

## شبیه‌سازی و پیش‌بینی آبدی با استفاده از الگوریتم ترکیبی ANN-GA

محبوبه زارع‌زاده مهریزی<sup>۱\*</sup> - امید بزرگ حداد<sup>۲</sup>

تاریخ دریافت: ۸۸/۱۱/۱۹

تاریخ پذیرش: ۸۹/۳/۳۰

### چکیده

به منظور تعیین آبدی رودخانه‌ها در آینده و برنامه‌ریزی جهت مصرف آب، از مدل‌هایی جهت پیش‌بینی این مقادیر استفاده می‌گردد. همچنین جهت تصحیح، تدقیق، تطویل، تکمیل و یا بازسازی داده‌ها، مدل‌های شبیه‌سازی مورد استفاده قرار می‌گیرند. از جمله مدل‌های تجربی مورد استفاده در این زمینه می‌توان به شبکه عصبی مصنوعی<sup>۱</sup> (ANN) اشاره نمود. در این تحقیق مؤثر بودن یا نبودن هر یک از عوامل دما، بارش، آبدی و تأخیرهای زمانی این پارامترها در شبیه‌سازی و پیش‌بینی آبدی رودخانه مورد بررسی قرار گرفته است. به منظور دستیابی آسانتر به این پارامترها و نیز تعیین ترکیب بهینه پارامترهای مؤثر در واسنجی ضرایب ANN از الگوریتم ژنتیک<sup>۲</sup> (GA) به عنوان یک ابزار بهینه‌سازی استفاده گردیده است. با انجام فرآیند فوق در دو مدل شبیه‌سازی و پیش‌بینی جریان، تعداد لایه‌های مخفی، تعداد نرون‌های مؤثر در هر یک از لایه‌ها، عوامل هواشناسی و هیدرولوژیکی مؤثر و نیز گام‌های زمانی مناسب هر یک از این عوامل در شبیه‌سازی و پیش‌بینی آبدی با استفاده از GA به نحوی تعیین می‌گردد که بهترین حالت در مقادیر شبیه‌سازی و پیش‌بینی شده آبدی حاصل شود. در این تحقیق که در حوضه آبریز رودخانه دز صورت گرفته است، تابع هدف کاهش مقدار میانگین مربعات خطای کل در نظر گرفته شد. مقادیر ضریب همبستگی بین آبدی‌های محاسباتی و موجود برای دو مدل شبیه‌سازی و پیش‌بینی به ترتیب برابر با ۰/۸۶ و ۰/۷۹ به دست آمد که بیانگر کارایی الگوریتم ANN-GA در شبیه‌سازی و پیش‌بینی آبدی با دقت مطلوب می‌باشد. همچنین نتایج نشان دهنده برتری جواب‌های به دست آمده از مدل شبیه‌سازی نسبت به مدل پیش‌بینی می‌باشند. از دلایل این برتری می‌توان به وجود عوامل هواشناسی ماه مورد نظر در تعیین میزان آبدی اشاره نمود.

**واژه‌های کلیدی:** شبکه عصبی مصنوعی، شبیه‌سازی، پیش‌بینی، آبدی، بهینه‌یابی، الگوریتم ژنتیک

### مقدمه

اصلاح و یا تکمیل داده‌ها استفاده نمود.

مطابق تقسیم بندی گویندراجو (۷) مدل‌هایی که امروزه در هیدرولوژی مورد استفاده قرار می‌گیرند، شامل مدل‌های ریاضی-فیزیکی، مدل‌های ژئومورفولوژیکی و مدل‌های تجربی می‌باشند. دسته اول مدل‌ها، براساس خصوصیات فیزیکی سیستم هستند که به صورت معادلات دیفرانسیل بیان می‌شوند. اما دسته دوم بر مبنای خصوصیات ژئومورفولوژیکی سیستم هیدرولوژیکی مورد نظر بیان می‌شوند. این نوع از مدل‌ها توانایی زیادی در شبیه‌سازی رفتار حوضه آبریز و شبکه‌های آبیاری و زهکشی دارند. مدل‌های تجربی بدون توجه به پارامترها، سعی در ایجاد رابطه‌ای بین داده‌های ورودی و خروجی دارند که این مدل‌ها به مدل‌های جمعه سیاه یا میانگینی معروف هستند. مدل ANN به عنوان یک مدل تجربی توانایی زیادی در مدل‌سازی پدیده‌های غیر خطی دارد. جین و همکاران (۱۱) شبکه عصبی مصنوعی و مدل سری زمانی ARMA<sup>۵</sup> را جهت پیش‌بینی

نیاز روزافزون به آب سبب گردیده است، برنامه‌ریزی‌های مدیریتی به منظور کنترل مصرف آب در آینده از اهمیت بیشتری برخوردار گردد. آبدی رودخانه‌ها در ماه‌های آینده که پدیده‌ای تصادفی و تأثیرپذیر از برخی عوامل هواشناسی و هیدرولوژیکی نظیر دما، بارش و آبدی می‌باشد، نقش مهمی را در مدیریت منابع آب ایفا می‌نماید. با پیش‌بینی نمودن آبدی رودخانه‌ها علاوه بر مدیریت بهره‌برداری منابع آب به منظور تأمین نیاز، می‌توان حوادث طبیعی نظیر سیل و خشکسالی را نیز پیش‌بینی و مهار نمود. همچنین می‌توان از نتایج اجرای یک مدل شبیه‌سازی به منظور بررسی صحت داده‌ها و یا

۱- دانشجوی کارشناسی ارشد مهندسی منابع آب، دانشگاه تربیت مدرس، تهران

\*- نویسنده مسئول: (Email: m.zarezade@modares.ac.ir)

۲- استادیار، گروه مهندسی آبیاری و آبادانی، دانشگاه تهران

3- Artificial Neural Network

4- Genetic Algorithm

5- Auto Regressive Moving Average

گسترش یافته و امروزه بواسطه توانائی‌های خویش، جایگاه مناسبی در میان دیگر روش‌ها دارد. پس از آن یو مینگ چن (۳) از GA در مدیریت منابع آب استفاده کرد. او جزء اولین کسانی بود که این علم را در زمینه مدیریت منابع آب بکار برد. او برخی از اصول و قراردادهای موجود در GA مانند ترکیب چند نقطه‌ای و جهش چند نقطه‌ای را بهبود بخشید.

روش ANN-GA یک روش مدل‌سازی- بهینه‌سازی قدرتمند برای فرآیندهای پیچیده می‌باشد و ممکن است بهتر از سایر روش‌ها مانند روش سطح پاسخ<sup>۱۰</sup> عمل کند [۱۰]. ترکیب ANN و GA می‌تواند برای فرآیند مدل‌سازی- بهینه‌سازی مورد استفاده قرار گیرد [۱ و ۱۷]. برای بهینه کردن نتایج آموزش داده‌ها در یک مدل شبیه‌سازی آینده‌ی هیدرولیکی با ANN در بامبروگی<sup>۱۱</sup> هلند توسط کمپ و ساوانیجه (۱۳) مورد استفاده قرار گرفته است. بعد از بهینه‌سازی آموزش داده‌ها با GA، شبکه عصبی مصنوعی نتایج دقیق‌تری را تولید کرد.

استفاده بهتر از ANN، مستلزم بهینه کردن پارامترهای مورد استفاده در آن می‌باشد. برای تعیین بهترین مقادیر پارامترهای مختلف ANN نظیر تعداد لایه‌ها و نرون‌ها در هر شبکه، زمان زیادی صرف واسنجی این پارامترها به روش آزمون و خطا می‌شود. به همین منظور، در این تحقیق با ترکیب ANN و GA به عنوان یک روش بهینه‌سازی، دستیابی به مقادیر مطلوب پارامترهای ANN به آسانی میسر می‌گردد. همچنین به منظور بررسی مؤثر بودن یا نبودن هر یک از عوامل دما، بارش، آینده‌ی و تأخیرهای زمانی هر یک از این عوامل بر روی میزان آینده‌ی رودخانه در یک ماه مشخص نیز از GA به طور همزمان در مدل ANN استفاده شده است. اهداف این تحقیق شامل بررسی و ارزیابی عملکرد ANN در زمینه شبیه‌سازی و پیش‌بینی آینده‌ی رودخانه‌ها، ارزیابی پارامترهای هیدرولوژیکی و هواشناسی مؤثر جهت شبیه‌سازی و پیش‌بینی جریان رودخانه (دما، بارش و آینده‌ی)، حذف روش آزمون و خطا برای محاسبه مقادیر بهینه پارامترهای ANN و نیز دستیابی آسانتر به مقادیر بهینه پارامترهای ANN می‌باشد. با پیش‌بینی آینده‌ی رودخانه‌ها علاوه بر مدیریت صحیح و دقیق طراحی، اجراء، توسعه و بهره‌برداری منابع آب به منظور تأمین نیاز، می‌توان حوادث طبیعی نظیر سیل و خشکسالی را نیز پیش‌بینی و مهار نمود. همچنین از نتایج اجرای یک مدل شبیه‌سازی در این تحقیق می‌توان به منظور بررسی صحت داده‌ها و یا اصلاح و یا تکمیل داده‌های مفقود و یا مشکوک استفاده نمود.

آبدهی ورودی به مخزن اوریسا<sup>۱</sup> در هند بکار بردند. هال و همکاران (۸) از شبکه‌های عصبی مصنوعی سه لایه‌ای جهت پیش‌بینی بارندگی روزانه سود جستند. لوک و همکارانش با استفاده از شبکه‌های پرسپترون چند لایه<sup>۲</sup> (MLP) و شبکه مبتنی بر پایه تابع شعاعی<sup>۳</sup> (RBF) به بررسی تأثیر تأخیر گام‌های زمانی در میزان بارندگی پرداختند. از نتایج این بررسی می‌توان به این نکته اشاره نمود که تأخیرهای زمانی زیاد و نیز تعداد نرون‌های زیاد، سبب ایجاد بیش آموزش<sup>۴</sup> در شبکه عصبی می‌شود [۱۵ و ۱۶]. کیسی (۱۴) ANN و مدل خود همبستگی اتوماتیک (AR)<sup>۵</sup> را برای پیش‌بینی آبدهی ماهانه رودخانه گوسودر<sup>۶</sup> واقع در ایالت ایساکوی ژاپن بکار برد. یک ترکیب از مدل بارندگی- رواناب که ANN را با مدل‌های مفهومی کامل می‌کند، توسط چن و ادمز (۴) پیشنهاد شده است. با استفاده از این روش در هر زیرحوضه، رواناب می‌تواند با توجه به پارامترهای توزیع مدل و داده‌های ورودی بارندگی شبیه‌سازی شود.

به طور کلی در حل مسائل بهینه‌سازی از الگوریتم‌های بهینه‌سازی سنتی و تکاملی استفاده می‌گردد. در بسیاری از مسائل ممکن است تابع هدف منفصل و یا با تغییرات ناگهانی همراه باشد که الگوریتم‌های سنتی قادر به حل اینگونه مسائل نمی‌باشند. همچنین الگوریتم‌های سنتی عموماً در حل مسائل کوچک و با تعداد متغیرهای محدود مؤثر می‌باشند و در شرایطی که تعداد متغیرهای تصمیم زیاد هستند کارایی چندانی نخواهند داشت. لذا امروزه به دلیل پیچیدگی‌ها و مشکلات مختلف در حل مسائل بهینه‌سازی، تلاش‌های گسترده‌ای جهت استفاده از الگوریتم‌های تصادفی و تقریبی صورت گرفته است. گرچه این الگوریتم‌ها بهینه مطلق را تضمین نمی‌نمایند، اما عموماً می‌توان به کسب جواب نزدیک بهینه امیدوار بود. با توجه به قابلیت‌های الگوریتم‌های تکاملی در رفع این گونه معضلات، در سال ۷۰های اخیر از الگوریتم‌های تکاملی بیشتر استفاده می‌گردد. از جمله الگوریتم‌های تکاملی می‌توان به الگوریتم بهینه‌سازی جامعه پرندگان<sup>۷</sup> (PSO)، الگوریتم بهینه‌سازی جامعه مورچگان<sup>۸</sup> (ACO) و الگوریتم بهینه‌یابی جفت گیری زنبورهای عسل<sup>۹</sup> (HBMO) اشاره نمود [۵، ۱۲ و ۲]. GA نوع خاصی از الگوریتم‌های تکاملی است که به عنوان یکی از روش‌های تصادفی بهینه‌یابی شناخته شده توسط جان هالند (۹) ابداع شد. بعدها این روش با تلاش‌های گلدبرگ (۶)

- 1- Orissa
- 2- Multi Layer Perceptron
- 3- Radial Basis Function
- 4- Over Training
- 5- Auto Regressive
- 6- Goksudere
- 7- Particle Swarm Optimization
- 8- Ant Colony Optimization
- 9- Honey-Bee Mating Optimization

10- Response Surface Methodology  
11- Bambrougi

## مواد و روش‌ها

### ANN در شبیه‌سازی و پیش‌بینی آینده:

به هنگام استفاده از ANN، تعداد مطلوب لایه‌های مخفی و نیز نرون‌های موجود در هر لایه با استفاده از روش آزمون و خطا تعیین می‌گردند. لازم به ذکر است که تنها با صرف وقت زیاد، می‌توان تمام حالات موجود را با روش آزمون و خطا مورد بررسی قرار داد. در این تحقیق به منظور تعیین پارامترهای ANN نظیر تعداد لایه‌های مخفی و تعداد نرون‌های هر یک از این لایه‌ها از GA استفاده گردید. در صورت استفاده از این روش دستیابی به پارامترهای ANN آسانتر صورت می‌گیرد.

همچنین به منظور بررسی و تعیین عوامل هواشناسی و هیدرولوژیکی مؤثر بر روی آینده رودخانه‌ها از عوامل مختلفی نظیر دما، بارش، آینده و ... و نیز تأخیرهای زمانی هر یک از عوامل استفاده می‌گردد. این بررسی‌ها در دو بخش شبیه‌سازی و پیش‌بینی مورد بررسی قرار می‌گیرند. در مدل شبیه‌سازی از تمامی عوامل مورد استفاده برای گام‌های زمانی قبل و گام زمانی حاضر برای سایر عوامل غیر از عامل مورد پیش‌بینی استفاده می‌گردد. اما در مدل پیش‌بینی تنها از عوامل هواشناسی و هیدرولوژیکی گام‌های زمانی قبل استفاده شده است. لازم به ذکر است که در تحقیقات گذشته برای تعیین وابستگی آینده ماهانه رودخانه با هر یک از این عوامل، هر بار یک شبکه مجزا با ورودی‌های مورد نظر ایجاد می‌شد و پس از اجرای این شبکه‌ها و با استفاده از مقایسه نتایج حاصل شده در هر اجرا عوامل تأثیر گذار را تعیین می‌نمودند. همچنین می‌توان از ترکیب کل این عوامل به عنوان لایه‌های ورودی ANN نیز استفاده نمود که بدین ترتیب امکان ورود اطلاعاتی با همبستگی نامناسب با عامل شبیه‌سازی و یا پیش‌بینی وجود دارد که نتایج را نامطلوب می‌نماید. از آنجا که بررسی تمام این حالات دشوار و تقریباً ناممکن می‌باشد، در این تحقیق به منظور دستیابی آسانتر به حالت مطلوب از GA استفاده شد. عوامل مؤثر احتمالی در این مقاله برای مدل‌های شبیه‌سازی و پیش‌بینی آینده در ماه فعلی، به ترتیب به شرح زیر می‌باشند:

$$Q_{s(t)} = g(Q_{o(t-1)}, \dots, Q_{o(t-L)}, P_{(t-1)}, \dots, P_t, T_{(t-1)}, \dots, T_t) \quad (۱-الف)$$

$$\forall l = 1, 2, \dots, L, \quad L \leq t$$

$$Q_{f(t)} = g(Q_{o(t-1)}, \dots, Q_{o(t-L)}, P_{(t-1)}, \dots, P_{(t-1)}, T_{(t-1)}, \dots, T_{(t-1)}) \quad (۱-ب)$$

$$\forall l = 1, 2, \dots, L, \quad L \leq t$$

که در رابطه (۱)،  $Q_{s(t)}$  آینده شبیه‌سازی شده رودخانه،  $Q_{f(t)}$  آینده پیش‌بینی شده رودخانه،  $Q_{o(t)}$  آینده مشاهده شده رودخانه،  $P$  بارش،  $T$  دما،  $t$  زمان و  $L$  حداکثر تعداد تأخیرهای زمانی در نظر گرفته شده می‌باشد. به منظور استفاده از این داده‌ها در ANN، کلیه داده‌های

ورودی و خروجی ANN با استفاده از روابط زیر به داده‌های نرمال تبدیل شده است.

$$(Q_{o(t)})_{normal} = \frac{Q_{o(t)}}{Q_{o(max)}} \quad \forall t = 1, 2, \dots, M \quad (۲)$$

$$(P_t)_{normal} = \frac{P_t}{P_{max}} \quad \forall t = 1, 2, \dots, M \quad (۳)$$

$$(T_t)_{normal} = \frac{T_t}{T_{max}} \quad \forall t = 1, 2, \dots, M \quad (۴)$$

که در روابط بالا  $Q_{o(t)}$  داده‌های آینده مشاهده شده،  $Q_{o(max)}$  بزرگترین عدد موجود در سری داده‌های آینده مشاهده شده،  $(Q_{o(t)})_{normal}$  داده‌های آینده مشاهده شده نرمال،  $P_t$  داده‌های بارش،  $P_{max}$  بزرگترین عدد موجود در سری داده‌های بارش،  $(P_t)_{normal}$  داده‌های بارش نرمال شده،  $T_t$  داده‌های دما،  $T_{max}$  بزرگترین عدد موجود در سری داده‌های دما،  $(T_t)_{normal}$  داده‌های دمای نرمال شده و  $M$  تعداد کل داده‌ها می‌باشد.

پس از آموزش شبکه با استفاده از عوامل و پارامترهای منتخب توسط GA و نیز صحت‌سنجی این داده‌ها، داده‌های آزمایش وارد مدل شده و سپس نتایج حاصل از مدل با نتایج مشاهده شده مقایسه می‌گردد. برای انجام مقایسه از معیار میانگین مربعات خطا ( $MSE$ ) که از رابطه (۵-الف) و (۵-ب) محاسبه می‌شود، استفاده شده است که این روابط به ترتیب برای شبیه‌سازی و پیش‌بینی مورد استفاده قرار می‌گیرد.

$$MSE_s = \frac{1}{M} \sum_{t=1}^M (Q_{o(t)} - Q_{s(t)})^2 \quad (۵-الف)$$

$$MSE_f = \frac{1}{M} \sum_{t=1}^M (Q_{o(t)} - Q_{f(t)})^2 \quad (۵-ب)$$

که در آن  $MSE_s$  و  $MSE_f$  به ترتیب میزان خطای به دست آمده از شبیه‌سازی و پیش‌بینی داده‌ها و  $t$  شمارنده داده‌ها می‌باشد. با این معیارها می‌توان در مورد کارایی مدل به دست آمده قضاوت نمود. در این تحقیق پارامتر آماری ضریب رگرسیون و خطا نیز مورد بررسی قرار گرفته است. این معیارها برای مراحل شبیه‌سازی و پیش‌بینی از روابط (۶) و (۷) به دست می‌آید. روابط (الف) برای مدل شبیه‌سازی و روابط (ب) برای مدل پیش‌بینی می‌باشند.

خطا به کمترین مقدار ممکن نزدیک شود. روابط (۹) و (۱۰) قیودات مورد نیاز در این مدل را نشان می‌دهند.

$$NL < ML \quad (۹)$$

$$NN < MN \quad (۱۰)$$

که در روابط (۷) و (۸) تعداد لایه‌ها در هر اجرا،  $ML$  حداکثر تعداد لایه‌های در نظر گرفته شده،  $NN$  تعداد نرون‌های موجود در هر لایه در هر اجرا و  $MN$  حداکثر تعداد نرون‌های موجود در نظر گرفته شده در هر لایه می‌باشند.

مراحل انجام مدل را می‌توان به صورت زیر بیان نمود.

#### مدل ANN-GA

مراحل ترکیب و توسعه مدل تلفیقی ANN-GA جهت شبیه‌سازی و پیش‌بینی آینده‌ی به شرح ذیل می‌باشد:

گام اول: تعداد جمعیت موجود در هر نسل و تعداد نسل حداکثر در مرحله اول انتخاب می‌گردد و در این مرحله یک جمعیت اولیه تصادفی ایجاد می‌گردد.

گام دوم: در این گام معماری شبکه عصبی مصنوعی با استفاده از مقادیر ژن‌های موجود در هر جمعیت ایجاد شده تعیین می‌گردد. (این اعداد نشان دهنده لایه‌های ورودی شبکه عصبی مصنوعی، تعداد لایه‌های مخفی شبکه عصبی مصنوعی و تعداد نرون‌های موجود در هر یک از این لایه‌ها می‌باشند).

گام سوم: شبکه طراحی شده با استفاده از داده‌های نرمال شده ورودی آموزش می‌بیند. بعد از آموزش شبکه، مراحل واسنجی و آموزش شبکه نیز در این گام انجام می‌شود.

گام چهارم: پس از انجام پیش‌بینی با استفاده از شبکه طراحی شده معیار  $MSE$  محاسبه می‌گردد. با محاسبه این معیار تابع هدف مسئله که در این مطالعه حداقل کردن میانگین مربعات خطا می‌باشد، محاسبه می‌شود.

گام پنجم: به منظور ایجاد نسل بعد از عملگرهایی نظیر عملگرهای ژنتیکی و تکاملی مانند ترکیب و جهش ژنی و نیز چرخه رولت جهت انتخاب نسل بعد در GA استفاده می‌گردد. در این گام از نخبه‌گرایی نیز استفاده می‌شود. با استفاده از نخبه‌گرایی برخی از بهترین‌های جمعیت نسل حاضر به نسل بعد منتقل می‌شود.

گام ششم: در این گام جمعیت جدید ایجاد شده جایگزین جمعیت قبلی شده تا نسل جدید شکل گیرد. در این مرحله به شماره نسل مقدار یک اضافه می‌شود و تا زمانی که شماره نسل به مقدار حداکثر خود برسد، مراحل فوق تکرار می‌شوند.

مراحل فوق در شکل (۱) نشان داده شده است.

$$R_s^2 = \frac{\left[ \sum_{t=1}^M (Q_{o(t)} - \bar{Q}_o)(Q_{s(t)} - \bar{Q}_s) \right]^2}{\sum_{t=1}^M (Q_{o(t)} - \bar{Q}_o)^2 \sum_{t=1}^M (Q_{s(t)} - \bar{Q}_s)^2} \quad (۶-الف)$$

$$R_f^2 = \frac{\left[ \sum_{t=1}^M (Q_{o(t)} - \bar{Q}_o)(Q_{f(t)} - \bar{Q}_f) \right]^2}{\sum_{t=1}^M (Q_{o(t)} - \bar{Q}_o)^2 \sum_{t=1}^M (Q_{f(t)} - \bar{Q}_f)^2} \quad (۶-ب)$$

$$E_s = \sum_{t=1}^M \frac{(Q_{o(t)} - Q_{s(t)})^2}{Q_{o(t)}} \quad (۷-الف)$$

$$E_f = \sum_{t=1}^M \frac{(Q_{o(t)} - Q_{f(t)})^2}{Q_{o(t)}} \quad (۷-ب)$$

که در روابط بالا  $\bar{Q}_o$  میانگین داده‌های مشاهده شده،  $\bar{Q}_s$  میانگین داده‌های شبیه‌سازی شده،  $\bar{Q}_f$  میانگین داده‌های پیش‌بینی شده،  $R_s^2$  و  $R_f^2$  به ترتیب ضریب رگرسیون به دست آمده از نتایج مدل شبیه‌سازی و پیش‌بینی و  $E_s$  و  $E_f$  به ترتیب معیار خطای به دست آمده در دو مدل شبیه‌سازی و پیش‌بینی می‌باشند.


#### مدل بهینه‌سازی توسعه یافته

به منظور بهینه‌سازی پارامترهای شبکه عصبی مصنوعی، تابع هدف حداقل نمودن  $MSE$  کل داده‌های آموزش، صحت‌سنجی و آزمایش در نظر گرفته شده است.

$$f = \text{Minimize} (MSE) \quad (۸)$$

که در آن  $f$  تابع هدف می‌باشد.

برای تحقق این هدف تعداد لایه‌های مخفی، تعداد نرون‌های موجود در این لایه‌ها، عوامل هیدرولوژیکی و هواشناسی و نیز تأخیرهای زمانی این عوامل، به عنوان متغیرهای تصمیم مسئله در نظر گرفته شدند. متغیرهای تصمیم در نظر گرفته شده بر اساس خصوصیات منطقه مورد مطالعه می‌باشند. از خصوصیات حوضه آبریز این رودخانه، برفی بودن آن می‌باشد. به همین دلیل در این تحقیق علاوه بر عوامل آینده و بارش، از عامل دما و تأخیرهای زمانی آن که بر میزان ذخیره و ذوب برف تأثیرگذار می‌باشند، استفاده شده است. عامل بارش و تأخیرهای زمانی آن و تأخیرهای زمانی دبی نیز از دیگر عوامل تأثیرگذار بر میزان آینده رودخانه دز می‌باشند که در این تحقیق به عنوان متغیرهای تصمیم مسئله مورد بررسی قرار گرفته‌اند. این مقادیر و پارامترها به نحوی انتخاب می‌شوند تا میانگین مربعات



شکل ۱- مراحل ترکیب و توسعه مدل تلفیقی ANN-GA

### منطقه مطالعاتی

حوضه آبریز رودخانه دز با مساحت ۲۳۳۲۵۰ کیلومترمربع در ارتفاعات زاگرس میانی ایران واقع شده که طول این رودخانه ۵۱۵ کیلومتر می‌باشد. رودخانه دز سهم عمده‌ای در تشکیل یکی از مهم‌ترین و پرآب‌ترین رودخانه‌های ایران یعنی رود کارون دارد و قسمت عمده‌ای از نیازهای کشاورزی استان خوزستان را برآورده می‌سازد. حوضه آبریز دز از حوضه‌های برف‌گیر منطقه می‌باشد که میزان بارش و ذخیره برف نیز در این منطقه بر میزان آبدی رودخانه موثر می‌باشد. از جمله ایستگاه‌های هیدرومتری واقع بر این رودخانه ایستگاه هیدرومتری تله زنگ می‌باشد. در این تحقیق به منظور بررسی قابلیت مدل حاضر در دو مدل شبیه‌سازی و پیش‌بینی آبدی با استفاده از شبکه عصبی مصنوعی از ۲۰ سال آمار ماهانه دما، آبدی و بارش ایستگاه هیدرومتری تله زنگ برای دوره آماری ۶۱-۱۳۶۰ تا ۸۰-۱۳۷۹ استفاده شده است. در این تحقیق از ۶۰ درصد داده‌های موجود به منظور آموزش شبکه و از ۲۰ درصد داده‌ها برای صحت-سنجی ANN استفاده شده است. این زوج داده‌ها با حفظ پیوستگی زمانی به صورت تصادفی از میان کلیه زوج‌های تاریخی ممکن انتخاب شده‌اند. دلیل انتخاب تصادفی، پوشش مناسب و کافی اطلاعات آموزش از کل رخدادهای موجود در سری زمانی تاریخی می‌باشد. با استفاده از صحت سنجی داده‌ها، می‌توان کارایی مدل آموزش داده شده را بررسی نمود. پس از آموزش شبکه و صحت

سنجی آن، شبکه قادر خواهد بود تا در مقابل داده‌های جدید قرار گیرد و خروجی مناسب را ارائه نماید. لذا از ۲۰ درصد باقیمانده داده‌های موجود برای آزمایش شبکه استفاده گردید. بر همین اساس از میان ۲۰ سال داده آماری ایستگاه هیدرومتری تله زنگ، از داده‌های ۱۲ سال برای آموزش شبکه و از داده‌های چهار سال برای صحت سنجی و داده‌های چهار سال دیگر برای آزمایش شبکه استفاده گردید. شکل (۲) منطقه مورد مطالعه را نشان می‌دهد.

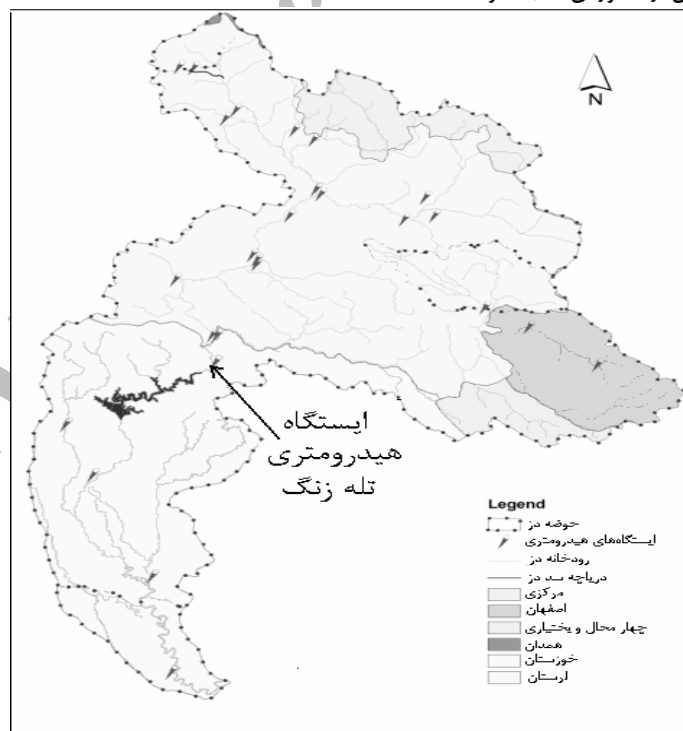
### نتایج و بحث

نتایج اجرای مدل ترکیبی بهینه‌سازی به تفکیک در مورد مدل‌های شبیه‌سازی و پیش‌بینی به شرح زیر حاصل گردیده است.

#### شبیه‌سازی

وابستگی آبدی ماهانه به پارامترهای دما و بارش همزمان و سه تأخیر زمانی برای هر یک از این عوامل و نیز سه تأخیر زمانی برای آبدی، در این قسمت بررسی می‌گردد.

$$Q_{s(t)} = f_1 \left( \begin{matrix} Q_{o(t-3)}, Q_{o(t-2)}, Q_{o(t-1)}, P_{(t-3)}, \\ P_{(t-2)}, P_{(t-1)}, P_t, T_{(t-3)}, T_{(t-2)}, T_{(t-1)}, T_t \end{matrix} \right) \quad (11)$$



شکل ۲- شکل شماتیک منطقه مطالعاتی

که در آن  $Q_{f(t)}$  آبدی پیش بینی شده رودخانه در ماه مورد نظر می باشد. خصوصیات ANN به کار گرفته شده در این بخش نیز همانند بخش قبل می باشد. تنها تفاوت موجود در تعداد متغیرهای تصمیم می باشد که در این بخش دو متغیر تصمیم بارش و دما در ماه مورد نظر حذف گردیده است. بنابراین تعداد متغیرهای تصمیم موجود در این قسمت برابر با ۱۳ می باشد. همچنین مقادیر پارامترهای GA نیز مشابه با مقادیر بخش قبل می باشد.

به منظور حذف تأثیر فرآیند تصادفی GA و قضاوت کلی بر اساس اجراهای متفاوت، مدل های حاضر پنج بار اجرا شده اند و برای هر اجرا مقادیر  $MSE$  برای مراحل آموزش، صحت سنجی، آزمایش و نیز کل داده ها و مقادیر  $R^2$  و  $E$  برای کل داده ها محاسبه گردید. همچنین به منظور ارزیابی مدل های مورد بررسی، دو شبکه با سه لایه مخفی و ۳۰ نرون در هر لایه و کلیه عوامل مورد استفاده در دو مدل شبیه سازی و پیش بینی ایجاد شد که این مقادیر برابر با حداکثر مقادیر مجاز مورد استفاده در مدل می باشند. نتایج به دست آمده از این اجراها، با نام اجرای نمونه ۱ و ۲ که به ترتیب نشان دهنده اجرای نمونه در مدل های شبیه سازی و پیش بینی می باشند، نشان داده شده است. جدول (۱) این نتایج را نشان می دهد.

جدول ۱- مقادیر  $MSE$ ،  $R^2$  و  $E$  در هر اجرا برای کل داده ها

| مدل       | شماره اجرا | MSE    | $R^2$ | E     |
|-----------|------------|--------|-------|-------|
| شبیه سازی | ۱          | ۰/۰۰۵۷ | ۰/۸۱  | ۵/۲۵  |
|           | ۲          | ۰/۰۰۴۸ | ۰/۸۵  | ۴/۰۹  |
|           | ۳          | ۰/۰۰۵۶ | ۰/۸۲  | ۴/۴۵  |
|           | ۴          | ۰/۰۰۸۴ | ۰/۷۳  | ۷/۲۲  |
|           | ۵          | ۰/۰۰۴۴ | ۰/۸۶  | ۳/۵۱  |
|           | نمونه ۱    | ۰/۰۰۹۷ | ۰/۷۵  | ۷/۳۶  |
| پیش بینی  | ۱          | ۰/۰۰۸۹ | ۰/۷۱  | ۶/۹۲  |
|           | ۲          | ۰/۰۰۸۲ | ۰/۷۵  | ۶/۰۸  |
|           | ۳          | ۰/۰۰۶۷ | ۰/۷۹  | ۵/۳۴  |
|           | ۴          | ۰/۰۰۶۹ | ۰/۷۷  | ۷/۶۰  |
|           | ۵          | ۰/۰۰۸۴ | ۰/۷۳  | ۶/۱۴  |
|           | نمونه ۲    | ۰/۰۱۲۵ | ۰/۶۱  | ۱۳/۷۵ |

با توجه به نتایج ذکر شده در جدول (۱) در مدل شبیه سازی و بررسی مقادیر  $MSE$ ،  $R^2$  و  $E$  برای هر اجرا مشاهده می شود که مقادیر این پارامترها در اجرای پنج بهتر از دیگر اجراها می باشد و این نشان دهنده نزدیکی بیشتر مقادیر شبیه سازی شده با مقادیر مشاهده شده در این اجرا می باشد. در بخش پیش بینی با توجه به مقادیر به دست آمده برای پارامترهای آماری  $MSE$ ،  $R^2$  و  $E$  می توان نتیجه گرفت که در اجرای سوم مقادیر پیش بینی شده به مقادیر مشاهده

که در رابطه فوق  $Q_{s(t)}$  آبدی شبیه سازی شده رودخانه در ماه مورد نظر،  $Q_{o(t-1)}$  آبدی رودخانه با یک ماه تأخیر،  $Q_{o(t-2)}$  آبدی رودخانه با دو ماه تأخیر،  $Q_{o(t-3)}$  آبدی رودخانه با سه ماه تأخیر،  $P_t$  بارش در ماه مورد نظر،  $P_{(t-1)}$  بارش با یک ماه تأخیر،  $P_{(t-2)}$  بارش با دو ماه تأخیر،  $P_{(t-3)}$  بارش با سه ماه تأخیر،  $T_t$  دما در ماه مورد نظر،  $T_{(t-1)}$  دما با یک ماه تأخیر،  $T_{(t-2)}$  دما با دو ماه تأخیر و  $T_{(t-3)}$  دما با سه ماه تأخیر می باشند.

ANN به کار گرفته شده در این مدل شامل حداکثر سه لایه مخفی ( $ML=3$ ) می باشد که در هر یک از این لایه ها، تعداد نرون های موجود، حداکثر ۳۰ نرون ( $MN=30$ ) می باشد. با توجه به موارد ذکر شده تعداد متغیرهای تصمیم مسئله برابر با ۱۵ متغیر شامل بارش و دما برای ماه حاضر و هر یک از سه ماه گذشته، آبدی برای هر یک از سه ماه گذشته و تعداد لایه های مخفی موثر و تعداد نرون ها در هر یک از این سه لایه می باشد. همچنین پس از انجام بررسی های لازم، تعداد ۲۵ اپوک به عنوان تعداد مطلوب اپوک های شبکه عصبی انتخاب گردید. در مدل حاضر توابع BP<sup>۱</sup>، تانژانت سیگموئید<sup>۲</sup> و لوگ سیگموئید<sup>۳</sup> به ترتیب به عنوان توابع انتقال الگوریتم یادگیری، انتقال لایه مخفی و انتقال لایه خروجی در نظر گرفته شده است.

عملکرد مدل GA به انتخاب مقادیر پارامترهای آن وابسته می باشد. بنابراین لازم است تا پارامترهای آن جهت اجرای بهتر مدل، واسنجی گردند. در این تحقیق احتمال جهش برابر با ۰/۱ و احتمال ترکیب برابر با ۰/۶ - منظور گردیده است. همچنین انتخاب کروموزوم های برتر به منظور تولید نسل جدید بر اساس روش چرخ رولت انجام گرفت. به منظور توقف الگوریتم از معیار توقف طی تعداد نسل های معین بدون توجه به اینکه تغییری در جواب نهایی نسل های آخر ایجاد گردد، استفاده شد. لذا تعداد ۱۰۰۰ نسل و ۱۵ کروموزوم برای هر اجرا در نظر گرفته شد. مدل بهینه سازی مورد بررسی توسط نرم افزار مطلب (Matlab) تهیه گردید.

### پیش بینی

در این بخش وابستگی آبدی ماهانه به پارامترهای دما، بارش و آبدی در ماه های گذشته مورد بررسی قرار می گیرد که رابطه زیر آن را نشان می دهد.

$$Q_{f(t)} = f_2 \left( \begin{matrix} Q_{o(t-3)}, Q_{o(t-2)}, Q_{o(t-1)}, \\ P_{(t-3)}, P_{(t-2)}, P_{(t-1)}, T_{(t-3)}, T_{(t-2)}, T_{(t-1)} \end{matrix} \right) \quad (12)$$

- 1- Back Propagation
- 2- Tangant Sigmoid
- 3- Log Sigmoid

شبیه‌سازی و پیش‌بینی، بارش همان ماه و بارش ماه قبل انتخاب شده است. جدول (۴) تعداد لایه‌های مخفی و تعداد نرون‌های موجود در این لایه‌ها را برای پنج بار اجرای مختلف نشان می‌دهد.

همان‌طور که مشاهده می‌شود در مدل شبیه‌سازی در دو اجرا (اجرای یک و سه)، تعداد لایه‌های مخفی یکسان و اعداد متناظر با تعداد نرون‌های موجود در این لایه‌ها نزدیک به هم می‌باشد. در مدل پیش‌بینی نیز تعداد لایه و تعداد نرون‌های موجود در هر لایه در سه اجرا (سه، چهار و پنج) تقریباً به یکدیگر نزدیک می‌باشند.

همچنین مشاهده می‌گردد که در هر دو مدل شبیه‌سازی و پیش‌بینی دو لایه به عنوان تعداد لایه برتر انتخاب شده است. شکل (۴) نیز نمودار داده‌های شبیه‌سازی شده و داده‌های پیش‌بینی شده را برای بهترین اجرا و اجرای نمونه نشان می‌دهند.

همان‌طور که در این شکل‌ها مشاهده می‌شود، آینده‌ی پیش‌بینی شده و آینده‌ی مشاهده شده برای بهترین اجرا، در بیشتر نقاط یا بر هم منطبق بوده و یا دارای اختلاف کمی با یکدیگر می‌باشند. اما در اجرای نمونه در برخی نقاط داده‌های پیش‌بینی شده با داده‌های مشاهده شده اختلاف چشمگیری دارند. این اختلاف را می‌توان به عدم وجود مقادیر بهینه پارامترهای شبکه عصبی مصنوعی و نیز تأثیر وجود عوامل هیدرولوژیکی و هواشناسی نامطلوب بر مقادیر شبیه‌سازی شده و پیش‌بینی شده در اجرای نمونه نسبت داد. همچنین ملاحظه می‌گردد که داده‌های شبیه‌سازی شده نسبت به داده‌های پیش‌بینی شده به مقادیر مشاهده شده نزدیک‌تر می‌باشد.

### نتیجه‌گیری

با توجه به این که بررسی تمام حالات ممکن برای تعداد لایه‌های مخفی و تعداد نرون‌های موجود در این لایه‌ها و نیز بررسی تمام عوامل هواشناسی و هیدرولوژیکی مؤثر، دشوار و تقریباً ناممکن می‌باشد، لذا در این تحقیق از GA برای دستیابی به حالت مطلوب ترکیب پارامترها و عوامل مؤثر در ANN استفاده گردید. بنابراین با به دست آوردن این مقادیر شبکه عصبی مناسب‌تری نتیجه می‌شود که با دقت بیشتر و در زمان کمتری قابل حصول می‌باشد. در تحقیقات گذشته برای پیش‌بینی و شبیه‌سازی جریان رودخانه بیشتر از عوامل بارش و تاخیرهای زمانی آن و نیز تاخیرهای زمانی دبی استفاده شده است. در این تحقیق علاوه بر عوامل ذکر شده از عامل دما و تاخیرهای زمانی آن همزمان با بهینه‌یابی انتخاب تعداد لایه‌ها و تعداد نرونهای هر لایه در شبکه عصبی نیز استفاده شده است. به دلیل برف‌گیر بودن حوضه آبریز دز، عامل دما به عنوان یکی از عوامل مورد بررسی انتخاب شده است. در اکثر اجراها از ۵ بار اجرای برنامه در مدل شبیه‌سازی لایه‌های بارش همان ماه و آینده‌ی ماه قبل به عنوان لایه‌های ورودی مؤثر بر آینده‌ی رودخانه و نیز عوامل مؤثر در

شده نزدیک‌تر می‌باشد. همچنین ملاحظه می‌گردد که نتایج به دست آمده در بهترین اجرا برای پارامترهای آماری در مدل شبیه‌سازی و با استفاده از معیار  $MSE$  ۳۴/۳ درصد، با استفاده از معیار  $R^2$  ۸/۸ درصد و با استفاده از معیار  $E$  ۳۴/۳ درصد بهتر از مدل پیش‌بینی می‌باشد. دلیل این برتری در نظر گرفتن عوامل هواشناسی در ماه مورد نظر در بخش شبیه‌سازی می‌باشد. شکل (۳) نمودار تغییرات کل داده‌های شبیه‌سازی و پیش‌بینی در بهترین اجرا نسبت به داده‌های مشاهداتی را نشان می‌دهد.

از شکل ۲ مشاهده می‌شود که شیب خط برازش داده شده بین داده‌ها همواره کمتر از یک می‌باشد و این نشان می‌دهد که شبکه عصبی مصنوعی عموماً داده‌ها را کمتر از داده‌های مشاهده شده شبیه‌سازی و پیش‌بینی می‌کند. همچنین می‌توان مشاهده نمود که شیب خط به دست آمده در بخش شبیه‌سازی به یک نزدیک‌تر بوده و این بدان معنی است که در شبیه‌سازی به دلیل در نظر گرفتن عوامل هواشناسی در ماه مورد نظر می‌توان آینده‌ی همان ماه را با دقت بیشتری تعیین نمود. جدول (۲) برخی از پارامترهای آماری محاسبه شده برای مقادیر  $MSE$ ،  $R^2$  و  $E$  در اجراهای مختلف را نشان می‌دهد.


با توجه به میزان انحراف معیار و ضریب تغییرات به دست آمده در جدول (۲) می‌توان نتیجه گرفت که در هر اجرا مقادیر شبیه‌سازی شده و پیش‌بینی شده با مقادیر مشاهده شده نزدیک به هم می‌باشند. همچنین نتایج نشان می‌دهد که انحراف معیار و ضریب تغییرات به دست آمده در مدل پیش‌بینی کمتر از مدل شبیه‌سازی می‌باشد. در جدول (۳) لایه‌های ورودی منتخب توسط GA را نشان می‌دهد.

با توجه به نتایج حاصل شده در مدل شبیه‌سازی مشخص گردید که آینده‌ی ماه قبل و بارش همان ماه در اکثر اجراها به عنوان لایه‌های مؤثر بر شبیه‌سازی آینده‌ی رودخانه انتخاب شده‌اند و در بهترین اجرا دمای ماه قبل و دمای سه ماه قبل نیز به عنوان عوامل تأثیر گذار بر شبیه‌سازی آینده‌ی ماهانه رودخانه انتخاب شدند. همچنین با توجه به نتایج جدول (۳) می‌توان نتیجه گرفت که بارش همان ماه و آینده‌ی ماه قبل بیشترین تأثیر را بر روی آینده‌ی ماهانه رودخانه‌ها و نیز بهبود عملکرد ANN در شبیه‌سازی آینده‌ی می‌گذارند. از دیگر نتایج حاصل شده می‌توان به عدم تأثیر گذاری تأخیرهای زمانی بارش و نیز تأخیرهای زمانی دوم و سوم آینده‌ی اشاره نمود. همچنین ملاحظه می‌گردد که در مدل پیش‌بینی نیز آینده‌ی ماه قبل در کلیه اجراها به عنوان یکی از عوامل تأثیر گذار بر روی پیش‌بینی آینده‌ی ماه مورد نظر انتخاب شده است. در بهترین اجرا در مدل پیش‌بینی بارش ماه قبل نیز انتخاب گردیده است. با مقایسه نتایج به دست آمده از دو مدل شبیه‌سازی و پیش‌بینی می‌توان نتیجه گرفت که مهمترین عامل تأثیر گذار بر روی آینده‌ی ماه مورد نظر، آینده‌ی ماه قبل می‌باشد. بارش نیز از عوامل مهم در تعیین آینده‌ی می‌باشد که به ترتیب در مدل‌های



عامل دما و تاخیرهای زمانی آن در تعیین میزان آبدهی حوضه‌های برفی می‌باشد. در مدل پیش‌بینی، آبدهی ماه قبل و بارش ماه قبل از جمله عوامل تأثیر گذار بر روی پیش‌بینی آبدهی ماه مورد نظر در بهترین اجرا انتخاب شدند.

عملکرد بهتر شبکه عصبی مصنوعی انتخاب گردیدند. در بهترین اجرا علاوه بر لایه‌های بارش همان ماه و آبدهی ماه قبل، لایه‌های دمای ماه قبل و دمای سه ماه قبل نیز به عنوان عوامل تأثیر گذار انتخاب شدند. دلیل انتخاب لایه‌های دمای سه ماه قبل و ماه قبل در بهترین اجرا را می‌توان وجود ذخائر برفی و همبستگی مقدار آبدهی با عامل دما در ذخیره و ذوب برف دانست. نتایج تحقیق نشان دهنده تأثیر



شکل ۳- خط برازش داده شده برای کل داده‌ها در بهترین اجرا، الف) شبیه‌سازی، ب) پیش‌بینی

جدول ۲- برخی پارامترهای آماری برای کل داده‌ها در ۵ اجرای مختلف توسط GA


| مدل       | معیار          | حداقل  | متوسط  | حداکثر | انحراف معیار | ضریب تغییرات |
|-----------|----------------|--------|--------|--------|--------------|--------------|
| شبیه‌سازی | MSE            | ۰/۰۰۴۴ | ۰/۰۰۵۸ | ۰/۰۰۸۴ | ۰/۰۰۱۶       | ۰/۲۷۰۴       |
|           | R <sup>2</sup> | ۰/۷۳   | ۰/۸۱   | ۰/۸۶   | ۰/۵۱         | ۰/۰۶۳        |
|           | E              | ۳/۵۱   | ۴/۹۰   | ۷/۲۲   | ۱/۴۴         | ۰/۲۹         |
| پیش‌بینی  | MSE            | ۰/۰۰۶۷ | ۰/۰۰۷۸ | ۰/۰۰۸۹ | ۰/۰۰۱۰       | ۰/۱۲۳۸       |
|           | R <sup>2</sup> | ۰/۷۱   | ۰/۷۵   | ۰/۷۹   | ۰/۳۱         | ۰/۰۴۲        |
|           | E              | ۵/۳۴   | ۶/۴۲   | ۷/۶۰   | ۰/۸۷         | ۰/۱۴         |

جدول ۳- لایه‌های ورودی منتخب توسط GA

| Q   |     |     | P |     |     |     | T |     |     | لایه<br>اجرا | مدل     |               |
|-----|-----|-----|---|-----|-----|-----|---|-----|-----|--------------|---------|---------------|
| t-1 | t-2 | t-3 | t | t-1 | t-2 | t-3 | t | t-1 | t-2 |              |         | t-3           |
| -   | -   | -   | - | -   | -   | -   | - | -   | -   | -            | ۱       | شبيه-<br>سازی |
| -   | -   | -   | - | -   | -   | -   | - | -   | -   | -            | ۲       |               |
| -   | -   | -   | - | -   | -   | -   | - | -   | -   | -            | ۳       |               |
| -   | -   | -   | - | -   | -   | -   | - | -   | -   | -            | ۴       |               |
| -   | -   | -   | - | -   | -   | -   | - | -   | -   | -            | ۵       |               |
|     |     |     |   |     |     |     |   |     |     |              | نمونه ۱ |               |
| -   | -   | -   | - | -   | -   | -   | - | -   | -   | -            | ۱       | پيش‌بینی      |
| -   | -   | -   | - | -   | -   | -   | - | -   | -   | -            | ۲       |               |
| -   | -   | -   | - | -   | -   | -   | - | -   | -   | -            | ۳       |               |
| -   | -   | -   | - | -   | -   | -   | - | -   | -   | -            | ۴       |               |
| -   | -   | -   | - | -   | -   | -   | - | -   | -   | -            | ۵       |               |
|     |     |     |   |     |     |     |   |     |     |              | نمونه ۲ |               |

جدول ۴- تعداد لایه‌های مخفی و تعداد نرون‌های موجود در این لایه‌ها

| مدل       | شماره اجرا | تعداد لایه مخفی | تعداد نرون لایه مخفی ۱ | تعداد نرون لایه مخفی ۲ | تعداد نرون لایه مخفی ۳ |
|-----------|------------|-----------------|------------------------|------------------------|------------------------|
| شبيه‌سازی | ۱          | ۳               | ۱۴                     | ۱۱                     | ۶                      |
|           | ۲          | ۲               | ۲۱                     | ۷                      | -                      |
|           | ۳          | ۳               | ۱۱                     | ۸                      | ۵                      |
|           | ۴          | ۳               | ۱۲                     | ۸                      | ۱۸                     |
|           | ۵          | ۲               | ۱۸                     | ۱۰                     | -                      |
| پيش‌بینی  | حداقل      | ۲               | ۱۱                     | ۷                      | ۰                      |
|           | میانگین    | ۲/۶             | ۱۵/۲                   | ۸/۸                    | ۵/۸                    |
|           | حداکثر     | ۳               | ۲۱                     | ۱۱                     | ۱۸                     |
|           | نمونه ۱    | ۳               | ۳۰                     | ۳۰                     | ۳۰                     |
|           | ۱          | ۱               | ۱۵                     | -                      | -                      |
| پيش‌بینی  | ۲          | ۳               | ۲۰                     | ۲۰                     | ۲۵                     |
|           | ۳          | ۲               | ۱۰                     | ۲۴                     | -                      |
|           | ۴          | ۲               | ۱۴                     | ۱۵                     | -                      |
|           | ۵          | ۲               | ۱۱                     | ۱۸                     | -                      |
|           | حداقل      | ۱               | ۱۰                     | ۰                      | ۰                      |
| پيش‌بینی  | میانگین    | ۲               | ۱۴                     | ۱۵/۴۰                  | ۵                      |
|           | حداکثر     | ۳               | ۲۰                     | ۲۴                     | ۲۵                     |
|           | نمونه ۲    | ۳               | ۳۰                     | ۳۰                     | ۳۰                     |



شکل ۴- نمودار آبدهی شبیه‌سازی شده، پیش‌بینی شده و مشاهده شده در بهترین اجرا و اجرای نمونه، الف) شبیه‌سازی، ب) پیش‌بینی

رودخانه دز در ایستگاه هیدرومتری تله زنگ توسعه داده شده و پارامترهای آن توسط GA تنظیم گردیده است، بیانگر نزدیکی مقادیر شبیه‌سازی شده با مقادیر مشاهده شده می‌باشد. همچنین در بخش پیش‌بینی نیز نتایج به دست آمده از اجرای مدل نسبت به اجرای نمونه بخش پیش‌بینی بهتر بوده است. همانگونه که انتظار می‌رفت نتایج به دست آمده از اجرای مدل در بخش شبیه‌سازی بهتر از بخش

از دیگر عوامل انتخاب شده در این اجرا دمای سه ماه قبل می‌باشد. همانگونه که اشاره شد این انتخاب را می‌توان به خصوصیات حوضه آبریز که حوضه‌ای برف‌گیر می‌باشد، نسبت داد. لذا در کنار مدل‌های بارش - رواناب موجود، از مدل حاضر می‌توان در برآورد اطلاعات آبدهی حوضه استفاده نمود. از طرفی مقادیر کوچک  $MSE$  حاصل از یک مدل ANN که جهت شبیه‌سازی آبدهی ماهانه

و برای مدل پیش‌بینی ۴/۴۶، ۵۱/۲۹ و ۱۶/۶۱ درصد بهبود را نشان می‌دهند. نتایج حاصل نشان دهنده کارایی روش فوق در تعیین مقادیر مطلوب پارامترهای ذکر شده و تخمین مناسب آینده‌ی چه در حالت شبیه‌سازی و چه در حالت پیش‌بینی می‌باشد.

پیش‌بینی می‌باشد. مقادیر ضریب رگرسیون برای دو مدل شبیه‌سازی و پیش‌بینی به ترتیب برابر با ۰/۸۶ و ۰/۷۹ به دست آمد. مقادیر  $MSE$ ،  $R^2$  و  $E$  به دست آمده از مدل ANN-GA نسبت به اجرای نمونه به ترتیب برای مدل شبیه‌سازی ۵۸/۷۶، ۱۴/۶۷ و ۵۲/۳۱ درصد

## منابع

- 1- Ahmad A.L., Azid I.A., Yusof A.R. and Seetharamu K.N. 2004. Emission control in palm oil mills using artificial neural network and genetic algorithm. *Journal of Computer and Chemical Engineering*, 28, 2709–2715.
- 2- Bozorg Haddad O., Afshar A. and Marino M.A. 2006. Honey-bee mating optimization (HBMO) algorithm: A new heuristic approach for water resources optimization. *Journal of Water Resources Management*, 20, 661-680.
- 3- Chen Y.M. 1997. Management of water resources using improved genetic algorithms. *Journal of Computers and Electronics in Agriculture*, 18, 117-127.
- 4- Chen J. and Adams B. J. 2006. Integration of artificial neural networks with conceptual models in rainfall-runoff modeling. *Journal of Hydrology*, 318, 232-249.
- 5- Chuanwen J. and Bompard E. 2005. A self – adaptive chaotic particle swarm algorithm for short term hydro electric system scheduling in deregulated environment. *Journal of Energy Conversion and Management*, 46(17), 2689-2696.
- 6- Goldberg D., Korb B. and Deb K. 1989. Messy genetic algorithms: motivation, analysis, and first results. *Complex Systems*, 3, 493-530.
- 7- Govindaraju R.S. 2000. Artificial neural network in hydrology. I: Preliminary Concepts. *Journal of Hydrologic Engineering*, 5(2), 115-123.
- 8- Hall T., Brooks H.E. and Doswell C.A. 1999. Precipitation forecasting using a neural network. *Journal of Weather and Forecasting*, 14, 338-345.
- 9- Holland J.H. 1975. *Adaption in natural and artificial systems*. The University of Michigan Press, Ann Harbor, MI.
- 10- Istadi I. and Amin N. A. S. 2007. Modeling and optimization of catalytic–dielectric barrier discharge plasma reactor for methane and carbon dioxide conversion using hybrid artificial neural network—genetic algorithm technique. *Journal of Chemical Engineering Science*, 62, 6568 – 6581.
- 11- Jain S.K., Das A. and Sirvastava D.K. 1999. Application of ANN for reservoir inflow prediction and operation. *Journal of Water Resource Planning and Management*, 125, 263-271.
- 12- Jalali M.R., Afshar A. and Mariño M.A. 2007. Multi-colony ant algorithm for continuous multi-reservoir operation optimization problem. *Journal of Water Resources Management*, 21(9), 1429-1447.
- 13- Kamp R. G. and Savenije H. H. G. 2006. Optimising training data for ANNs with Genetic Algorithms. *Journal of Hydrology and Earth System Sciences*, 10, 603-608.
- 14- Kisi, O., (2004). River flow modeling using artificial neural networks. *Journal of Hydrologic Engineering*, 9(1), 60-63.
- 15- Luk K.G., Ball J.E. and Sharma A. 2000. A study of optimal lag and statistical inputs to artificial neural network for rainfall forecasting. *Journal of Hydrology*, 227, 56-65.
- 16- Luk K.G., Ball J.E. and Sharma A. 2001. An application of artificial neural network for rainfall forecasting. *Journal of Mathematical and Computer Modeling*, 33, 683-693.
- 17- Nandi S., Badhe Y., Lonari J., Sridevi U., Rao, B.S., Tambe, S.S. and Kulkarni B.D. 2004. Hybrid process modeling and optimization strategies integrating neural networks/support vector regression and genetic algorithms: study of benzene isopropylation on hbeta catalyst. *Journal of Chemical Engineering*, 97, 115–129.

## Inflow Simulation and Forecasting Optimization Using Hybrid ANN-GA Algorithm

M. Zarezadeh-Mehrizi<sup>1\*</sup>- O. Bozorg Haddad<sup>2</sup>

Received: 8-2-2010  
Accepted: 20-5-2010

### Abstract

One of the major factors on the amount of water resources is river flow which is so dependent to the hydrologic and meteorologic phenomena. Simulation and forecasting of river flow makes the decision maker capable to effectively manage the water resources projects. So, simulation and forecasting models such as artificial neural networks (ANNs) are commonly used for simulation and predicting the exact value of such factors. In this research, the Dez River basin was selected as the case study. This paper investigates the effectiveness of temperature, precipitation and inflow factors and the lag time of those factors in inflow simulation and forecasting. Genetic algorithm (GA) has been thus used as an optimization tool, determining the optimum composition of the effective variables. Thus, in a flow simulation and forecasting model, the number of hidden layers, effective neurons in each layer, effective meteorologic and hydrologic parameters and also the lag time of each factor of flow simulation and forecasting has been considered as decision variables, and GA has been used to obtain the best combination of those variables. In this study, minimization of the total mean square error (MSE) has been considered as the objective function. Results show GA's effectiveness in flow simulation and forecasting with consistent accuracy. The value of  $R^2$  criterion has been obtained 0.86 and 0.79 in the simulation and forecasting models, respectively. The results also showed superiority replies obtained from the simulation model to the prediction model. One of the reasons for this superiority can be considering the meteorological factors in the current month in river flow simulation.

**Keywords:** Artificial Neural Network, Simulation, Forecasting, Flow, Optimization, Genetic Algorithm

---

1- M.Sc Student of Water Resources Engineering, Department of Water Resources Engineering, Tarbiat Modares University, Tehran, Iran

(\*- Corresponding Author; Email: m.zarezade@modares.ac.ir)

2- Assistant Professor, Department of Irrigation & Reclamation Engineering, Faculty of Agricultural Engineering and Technology, College of Agriculture & Natural Resources, University of Tehran, Karaj, Tehran, Iran