می‌شود، شبیه MLP دارای بیشترین همبستگی برای داده‌های بده و مقیاس در مرحله‌ی آزمون نسبت به دو شبیه دیگر می‌باشد. علاوه بر آن، مقادیر بده و مقیاس محاسباتی نسبت به مقادیر متناظر اندازه‌گیری شده در مرحله‌ی آزمون به ازاء شبیه‌های مختلف در شکل‌های (۷) و (۸) نشان داده شده‌اند.

جدول (۴): نتایج حاصل از آموزش شبیه‌های بهینه‌ی EANN

ردیف	شبیه	آموزش			
		مقیاس		بده	
		NMSE	R	NMSE	r
1	FF	0.183	0.872	0.241	0.907
2	RBF	0.389	0.851	0.274	0.778
3	MLP	0.162	0.898	0.192	0.916

جدول (۵): نتایج حاصل از ارزیابی شبیه‌های بهینه‌ی EANN

ردیف	شبیه	اعتباریابی همزمان با آموزش			
		مقیاس		بده	
		NMSE	R	NMSE	r
1	FF	0.189	0.904	0.182	0.902
2	RBF	0.580	0.823	0.324	0.651
3	MLP	0.186	0.902	0.128	0.938

جدول (۶): نتایج حاصل از آزمون شبیه‌های بهینه‌ی EANN

ردیف	شبیه	آزمون			
		مقیاس		بده	
		NMSE	r	NMSE	r
1	FF	0.173	0.926	0.145	0.918
2	RBF	0.377	0.873	0.239	0.791
3	MLP	0.093	0.952	0.119	0.940

تعیین ساختار بهینه‌ی شبیه‌های شبکه‌های عصبی مصنوعی

در شبکه‌ی عصبی مصنوعی ورودی‌ها، شش فراسنج $Q(t)$ ، فراسنج $Q(t-1)$ ، $Q(t-2)$ ، $H(t)$ ، $H(t-1)$ ، $H(t-2)$ و خروجی‌ها دو فراسنج $Q(t)$ ، $Q(t-1)$ می‌باشند که در شکل (۱) نشان داده شده‌اند. در این تحقیق از سه شبیه شبکه‌ی FF و RBF و MLP برای آموزش استفاده شده است. همچنین، برای بهینه کردن ساختار و تحلیل موضعی^۱ هر شبکه از الگوریتم ژنتیک استفاده گردید. از ۵۲۸۰ الگوی داده‌ها، ۷۰٪ (۳۶۹۴ الگو) برای آموزش^۲ و ۱۵٪ (۷۹۳ الگو) برای ارزیابی^۳ و ۱۵٪ انتخابی (۷۹۳ الگو) برای آزمون^۴ شبکه مورد استفاده قرار گرفتند. توابع تحریک مختلف شامل اکسان تانژانت هذلولی، اکسان S شکل و اکسان خطی و الگوریتم‌های آموزش مختلف شامل Momentum، Quickprop و Delta Bar Delta جهت تعیین ساختار بهینه‌ی شبیه‌های شبکه عصبی مصنوعی تکاملی در نظر گرفته شدند. برای تعیین تعداد گره‌های لایه پنهان از رابطه‌ی تجربی زیر استفاده شد (گیوین و همکاران، ۲۰۰۴):

$$N_H \leq 2N_I + 1 \quad (9)$$

که در آن N_H تعداد گره‌های لایه‌های پنهان و N_I تعداد ورودی‌ها می‌باشد. با توجه به این که تعداد ورودی‌های موثر به دست آمده برابر با ۶ است، حداکثر تعداد گره‌های لایه‌ی پنهان برابر با ۱۳ عدد می‌باشد ($N_H \leq 13$). برای تعیین ساختار بهینه‌ی هر یک از شبیه‌های شبکه‌ی عصبی مصنوعی تکاملی FF و MLP و RBF، از نظر تعداد لایه‌های پنهان، تعداد گره‌ها در لایه‌های پنهان، الگوریتم یادگیری شبکه و تابع انتقال، قابلیت الگوریتم بهینه‌سازی ژنتیک از نرم افزار NeuroSolutions استفاده شد. جدول (۳) ساختار بهینه‌ی هر یک از شبیه‌ها و مشخصات مختلف آنها را که الگوریتم ژنتیک به دست آمده نشان می‌دهد. یادآوری می‌گردد که در تمام شبیه‌ها مقدار ورودی‌ها و خروجی‌ها به ترتیب برابر با ۶ و ۲ می‌باشد.

- 1- Topology
- 2 - Training
- 3- Cross Validation
- 4- Test

تحلیل حساسیت خروجیهای شبیه بهینه ی MLP


نسبت به فراسنجهای ورودی

برای آن که میزان تاثیر فراسنجهای ورودی بر فراسنج خروجی مشخص شود، از روش تحلیل حساسیت استفاده می کنند. این روش برای مشخص کردن آن است که فراسنج خروجی در شبکه ی موردنظر نسبت به کدام یک از فراسنجهای ورودی دارای حساسیت بیشتری می باشد. نتایج حاصل از تحلیل حساسیت خروجی شبیه MLP نسبت به فراسنجهای ورودی در جدول (۷) و نمودار ستونی آن در شکل های ۹ و ۱۰ آمده اند.

جدول (۷): تحلیل حساسیت خروجی شبیه MLP نسبت به


فراسنجهای ورودی

حساسیت	درصد بده ی خروجی	درصد مقیاس خروجی
H(t)	40.1	69.3
H(t-1)	28.9	17.8
H(t-2)	14.1	7.2
Q(t)	12.1	4.3
Q(t-1)	3.4	0.8
Q(t-2)	1.4	0.5



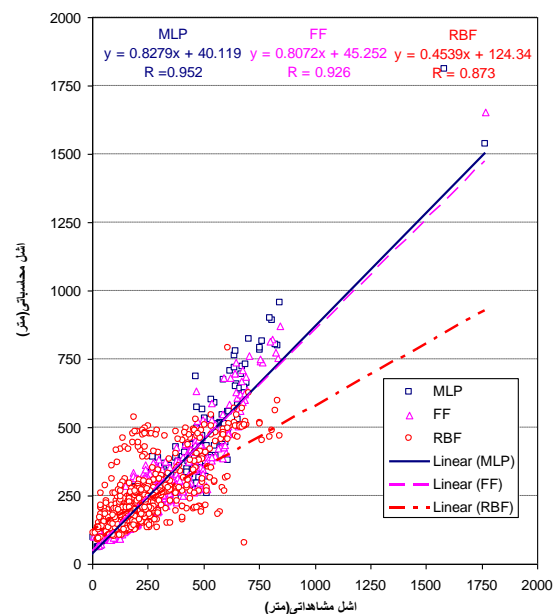
شکل (۹): تحلیل حساسیت بده ی خروجی در شبیه MLP

نسبت به فراسنجهای ورودی.



شکل (۷): مقایسه ی مقادیر بده ی مشاهده ای و محاسباتی با

کاربرد شبیه های EANN در مرحله ی آزمون


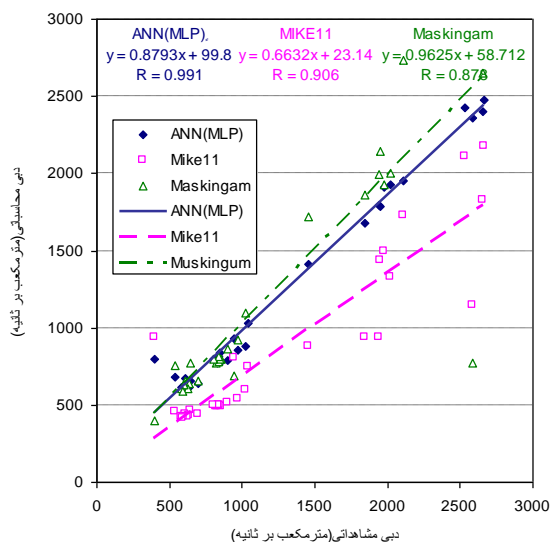


شکل (۸): مقایسه ی مقادیر مقیاس مشاهده ای و محاسباتی با

کاربرد شبیه های EANN در مرحله ی آزمون

همان طور که در شکل های (۷) و (۸) مشاهده می شود، شبیه MLP همبستگی بالاتری را نسبت به دو شبیه دیگر دارد. همچنین، شبیه FF همبستگی بالاتری را نسبت به شبیه RBF دارد. بنابراین، شبیه MLP با ساختار آرایش (۲-۸-۶) بهترین شبیه شبکه ی عصبی مصنوعی تکاملی می باشد. مشخصات و پستی و بلندی شبیه پایدار MLP در جداول ۴ تا ۶ نشان داده شده اند.

شبکه‌ی عصبی مصنوعی تکاملی MLP، شبیه Muskingum و شبیه MIKE11 به ترتیب آبنمای سیل را در انتهای بازه‌ی رود در ایستگاه آبسنجی فارسیات با دقت بیشتری روندیابی کرده‌اند. همچنین با مقایسه‌ی مقادیر ضریب تعیین مربوط به معادلات خطوط برازش شده بر مقادیر مقیاس محاسباتی و مشاهده‌ای در شکل (۱۲) می‌توان دریافت که شبیه MLP از دقت بیشتری نسبت به شبیه MIKE11 در روندیابی آبنمای مقیاس دارا می‌باشد.



شکل (۱۰): تحلیل حساسیت مقیاس خروجی در شبیه MLP نسبت به فراسنج‌های ورودی.

با توجه به شکل (۹)، فراسنج‌های ورودی $H(t)$ ، $Q(t)$ ، $H(t-1)$ به ترتیب دارای بیشترین تاثیر بر بدهی خروجی می‌باشند. همچنین در شکل (۱۰) فراسنج‌های ورودی $H(t)$ ، $H(t-1)$ ، $H(t-2)$ به ترتیب دارای بیشترین تاثیر بر مقدار خروجی مقیاس می‌باشند.


مقایسه‌ی شبیه MLP با شبیه MIKE11 و ماسکینگام در روندیابی سیل

برای ارزیابی عملکرد شبیه بهینه‌ی MLP در روندیابی متمرکز آبنمای بده و مقیاس در رود، نتایج حاصل از آن با نتایج حاصل از شبیه هیدرولیکی MIKE11 و مدل آبنمای ماسکینگام مقایسه شدند. بدین منظور از آبنمای سیل ۸۱ (۱۳۸۱/۱/۱ تا ۱۳۸۱/۱/۲۸) در روندیابی با کاربرد سه شبیه استفاده شده است. شکل‌های (۱۱) و (۱۲) مقایسه‌ی مقادیر بده و مقیاس تعیین گردیده و روندیابی شده با کاربرد سه شبیه را نشان می‌دهد. همچنین هیدروگراف بده و مقیاس ورودی به بازه‌ی رود موردنظر در ایستگاه آبسنجی اهواز، آبنمای بده و مقیاس اندازه‌گیری شده در پایین بازه‌ی رود در محل ایستگاه آبسنجی فارسیات، آبنماهای روندیابی شده با کاربرد شبیه‌های MLP، ماسکینگام و MIKE11 در شکل‌های ۱۳ و ۱۴ نشان داده شده‌اند.

با توجه به معادلات خطوط برازش داده شده بر مقادیر بده‌ی محاسباتی و مشاهده‌ای در هر شبیه در شکل ۱۱ و ضریب تعیین مربوط به آنها می‌توان دریافت که شبیه

شکل (۱۱): مقایسه‌ی مقادیر بده‌ی مشاهده‌ای و محاسباتی حاصل از روندیابی آبنمای سیل با شبیه‌های مختلف به ازاء

سیل فروردین ۱۳۸۱



شکل (۱۲): مقایسه‌ی مقادیر مقیاس مشاهده‌ای و محاسباتی حاصل از روندیابی آبنمای مقیاس با کاربرد شبیه‌های مختلف مربوط به سیل فروردین ۱۳۸۱

ایستگاه آبسنجی بالادست (ایستگاه اهواز) بازه‌ی مورد مطالعه و ایستگاه آبسنجی پایین دست (ایستگاه فارسیات)، مقادیر حداکثر تا دو روز قبل بده و مقیاس ایستگاه اهواز بر مقادیر بده و مقیاس ایستگاه فارسیات تأثیری قابل ملاحظه داشت.

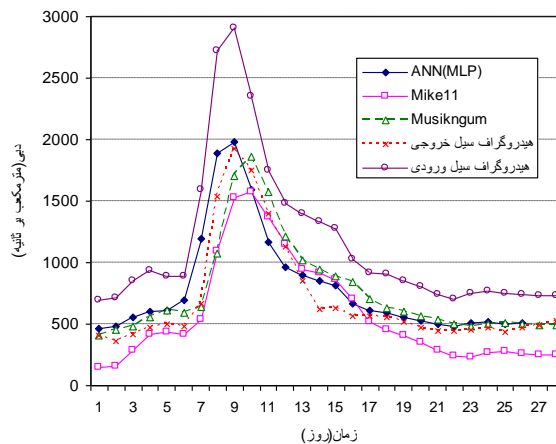
علاوه بر این، با قابلیت بهینه سازی الگوریتم پر کاربرد ژنتیک می‌توان ساختار بهینه‌ی هر یک از شبیه‌های شبکه‌ی عصبی مصنوعی را از نظر تعداد لایه‌های پنهان، تعداد گره‌ها در لایه‌ی پنهان، نوع تابع تحریک و الگوریتم یادگیری شبکه مشخص کرد، به طوری که با کاربرد این روش زمان لازم برای تعیین ساختار بهینه‌ی هر شبیه به میزان قابل ملاحظه‌ای کاهش می‌یابد.

مقایسه‌ی نتایج حاصل از آموزش، ارزیابی همزمان با آموزش و آزمون شبیه‌های شبکه‌های عصبی مصنوعی تکاملی با مقادیر آزمون اندازه‌گیری شده نشان می‌دهد که شبیه‌های MLP، FF و RBF به ترتیب توانایی و دقت بیشتری را در روندیابی آبنمای بده و مقیاس در رود دارند، به طوری که ضریب همبستگی بین مقادیر بده‌ی مشاهده‌ای و روندیابی شده با MLP، FF و RBF در مرحله‌ی آزمون به ترتیب برابر با ۰.۹۴۰، ۰.۹۱۸ و ۰.۷۹۱ به دست آمد. همچنین، مقادیر ضریب همبستگی بین مقیاس مشاهده‌ای و روندیابی شده با شبیه‌های MLP، FF و RBF در مرحله‌ی آزمون به ترتیب برابر با ۰.۹۵۲، ۰.۹۲۶ و ۰.۸۷۳ حاصل شد.

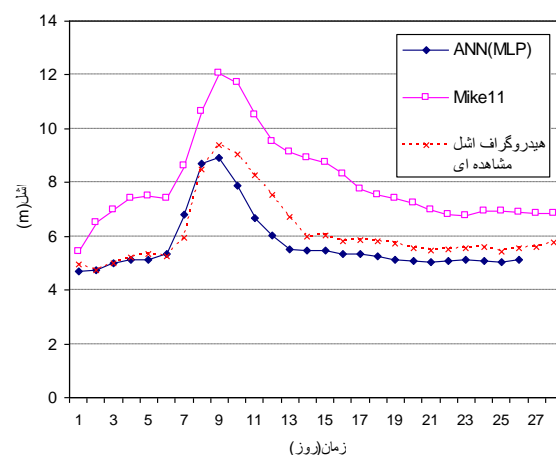
مقایسه‌ی نتایج حاصل از شبیه‌ها نشان می‌دهد که شبیه شبکه‌ی عصبی مصنوعی تکاملی (MLP) از دقت بالاتری نسبت به شبیه‌های MIKE11 و ماسکینگام در روندیابی آبنمای سیل و مقیاس در رود برخوردار است.

منابع

- ۱- اصغری مقدم، ا.، نورانی، و.، ندیری، ع.، "مدل سازی بارش دشت تبریز با استفاده از شبکه‌های عصبی مصنوعی" نشریه دانش کشاورزی.
- ۲- آر. بیل و تی. جکسون، ۱۳۸۶، "آشنایی با شبکه‌های عصبی"، دکتر محمود البرزی، انتشارات علمی دانشگاه صنعتی شریف.
- ۳- جهانگیر، ع.، رائینی، م.، احمدی، م.، ض. و اکبری، و. "شبیه‌سازی فرآیند بارش - رواناب با شبکه عصبی



شکل (۱۳): مقایسه‌ی آبنمای سیل ورودی و خروجی و روندیابی شده در ایستگاه فارسیات با شبیه‌های مختلف مربوط به سیل فروردین ۱۳۸۱



شکل (۱۴): مقایسه‌ی آبنمای مقیاس اندازه‌گیری شده و روندیابی شده در ایستگاه فارسیات با کاربرد شبیه‌های مختلف مربوط به سیل فروردین ۱۳۸۱

با توجه به شکل‌های (۱۱) تا (۱۴) می‌توان نتیجه گرفت که شبکه‌های عصبی - مصنوعی تکاملی از انعطاف‌پذیری و دقت بالاتری نسبت به شبیه‌های MIKE11 و ماسکینگام دارد.

نتیجه‌گیری

همان‌طور که در این تحقیق مشخص گردید، با کاربرد روش همبستگی عرضی گروه‌های زمانی می‌توان تعداد و تاخیر زمانی موثر فراسنج‌های ورودی در شبیه‌های شبکه‌ی عصبی را تعیین کرد؛ به طوری که با کاربرد این روش فراسنج‌های اضافی و غیر موثر حذف و مجموعه‌ی داده‌های ورودی بهینه می‌گردد. در این تحقیق با کاربرد روش همبستگی عرضی گروه‌های زمانی بده و مقیاس بین

- 13- Gavin, J., Graeme C., Holger, R., 2004 " Input determination for neural network models in water resources applications. Part 2. Case study: forecasting salinity in a river", Journal Of Hydrology Elsevier.
- 14- Gopakumar, 2002 , "Decision Support for Water Management in the Vembanad Wetland System" , Journal Centre for Water Resources Development and Management, Surface Water Division.
- 15- Lauzon, N., Rousselle, J., Birikundavyi, S., Trung, H.T., 2000, "Real-time daily flow forecasting using black-box models, diffusion processes, and neural networks", J. Civil Engineering, 27, pp.671-682.
- 16- Makridakis, S.C, Wheelwright , and Hyndman, R., 1998" Forecasting: Methods and Applications". Wiley
- 17- Mendeza, M.C., Manteigaa, W.G., Banda, M.F., Sancheza, J.M.P. and Calderon, R.L., 2004, " Modelling of the monthly and daily behaviour of the runoff of the Xallas river using Box-Jenkins and neural networks methods ", Journal of Hydrology, 296 PP. 38-58.
- 18- Salas, J.D., Markus, M., and Tokar, A.S., 2000, " Streamflow Forecasting Based Artificial Neural Networks", Artificial Neural Networks In Hydrology, pp.23-51.
- 19- Vandaele, W., 1983,"Applied Time Series and Box-Jenkins Models". Academic Press, Inc.
- مصنوعی (ANN) و مقایسه با مدل HEC-HMS در حوزه معرف کارده"، پژوهشنامه علوم کشاورزی و منابع طبیعی خزر، سال سوم / شماره دوم / تابستان ۱۳. ۴- طارقیان، ر.، کاشفی پور، م.، طاهری، م.، ۱۳۸۵، "پیش‌بینی جریان رودخانه‌ها با استفاده از شبکه‌های عصبی مصنوعی" اولین همایش منطقه‌ای بهره‌برداری بهینه از منابع آب حوضه‌ها، شهرکرد، دانشگاه شهرکرد.
- ۵- منهای، م. ب.، ۱۳۸۱، "مبانی شبکه‌های عصبی"، مرکز نشر پروفیسور حسابی.
- ۶- یزدانی، م. ر.، چاوشی، س.، "پیش‌بینی جریان رودخانه با استفاده از مدل شبکه عصبی مصنوعی" پنجمین کنفرانس هیدرولیک ایران، ۱۳۸۴.
- 7- Anmala, J., Zhang, B., Govindaraju, R.S., 2000, "Comparison of ANNs and Empirical Approaches for Predicting Watershed Runoff", Journal of Water Resources Planning and Management, Vol. 126, No. 3, pp. 156-166.
- 8- Bowden, G., Maier, H., Dandy, G., " Input determination for neural network models in water resources applications. Part 2. Case study: forecasting salinity in a river" Journal of Hydrology, 2004 , Volume: 301, Issue: 1-4, Pages: 93-107
- 9- CIĞIZOĞLU, 2003, "ARTIFICIAL NEURAL NETWORK MODELS IN RAINFALL-RUNOFF MODELLING OF TURKISH RIVERS" , RIVER BASIN FLOOD MANAGEMENT, page 561-571
- 10- Coulibaly, P., Anctil, F., Bobee, B., 2000, "Daily reservoir inflow forecasting using artificial neural networks with stopped training approach", Journal of Hydrology, Vol. 230, pp.244-257.
- 11- Dolling, O.R., Varas, E.A., 2002, "Artificial neural networks for streamflow prediction", Journal of Hydraulic Research, Vol. 40, No. 5.
- 12- Gavin, J., Graeme C., Holger, R., 2004 " Input determination for neural network models in water resources applications. Part 1-background and methodology" ,Journal Of Hydrology Elsevier.

