



## ارزیابی عملکرد شبکه عصبی استوکستیک در بهره‌برداری بهینه از مخزن سیمره

پریسادات آشفته<sup>۱\*</sup>، مبینا ولی‌دوستی<sup>۲</sup>

۱- استادیار، گروه مهندسی عمران، دانشکده فنی و مهندسی دانشگاه قم، PS.Ashofteh@qom.ac.ir

۲- دانشجوی کارشناسی، گروه مهندسی عمران، دانشکده فنی و مهندسی دانشگاه قم،

mobina.validoosti@gmail.com

### چکیده

از آنجایی که بین آورد ورودی به مخازن و تقاضای آب پایین دست مخازن در بیش تر مواقع اختلاف وجود دارد، به خصوص اختلاف زمانی بین اوج تقاضای آب و آورد ورودی به مخازن، سدها نقش مهمی در مدیریت منابع آب دارند. هدف از تحقیق حاضر کاربرد شبکه عصبی استوکستیک<sup>۱</sup> (SNN) به منظور بهره‌برداری از مخزن سیمره (شهرستان دره شهر) می‌باشد. در مطالعه حاضر از روش برنامه‌ریزی ژنتیک<sup>۲</sup> (GP) برای آموزش شبکه عصبی استفاده گردید. برای بررسی کارایی مدل از داده‌های سد سیمره به عنوان مطالعه موردی استفاده گردید، سپس نتایج، با نتایج برنامه‌ریزی خطی<sup>۳</sup> (LP) مقایسه شده است. نتایج حاکی از کارایی و قابلیت بالای مدل SNN به منظور بهره‌برداری از مخزن می‌باشد. نتایج نشان دادند که مدل SNN با توجه به قدرت بالایی که در امر یادگیری داشت توانست به عنوان یک ابزار کارآمد به منظور بهره‌برداری بهینه از مخازن، در اختیار تصمیم‌گیران و بهره‌برداران قرار گیرد.

**کلمات کلیدی:** بهره‌برداری بهینه از مخازن، شبکه عصبی استوکستیک، برنامه‌ریزی ژنتیک.

### ۱- مقدمه

بهره‌برداری بهینه از سدها از موضوعات مهم و اساسی در امر بهره‌برداری بهینه از منابع آب سطحی می‌باشد. بنابراین با توجه به اهمیت و حساسیت نحوه بهره‌برداری از سدها، یافتن راه‌کار مناسب برای بهره‌برداری از سدها ضروری است. بهره‌برداری در زمان حاضر از مخزن بر مبنای سیاست بهره‌برداری و قواعد و تصمیماتی است که اتخاذ گردیده است (دوبراوین<sup>۴</sup> و همکاران، ۲۰۰۲). بهره‌برداری از مخزن به دلیل عدم قطعیت‌های موجود در ورودی‌ها و تأمین خروجی‌ها با توجه به قیودات فیزیکی مسأله، بسیار پیچیده می‌باشد (دکا و چندرامولی<sup>۵</sup>، ۲۰۰۹).

بنابراین با توجه به اختلاف آورد ورودی به مخازن و تقاضای آب پایین دست آن، سدها نقش مهمی در مدیریت منابع آب دارند. این اختلاف می‌تواند هم از نظر مقداری باشد و هم از نظر زمانی (یعنی بین اوج مصرف و آورد ورودی). امروزه شبکه‌های عصبی در مدیریت منابع آب کاربردهای فراوانی داشته‌اند. شبکه عصبی در واقع یک نوع هوش مصنوعی است

<sup>۱</sup> Stochastic Neural Network

<sup>۲</sup> Genetic Programming

<sup>۳</sup> Linear Programming

<sup>۴</sup> Dubrovin

<sup>۵</sup> Deka Chandramouli



که تلاش می‌کند تا سامانه عصبی و ساختار بیولوژیکی مغز انسان را شبیه‌سازی کنند. مفهوم شبکه عصبی برای اولین بار در دهه چهل قرن بیستم میلادی مطرح گردید ولی اوج شکوفایی کاربرد شبکه عصبی با معرفی الگوریتم پیش‌انتشار برای شبکه‌های پیشخور در سال ۱۹۸۶ اتفاق افتاد (منهاج، ۱۳۷۹).

آیتک<sup>۶</sup> و همکاران (۲۰۰۸) شبکه‌های عصبی و GP را برای مدل‌سازی بارش-رواناب روزانه حوضه رودخانه جونیاتا در ایالت پنسیلوانیای آمریکا استفاده نمودند و نتیجه گرفتند که GP با دقت بهتری نسبت به شبکه‌های عصبی مصنوعی فرآیند بارش-رواناب را مدل‌سازی می‌کند. احمدی و همکاران (۲۰۱۹) عملکرد مدل‌های ANN و IHACRES و ANN در شبیه‌سازی بارش-رواناب برای حوضه کن بررسی شد. بررسی‌ها نشان دادند که مدل ANN بهترین رواناب روزانه را شبیه‌سازی نمود و در عین حال به داده‌های خیلی کمی در مقایسه با دو مدل دیگر نیاز بود. زکی‌زاده<sup>۷</sup> و همکاران (۲۰۲۰) مدل‌سازی هیدرولوژیکی را بررسی نمودند. ایشان از مدل‌های ANN و SWAT برای یک حوضه آبریز شهری استفاده نمودند. نتایج نشان دادند که عملکرد مدل‌ها بسیار مطلوب بوده است.

یکی از مشکلاتی که محققان در استفاده از شبکه عصبی به‌منظور بهره‌برداری از مخزن با آن مواجه بودند، انتخاب داده‌های آموزشی شبکه عصبی است، زیرا تنها داده‌های تاریخی بهره‌برداری موجود می‌باشد که لزوماً بهینه نیستند و استفاده از آنها برای آموزش شبکه موجب ایجاد خطا در مدل می‌گردد. در این مطالعه سعی گردیده است مدلی ارائه گردد که در هر مرحله از بهره‌برداری از مخزن با توجه به تراز سطح آب در مخزن در ابتدای دوره و هم‌چنین مقدار آبدهی ورودی به مخزن در این دوره، مقدار رهاسازی از مخزن به‌گونه‌ای تعیین گردد که به بهترین نحو سیاست بهره‌برداری از مخزن را ارضا کند. بدین‌منظور از شبکه عصبی استفاده گردیده است که بر مبنای روش استوکستیک آموزش می‌بیند یا به‌عبارتی بهینه می‌گردد.

## ۲- مواد و روش‌ها

### ۲-۱- برنامه‌ریزی ژنتیک

GP به‌عنوان یکی از ابزارهای پرکاربرد، قادر به استخراج روابط بسیار متنوع و پیچیده از پایگاه داده‌ها و ارائه آنها در قالب روابط ریاضی است. یکی از مهم‌ترین وجوه تمایز برنامه‌ریزی ژنتیک در مقایسه با ابزارهایی نظیر انواع شبکه‌های مصنوعی و ماشین‌های بردار پشتیبان در این است که خروجی این ابزار یک فرمول و رابطه کاملاً شهودی است. این ابزار را می‌توان برآمده از هر سه شاخه یادگیری ماشین، داده‌کاوی و هوش مصنوعی دانست.

GP را می‌توان نسخه تکمیل‌یافته الگوریتم بهینه‌سازی ژنتیک دانست با این تفاوت که در GP در هر ژن علاوه بر اعداد (مقادیر متغیرهای تصمیم)، می‌توان عملگرهای ریاضی نظیر عملگر جمع، تفریق، تقسیم و ضرب، توابع مختلف نظیر توابع لگاریتمی و مثلثاتی و هم‌چنین نام متغیرهای ورودی را نیز در نظر گرفت. هم‌چنین در GP به‌جای ساختار مرسوم کروموزم در الگوریتم ژنتیک<sup>۸</sup> (GA) با ساختاری درختی از کروموزوم‌ها روبرو هستیم. ساختارهای درختی از مجموعه توابع (عملگرهای ریاضی مورد استفاده در فرمول‌ها) و ترمینال‌ها (متغیرهای مسأله و اعداد ثابت) ایجاد

<sup>۶</sup> Aytok

<sup>۷</sup> Zakizadeh

<sup>۸</sup> Genetic Algorithm



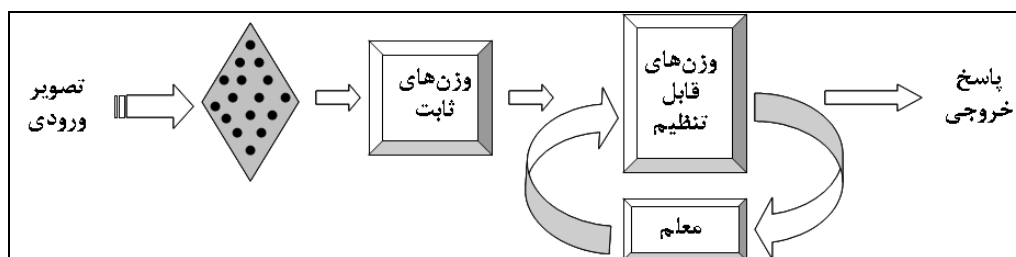
می‌شوند (کزا<sup>۹</sup>، ۱۹۹۲). بنابراین، GP به مراتب از پیچیدگی بیش تری نسبت به شبکه‌های عصبی و ماشین‌های بردار پشتیبان برخوردار است.

مراحل حل مسأله با GP به شرح زیر است (ست و بولارت<sup>۱۰</sup>، ۲۰۰۱): (۱) تولید یک جمعیت اولیه، (۲) ارزیابی برازش هر فرمول موجود در جمعیت، (۳) انتخاب عملگرهای ژنتیکی (جهش، تزویج و تولید مثل) برای تولید فرمول جدید، و (۴) قرار دادن فرمول تولیدشده در جمعیت جدید تا زمانی که تعداد افراد جمعیت برابر جمعیت اولیه شود.

## ۲-۲- شبکه عصبی

شبکه‌های عصبی مصنوعی، ساختاری شبیه به مغز انسان دارند و با پردازش روی داده‌های تجربی، قانون نهفته در ورای داده‌ها را کشف نموده و از آن برای پیش‌بینی مقادیر آتی استفاده می‌نمایند. براساس این دیدگاه می‌توان روابط موجود بین متغیرها را با استفاده از روش‌های جستجو در اطلاعات از طریق یارانه فرا گرفت و از آنها برای پیش‌بینی مقادیر آینده استفاده نمود.

دیدگاه جدید شبکه‌های عصبی را در سال ۱۹۴۳ با ارائه شبکه‌ای از چند نرون ساده توسط مک‌کولوچ و پیت آغاز گردید. نخستین کاربرد عملی شبکه‌های عصبی در سال ۱۹۵۸، با معرفی شبکه پرسپترون توسط روزنبلت و همکارانش صورت گرفت. پرسپترون الگویی است که احتیاج به آموزش با نظارت دارد. الگوی اولیه روزنبلت مطابق شکل ۱ می‌باشد.



شکل ۱- الگوی اولیه شبکه عصبی

این الگوی آموزش در سه سطح قابل توصیف است. (۱) واحد سنسور (S)، جایی که محرک نوری اعمال می‌شود. (۲) واحد تجمع (A)، جایی که آموزش از قبل شناخته شده است (یعنی وزن‌های سیناپسی ثابت هستند). (۳) واحد پاسخ (R) جایی که آموزش و تعلیم صورت می‌گیرد و خروجی به دست می‌آید (منهاج، ۱۳۷۹). بنابراین شبکه عصبی براساس ساختار شبکه، تابع محرک نرون‌ها و روش تعیین مقادیر وزن‌های رابط میان نرون‌ها مشخص می‌گردد (فاست<sup>۱۱</sup>، ۱۹۹۴). در شکل ۲ قالب کلی یک شبکه عصبی نمایش داده شده است.

<sup>۹</sup> Koza

<sup>۱۰</sup> Sette Boullart

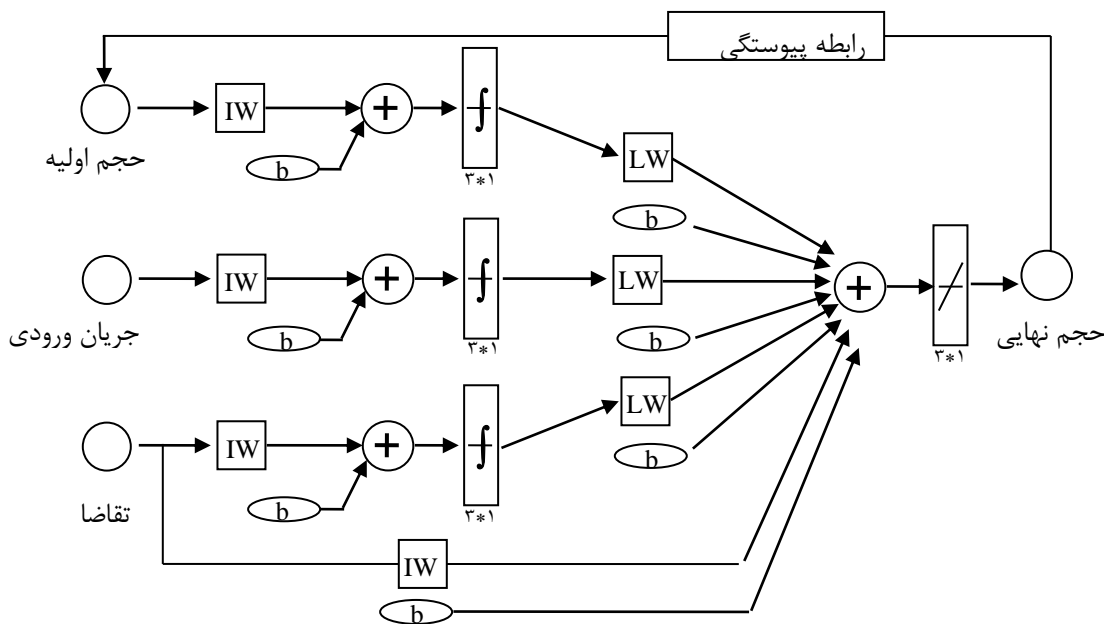
<sup>۱۱</sup> Fausett



شکل ۲- قالب کلی یک شبکه عصبی

### ۳-۲- شبکه عصبی استوکستیک

در این مطالعه از شبکه عصبی که توسط روش بهینه‌سازی GP، بهینه‌سازی شده است، با نام شبکه عصبی استوکستیک یاد شده است. GP در هر تکرار خروجی‌ها را تعیین و به شبکه عصبی تزریق می‌کند. شبکه عصبی تولیدشده، شبیه‌سازی بهره‌برداری از مخزن را انجام می‌دهد. سپس تابع هدف تعیین می‌گردد و به GP انتقال می‌یابد و GP به‌گونه‌ای عمل می‌کند که مقدار تابع هدف بهینه گردد. به‌منظور تولید شبکه عصبی استوکستیک از نرم‌افزار MATLAB، استفاده گردید. شبکه عصبی به‌کاررفته در این مطالعه دارای ساختار ارائه‌شده در شکل ۳ می‌باشد.



شکل ۳- ساختار شبکه عصبی استوکاستیک

همان‌طور که در شکل ۳ نمایش داده شده است، شبکه عصبی دارای ۴ لایه و هر لایه دارای ۳ نرون می‌باشد. در لایه‌های یک، دو و سه از تابع محرک تانژانت‌زیگموئید و در لایه چهارم از تابع محرک خطی استفاده گردید. خروجی تابع تانژانت‌زیگموئید در بازه (۰،۱) می‌باشد، اما نتایج نشان دادند در صورتی که خروجی این تابع در بازه (۰،۵۰۰) تعریف شود، نتایج بهتری ارائه خواهد نمود.



#### ۲-۴- تعریف مدل بهینه‌سازی به کاررفته

برای آموزش (بهینه‌سازی) شبکه عصبی برای بهره‌برداری از مخزن، تابع هدف بصورت بیشینه‌سازی رهایی نرمال در نظر گرفته شده است. در این مطالعه، آستانه رهایی نرمال ۹۵ درصد تقاضا فرض شده است. قالب ریاضی روابط بهینه‌سازی مطابق با رابطه‌های (۱) تا (۵) می‌باشد:

تابع هدف:

$$\text{Max: Reliability} = m + \text{Penalty Function} \quad (1)$$

قیودات:

$$R_{opt_{kt}} = S_{l,t+1} - S_{kt} + I_t - Sp_{kt} \quad (2) \text{ تابع پیوستگی}$$

$$S_{\min} < S_{kt} < S_{\max} \quad (3) \text{ محدودیت حجم مخزن}$$

$$0 \leq R \leq De \quad (4) \text{ محدودیت رهاسازی آب از مخزن}$$

$$Sp_t \geq 0 \quad \forall t \quad (5) \text{ نامنفی بودن متغیرهای تصمیم}$$

که در آن،  $m$ ،  $R_{opt}$ ،  $S$ ،  $S_{min}$ ،  $S_{max}$ ،  $I$  و  $Sp$  = به ترتیب بیان گر احتمال رهایی نرمال (بالتر از سطح آستانه که در این مطالعه، ۹۵ درصد نیاز در نظر گرفته شده است)؛ رهاسازی بهینه؛ حجم ذخیره؛ حجم کمینه؛ حجم بیشینه؛ جریان ورودی و سرریز از مخزن، هستند.

با توجه به این که از GP برای بهینه‌سازی استفاده شده است، بجز قید پیوستگی که به‌طور مستقیم در مرحله شبیه‌سازی به مسأله اضافه گردید، دیگر قیودات به‌صورت تابع جریمه به مسأله اضافه گردید. تابع جریمه به کار گرفته شده در این تحقیق، به‌ازای مرتبه نقض قیودات ۰/۱ واحد از تابع هدف کسر می‌کند. قابل ذکر است برای سادگی از تلفات مخزن (تبخیر و نشت) صرف‌نظر شده است.


#### ۳- مورد مطالعاتی

سد سیمره در مسیر رود سیمره و جز استان ایلام قرار دارد. این سد از نوع بتنی دو قوسی است و توانایی تولید انرژی به میزان سالانه ۶۷۳ گیگاوات ساعت را دارد. ساختگاه نیروگاه در فاصله ۲۵ کیلومتری شمال غربی شهر دره‌شهر است. هدف از اجرای طرح سیمره تولید انرژی برق‌آبی به میزان متوسط سالانه ۶۸۴ گیگاوات ساعت در سال، کنترل و تنظیم جریان‌های سطحی رودخانه و تأمین حقابه پایین دست می‌باشد. صرفه‌جویی در مصرف سوخت‌های فسیلی و کنترل طغیان‌های رودخانه هم‌چنین اثرات جانبی ایجاد اشتغال، افزایش قدرت تنظیم سدهای پایین دست و استحصال سایر درآمدهای جانبی نظیر آبی‌پروری و گردشگری را در پی خواهد داشت. رود سیمره به‌طول ۴۱۷ کیلومتر و شیب ۰/۳ درصد از بهم پیوستن رودخانه‌های قره‌سو و گاماسیاب تشکیل شده و مهم‌ترین شاخه‌های فرعی آن چرداول و شیروان می‌باشد. ساختگاه سد سیمره در ۴۰ کیلومتری شمال غربی شهرستان دره شهر و در ۱۰۶ کیلومتری جنوب شرقی شهرستان ایلام واقع است. سطح حوضه در محل ساختگاه، ۲۷۸۸۶ کیلومتر مربع، میزان متوسط تبخیر سالانه از سطح آزاد آب ۱۸۱۴/۰۱ میلی‌متر، متوسط آبدهی سالانه رودخانه ۸۵/۷ مترمکعب در ثانیه، بیشینه دبی سیلاب ۱۱۵۲۵ مترمکعب در ثانیه، است.






برای بررسی کارآیی مدل، بهره‌برداری از مخزن سد سیمره در ۳۷ کیلومتری شمال غربی شهرستان دره‌شهر مورد مطالعه قرار گرفت. در این مسأله یک سامانه، با گام زمانی ماهانه و شامل ۶۰ ماه آمار آبدهی مورد بررسی قرار گرفت. برای بررسی مدل شبکه عصبی استوکستیک، از GP تک‌هدفه، با احتمال تزویج برابر با (۰/۹)، احتمال جهش با (۰/۰۶) و تعداد اعضای هر نسل ۵۰ عضو در نظر گرفته شد. بیشینه تعداد تولید نسل برابر ۳۰۰۰ نسل در نظر گرفته شد. شکل ۱، حجم آب موجود در مخزن در طول بهره‌برداری را با استفاده از شبکه عصبی استوکستیک نمایش می‌دهد. شکل ۲، وضعیت رهاسازی و سرریز در طول بهره‌برداری، با استفاده از شبکه عصبی استوکستیک را ارائه می‌دهد.



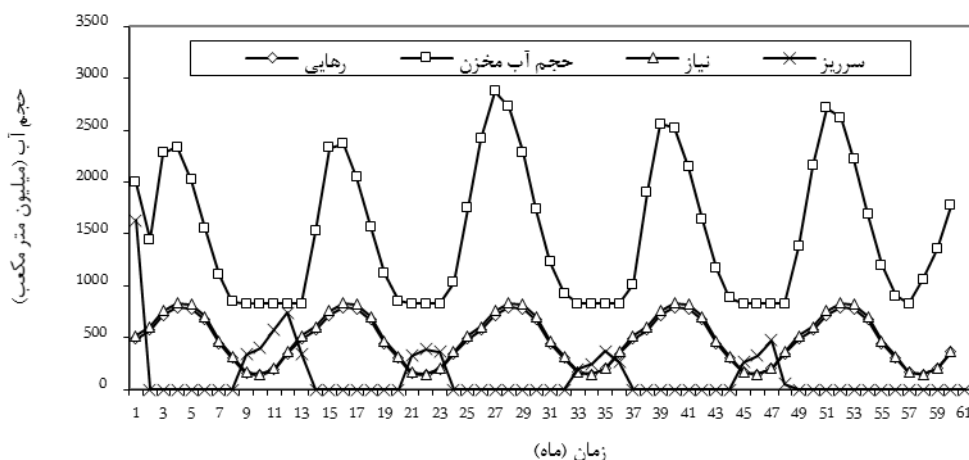
شکل ۱- نمودار تغییرات حجم مخزن در طی دوره بهره‌برداری



شکل ۲- مقایسه تغییرات حجم رهاسازی، سرریز از مخزن، و نیاز پایین دست



نتایج ارائه شده در این قسمت بهترین خروجی مدل در چند تکرار انجام شده می‌باشد. همان‌طور که در شکل ۱ مشخص است، تغییرات حجم ذخیره آب مخزن بین حجم کمینه و بیشینه مخزن قرار دارد. همان‌طور که از شکل ۲ بر می‌آید، این مدل به خوبی می‌تواند نیاز پایین دست را تأمین کند. این نتیجه پس از ۲۴ نسل حاصل شده است، بنابراین GP توانسته است با ۱۲۰۰ (۲۴×۵۰) مرتبه بررسی تابع هدف، شبکه عصبی را به خوبی آموزش داده و تمام قیودات را نیز ارضا گردیده است. شکل ۳ نتایج حاصل از بهره‌برداری با استفاده از برنامه‌ریزی خطی را ارائه می‌دهد.



شکل ۳- نتایج حاصل از بهره‌برداری با استفاده از برنامه‌ریزی خطی

مقایسه نتایج دو مدل نشان می‌دهد که مدل شبکه عصبی استوکستیک می‌تواند به‌عنوان یک گزینه مناسب در اختیار بهره‌برداران قرار گیرد.

##### ۵- نتیجه‌گیری

هرچند فرآیند آموزش (بهینه‌یابی) شبکه عصبی استوکستیک وقت‌گیر می‌باشد، اما پس از آموزش کاربرد آنها بسیار ساده و سریع می‌باشد که بیان‌گر کارایی بالای این مدل می‌باشد. برتری بسیار مهم و متمایز شبکه عصبی استوکستیک، نسبت به شبکه عصبی مصنوعی به‌منظور بهینه‌سازی بهره‌برداری از مخزن، این است که شبکه عصبی را با استفاده از داده‌های تاریخی بهره‌برداری و یا نتایج حاصل از مدل‌هایی هم‌چون برنامه‌ریزی پویا<sup>۱۲</sup> (DP) آموزش داده می‌شود که این امر به دلیل، الزاماً بهینه نبودن داده‌های تاریخی و عدم دقت کافی برنامه‌ریزی پویا به‌علت گسسته‌سازی، موجب وارد شدن خطا به مدل می‌گردد. اما در مدلی که در مطالعه حاضر ارائه گردید، می‌توان مدل را تنها با استفاده از داده‌های آبدی تاریخی و نیاز منطقه آموزش داد، و به‌عنوان یک مدل برای بهره‌برداری در اختیار بهره‌برداران قرار داد.

##### ۶- منابع

منهاج، م. (۱۳۷۹). "مبانی شبکه‌های عصبی"، نشر دانشگاه امیرکبیر، تهران، ایران.

<sup>۱۲</sup> Dynamic Programming

# 4<sup>th</sup> National Conference of Water Crisis in Iran and the Middle East

WATERCONF

www.WaterConf.ir



- Ahmadi, M., Moeini, A., Ahmadi, H., Motamedvaziri, B., and Zehtabian, Gh.-R. (2019). "Comparison of the performance of SWAT, IHACRES and artificial neural networks models in rainfall-runoff simulation (case study: Kan watershed, Iran)", *Physics and Chemistry of the Earth, Parts A/B/C*, 111, 65-77, DOI: 10.1016/j.pce.2019.05.002.
- Aytek A, Asce M and Alp M. 2008. An application of artificial intelligence for rainfall-runoff modeling. *J Earth System Science* 117: 145-155.
- Dubrovin, T., Joima, A., and Turunen, E. 2002. "Fuzzy model for real-time reservoir operation." *J. Water Resour. Plann. Manage.*, 128(1):66-73.
- Deka, P., and Chandramouli, V. \_2005\_. "Fuzzy neural network model for hydrologic flow routing." *J. Hydrol. Eng.*, 10(4), 302-314.
- Fausett, L. 1994. "Fundamental of Neural Networks: Architecture, Algorithms and Applications", Prentice Hall.
- Koza JR, 1992. Genetic programming: On the programming of computers by means of natural selection. Cambridge, MA: MIT Press.
- Sette S, Boullart L, 2001. Genetic programming: principles and applications. *Engineering Applications of Artificial Intelligence* 14: 727-736.
- Zakizadeh, H., Ahmadi, H., Zehtabian, Gh., Moeini, A., and Moghaddamnia, A. (2020). "A novel study of SWAT and ANN models for runoff simulation with application on dataset of metrological stations", *Physics and Chemistry of the Earth, Parts A/B/C*, 120, 102899, DOI: 10.1016/j.pce.2020.102899.