



ارتقاء شبکه عصبی مصنوعی با روش‌های تکاملی برای پیش‌بینی بارش-رواناب حوضه‌های آبریز

پریساسادات آشفته<sup>۱\*</sup> و زهرا شریعت<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، elnazshariat@gmail.com

### چکیده

در بسیاری از مطالعات هیدرولوژیکی، از جمله تخمین اوج جریان، طراحی سازه‌های هیدرولیکی و غیره، مدل‌سازی بارش-رواناب دارای اهمیت است. استفاده از رویکردهای پیشرفته‌ای هم‌چون تلفیق شبکه عصبی مصنوعی<sup>۱</sup> (ANN) با الگوریتم‌های تکاملی می‌توان منجر به بهبود شبکه عصبی در فرآیند مدل‌سازی بارش-رواناب باشد. در تحقیق حاضر ضمن ترکیب الگوریتم پس‌انتشار<sup>۲</sup> (BP) ANN با الگوریتم ژنتیک<sup>۳</sup> (GA) (GA-BP) و ارزیابی عملکرد آن در شبیه‌سازی بارش-رواناب حوضه رودخانه قرقو در آذربایجان شرقی در مقایسه با ANN (BP) از معیارهای عملکرد مانند ریشه میانگین مربعات خطا<sup>۴</sup> (RMSE) و ضریب تعیین<sup>۵</sup> ( $R^2$ ) استفاده شده است. نتایج نشان می‌دهند که مدل GA-BP نسبت به BP با RMSE برابر با ۰/۱۵ عملکرد به نسبت بهتری از BP با RMSE برابر با ۰/۲۵ دارد.

کلمات کلیدی: شبکه عصبی مصنوعی، بارش-رواناب، برنامه‌ریزی ژنتیک

---

<sup>۱</sup> Artificial Neural Network

<sup>۲</sup> Back Propagation Algorithm

<sup>۳</sup> Genetic Algorithm

<sup>۴</sup> Root Mean Square Error

<sup>۵</sup> Coefficient of Determination



## مقدمه

شبکه‌های عصبی بخشی از هوش مصنوعی می‌باشند. هدف از هوش مصنوعی، مدل‌سازی کلی مغز بصورت یک موجودیت واحد است که این کار با ساخت یک مدل کامپیوتری که رفتاری شبیه به مغز را دارا باشد، صورت می‌گیرد. اولین حوزه‌ای که برای مدل‌سازی مغز تلاش می‌کند، بر بخش منطقی (عقلی) عملکردهای مغز تمرکز دارد. براساس روش‌هایی که برپایه منطق ریاضی عمل می‌کنند و به‌طور معمول به شکل مجموعه‌ای از قاعده‌ها می‌باشند، می‌توان سامانه‌های بسیار پیچیده را ایجاد نمود. حوزه دوم مغز بر استفاده از مدل‌های ریاضی اعصاب برای ساخت شبکه‌های عصبی مصنوعی متمرکز است. با مرتب کردن عصب‌ها در شکل‌های مختلف می‌توان عملکردهای مغز را مدل‌سازی نمود. بدین ترتیب شبکه‌های عصبی قادرند توابع پیچیده‌ای که انجام آنها توسط سیستم‌های مبتنی بر قاعده مشکل می‌باشد، یادگیرند. به هر حال شبکه‌های عصبی نیز یک ایراد دارند؛ آنها نمی‌توانند در مورد آنچه انجام می‌دهند دلیل بیاورند. بسیاری از مطالعاتی که امروزه در حال انجام هستند، در جستجوی سامانه‌های ترکیبی هستند که شبکه‌های عصبی (با قابلیت یادگیری) را در جوار سامانه‌های مبتنی بر قاعده (با قابلیت توضیح در مورد آنچه انجام می‌دهند) قرار دهند. زمانی که این دو نوع سامانه بتوانند در کنار یکدیگر کار کنند، آنگاه ماشین‌های خبره را خواهیم داشت.

چن<sup>۶</sup> و همکاران (۲۰۱۳) رویکرد ANN را برای مدل‌سازی بارش-رواناب برای حوضه‌ای در تاپوان به‌کار بردند. حسن‌پور و کاشانی (۲۰۱۴) مدل وُلتر و ANN را برای شبیه‌سازی بارش-رواناب در حوضه رودخانه ناورود (ایران) به‌کار گرفتند. نتایج نشان دادند که ANN از مدل وُلتر بهتر عمل نمود. مَنگ<sup>۷</sup> و همکاران (۲۰۱۵) مدل ANN را برای بهبود پیش‌بینی رواناب در حوضه‌های حوضه هاماجینگ<sup>۸</sup> چین به‌کار گرفتند. صدیقی و همکاران (۲۰۱۶) عملکرد مدل‌های ANN و ماشین بردار پشتیبان<sup>۹</sup> (SVM) برای شبیه‌سازی بارش-رواناب در حوضه رودخانه رودک ایران بررسی نمودند. پونیا و تیواری<sup>۱۰</sup> (۲۰۲۰) یک ANN مبتنی بر مدل بارش-رواناب را برای حوضه هوشنگ‌آباد رودخانه نارمادا<sup>۱۱</sup> در مادهاپا پرادش<sup>۱۲</sup> توسعه دادند. نتایج نشان دادند که ANN‌ها ابزاری لازم برای پیش‌بینی پاسخ‌های هیدرولوژیکی در حوضه‌ها بودند. ویتیارتی<sup>۱۳</sup> و همکاران (۲۰۲۰) روش جدیدی متشکل از آماره‌های اساسی برای ارزیابی حساسیت پارامترهای ANN پیشنهاد دادند. داده‌های بارش و جریان به‌دست‌آمده از حوضه مختلف، برای تحقیق حاضر به‌کار رفت. نتایج نشان دادند که مدل بارش-رواناب آموزش‌دیده توسط الگوریتم لونیبرگ-مارکوآرت<sup>۱۴</sup> (LM) نسبت به مدل‌های آموزش‌دیده شیب نزولی<sup>۱۵</sup> (GD) قوی‌تر عمل نمود. غلامی و ساحور<sup>۱۶</sup> (۲۰۲۲) رویکرد ANN را برای شبیه‌سازی فرآیند بارش-رواناب با استفاده از نمونه‌برداری میدانی در ارتباط با داده‌های بارش و هیدرومتری به‌کار گرفتند.

<sup>۶</sup> Volumetric Reliability

<sup>۷</sup> Meng

<sup>۸</sup> Hamajing

<sup>۹</sup> Support Vector Machine

<sup>۱۰</sup> Poonia and Tiwari

<sup>۱۱</sup> Narmada

<sup>۱۲</sup> Madhya Pradesh

<sup>۱۳</sup> Vidyarthi

<sup>۱۴</sup> Levenberg-Marquardt

<sup>۱۵</sup> Gradient Descent

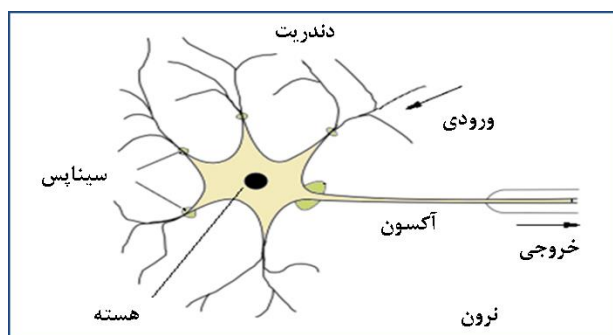


با توجه به تحقیقات انجام‌شده که مواردی از آنها در بخش قبل به آنها اشاره شد، می‌توان به کارایی مدل ANN در زمینه پیش‌بینی و مدل‌سازی فرآیند بارش-رواناب نسبت به سایر مدل‌های آماری از جمله مدل‌های سری زمانی و رگرسیون خطی و غیرخطی معمولی پی برد. در تحقیق حاضر ضمن ترکیب BP با GA (GA-BP) و ارزیابی عملکرد آن در شبیه‌سازی بارش-رواناب حوضه رودخانه قرقو در آذربایجان شرقی در مقایسه با ANN (BP)، از معیارهای عملکرد مانند  $RMSE$  و  $R^2$  استفاده شده است.

## مواد و روش‌ها

### سلول عصبی

مغز به‌عنوان یک سامانه پردازش اطلاعاتی موازی، از حدود  $10^{11}$  نرون به هم مرتبط با تعداد کل  $10^{16}$  ارتباط تشکیل شده است. نرون‌ها ساده‌ترین واحد ساختاری سامانه‌های عصبی هستند. هر بافت عصبی از تعداد زیادی نرون تشکیل شده است که پیام‌ها را از یک قسمت بدن به قسمت دیگر منتقل می‌کنند. پیام‌ها از نوع ایمپالس‌های<sup>۱۷</sup> الکتروشیمیایی هستند. حتی ساده‌ترین کارهای روزمره انسان از قبیل پلک زدن، تنها از همکاری همه جانبه این نرون‌ها میسر است. بیش‌تر نرون‌ها از سه قسمت اساسی بدنه سلول (شامل هسته و قسمت‌های حفاظتی دیگر)، دندربیت، اکسون تشکیل شده‌اند (شکل ۱).



شکل ۱- قسمت‌های مختلف نرون طبیعی

### دسته‌بندی الگوریتم‌های آموزش

الگوریتم‌های آموزش را می‌توان به دو دسته کلی با نظارت و بدون نظارت تقسیم کرد (Error! Reference source not found). در یادگیری با نظارت تعدادی ورودی و خروجی متناظر با آنها به شبکه داده می‌شود. خروجی توسط شبکه محاسبه می‌شود و با خروجی مطلوب مقایسه می‌شود. وزن‌ها متناسب با خطای شبکه اصلاح می‌شوند. این روش یادگیری، یادگیری با معلم نیز نامیده می‌شود. از رایج‌ترین الگوریتم‌های آموزش شبکه‌های عصبی مصنوعی می‌توان الگوریتم انتشار خطا به عقب را نام برد.

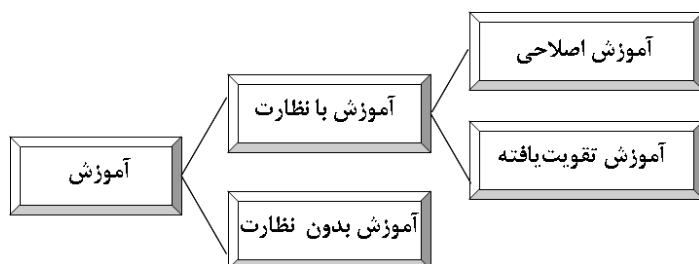
یادگیری بانظارت خود به دو روش "تقویت یافته" و "اصلاحی" تقسیم می‌شود. در روش تقویت یافته، پس از ارائه هر مثال ورودی-خروجی ما تنها می‌دانیم که شبکه خروجی مطلوب را داده است یا خیر. وزن‌ها براساس این اطلاعات به روز می‌شوند. بنابراین تنها بردار ورودی برای اصلاح وزن‌ها استفاده می‌شود.

<sup>۱۶</sup> Gholami and Sahour

<sup>۱۷</sup> Impulse



در روش اصلاحی، بزرگی خطا میزان تصحیح وزن‌ها را معین می‌کند. شیوه آموزش به نحوه اتصالات نرون‌های مصنوعی بستگی دارد. در روش تقویت یافته سیگنال خطای تولیدی بصورت باینری است. در این روش نشان‌دهنده‌ای وجود ندارد که معین کند پاسخ خروجی‌ها در جهت صحیح در حال حرکت است یا اینکه پاسخ خروجی‌ها به چه میزان به پاسخ مطلوب نزدیک است. در دسته دوم الگوریتم‌های آموزش، آموزش بدون نظارت، خروجی هدف وجود ندارد. در خلال آموزش شبکه الگوهی آموزشی خود را از طریق ورودی‌هایش دریافت می‌کند و به شکل دلخواه آن‌ها را تحت طبقه‌های مختلفی دسته‌بندی می‌کند. وقتی شبکه یک ورودی را دریافت می‌کند پاسخی در خروجی ظاهر می‌کند که نشان‌دهنده طبقه‌ای است که آن ورودی به آن تعلق دارد. اگر طبقه‌ای برای این ورودی یافت نشد، آنگاه یک طبقه جدید تشکیل می‌دهد. بطور مثال چند شیء به شخصی داده می‌شود و گفته می‌شود براساس چند ویژگی متمایزکننده آن‌ها از همدیگر، اشیاء را طبقه‌بندی کند. پس از انجام کار به وی شیء دیگری داده می‌شود تا در طبقه‌ای قرار دهد، اگر به هیچکدام از شبکه‌ها تعلق نداشت آنگاه طبقه جدیدی بوجود می‌آید. آموزش بدون نظارت نیاز به معلم ندارد اما برای طبقه‌بندی الگوهای ورودی، نیاز به معیارهایی دارد که معین کند که طبقه‌ها بر چه اساسی تشکیل می‌شوند. اگر معیاری برای طبقه‌بندی وجود نداشته باشد در مورد موفقیت یا عدم موفقیت دسته‌ها نمی‌توان اظهار نظر کرد.




شکل ۲- دسته‌های الگوریتم‌های آموزش


### الگوریتم پس‌انتشار

الگوریتم پس‌انتشار توسط پال ورباس در سال ۱۹۷۴ ارائه شد و بعدها توسط رامل هارت و پارکر به‌طور مستقل کشف گردید. این الگوریتم از زمان پیدایش به‌طور گسترده به‌عنوان یک الگوریتم آموزش در شبکه‌های عصبی پیش‌خور مورد استفاده قرار گرفته است. الگوریتم پس‌انتشار به شبکه‌های عصبی مصنوعی با یک یا چند لایه پنهانی اعمال شده است. براساس این الگوریتم، شبکه، برنامه و طرح ارتباطی توزیع یافته بین لایه‌های خروجی و ورودی را یاد می‌گیرد.

برای استفاده از الگوریتم پس‌انتشار، هر نرون به دو بخش راست و چپ تقسیم می‌شود که به آن B-دیگرام گفته می‌شود (شکل ۳). قسمت راست مقدار تابع اصلی و قسمت چپ مقدار مشتق تابع اصلی ورودی به نرون را محاسبه می‌کند (شکل ۴). برای سادگی در بحث می‌توان تابع جمع را از تابع تبدیل جدا کرد. در قسمت جمع مشتق نسبت به هر کدام از متغیرها تنها ۱ است.



شکل ۳- B- دیاگرام




شکل ۴- تفکیک بخش جمع و تابع تبدیل

• دو نرون سری


شبکه در دو سطح ارزیابی می‌شود؛ در سطح اول، گام پیش‌رو است و اطلاعات از سمت چپ هر نرون وارد می‌شود و مقدار تابع اصلی در سمت راست و مشتق آن در سمت چپ محاسبه و ذخیره می‌شود. نتیجه قسمت راست به نرون‌های متصل در سمت راست منتقل می‌شود. در گام دوم، گام پس‌انتشار، کل شبکه رو به عقب اجرا می‌شود. در این قسمت است که نتایج ذخیره شده در قسمت چپ هر نرون استفاده می‌شود.

در دو نرون سری مشاهده می‌شود. در گام پیش‌رو ترکیب تابع دو نرون حاصل گام پیش‌رو خواهد بود.



شکل ۵- گام پیش‌رو در دو نرون سری


در گام BP ورودی از سمت راست شبکه عدد ثابت ۱ است. اطلاعات آمده به گره در مقدار ذخیره شده در قسمت چپ نرون ضرب می‌شود. حاصل ضرب به نرون بعدی در سمت چپ منتقل می‌شود. جواب نهایی در واقع مشتق تابع بدست آمده در گام پیش‌رو است (شکل ۵). در صورتیکه اتصالات وزن دار باشند، وزن مربوطه در مقدار عبوری ضرب می‌شود. در واقع اتصالات وزن دار در هر دو گام پیش‌رو و پس‌رو به طریق مشابه عمل می‌کنند.




شکل ۶- گام پس‌رو در دو نرون سری

• دو نرون موازی

در حالت دو نرون موازی نیز مانند حالت سری دو گام پیش‌رو و پس‌رو خواهیم داشت. در این حالت مقدار دو تابع با یکدیگر جمع می‌شوند.




شکل ۷- دو نرون موازی در گام پیش‌رو



شکل ۸- دو نرون موازی در گام پس‌رو

• حالت کلی در الگوریتم پس‌انتشار


حال شبکه‌ای با یک ورودی در نظر بگیرید (شکل ۹). در گام پیش‌رو همانطور که گفته شد ورودی  $x$  به شبکه داده می‌شود. مقدار تابع اصلی و مشتق آن در هر گره محاسبه شده و مقادیر مشتق ذخیره می‌شوند. در گام BP نیز ثابت ۱ به نرون خروجی داده می‌شود و شبکه به عقب اجرا می‌شود. در نهایت در قسمت ورودی مشتق تابع شبکه نسبت به  $x$  را خواهیم داشت.



شکل ۹- الگوریتم پس‌انتشار برای شبکه‌ای با n نرون

### یادگیری توسط الگوریتم پس‌انتشار

تا اینجا با الگوریتم پس‌انتشار معرفی شد و نیز مشاهده شد که در مسئله آموزش نیاز به کمینه کردن تابع خطا نسبت به وزن‌های شبکه است. با استفاده از الگوریتم پس‌انتشار می‌توان طی یک پروسه تکراری تابع خطا را کمینه کرد. برای این کار لازم است که با همه وزن‌های شبکه بطور همزمان کار شود. برای استفاده از الگوریتم BP در آموزش شبکه، از شبکه توسعه یافته استفاده می‌شود. در هر مرحله خطاهای شبکه لایه به لایه محاسبه و اصلاح می‌شود.



شکل ۱۰- شبکه توسعه یافته برای یادگیری توسط الگوریتم پس‌انتشار

گام پیش‌رو و پس‌رو اجرا می‌شود. توجه خود را به یکی از وزن‌ها مانند  $W_{ij}$  که وزن اتصال نرون  $i$  به نرون  $j$  است جلب می‌کنیم. خروجی نرون  $i$  از اتصال مربوط به  $W_{ij}$ ،  $O_i$  می‌باشد. در گام BP گرادینت خطا نسبت به  $W_{ij}O_i$  حساب می‌شود. در صورتیکه در گام BP،  $O_i$  به عنوان ثابت در نظر گرفته شود خواهیم داشت:



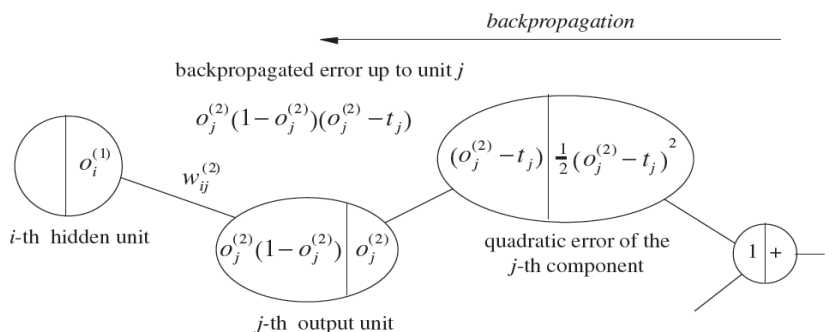
$$\frac{\partial E}{\partial w_{ij}} = o_i \frac{\partial E}{\partial o_i w_{ij}} \quad (1)$$

$$\frac{\partial E}{\partial w_{ij}} = o_i \delta_j \quad (2)$$

$$\Delta w_{ij} = -\gamma o_i \delta_j \quad (3)$$

### طریقه محاسبه خطای BP

برای نشان دادن نحوه محاسبه خطای BP به شکل ۱۱ توجه شود. در این شکل شبکه توسعه یافته برای یک نرون خروجی را نشان می دهد. برای محاسبه خطای پس انتشار ابتدا یک الگوی ورودی-خروجی به شبکه داده می شود و در گام پیش رو اطلاعات در نرون ها ذخیره می شود. سپس گام BP تا لایه خروجی و سپس تا لایه مخفی اجرا می شود. مقدار بدست آمده در گام BP خطای پس انتشار برای وزن  $w_{ij}^{(2)}$  نامیده می شود.



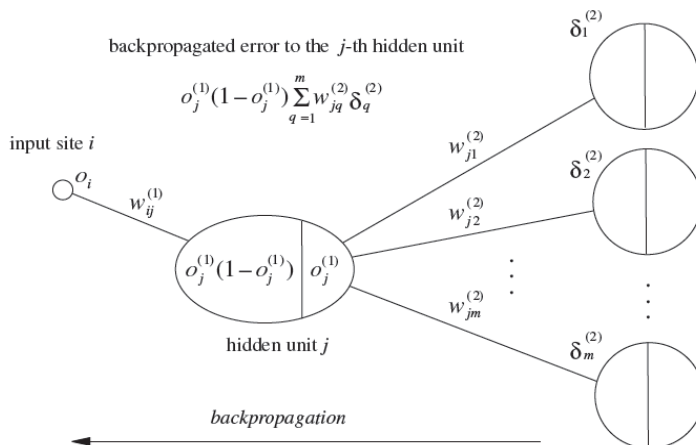
شکل ۱۱- محاسبه خطای BP در حالت یک نرون خروجی

$$\delta_j^{(2)} = o_j^{(2)}(1 - o_j^{(2)})(o_j^{(2)} - t_j) \quad (4)$$

$$\frac{\partial E}{\partial w_{ij}^{(2)}} = [o_j^{(2)}(1 - o_j^{(2)})(o_j^{(2)} - t_j)] o_i^{(1)} = \delta_j^{(2)} o_i^{(1)} \quad (5)$$

در حالت کلی تر که چند نرون خروجی وجود دارد محاسبات به صورت زیر خواهد بود.





شکل ۱۲- حالت کلی محاسبه خطای BP


$$\delta_j^{(1)} = o_j^{(1)}(1 - o_j^{(1)}) \sum_{q=1}^m w_{jq}^{(2)} \delta_q^{(2)} \quad (6)$$

#### مطالعه موردی


رودخانه قرنقو یکی از پرآب‌ترین و مهم‌ترین شعبات رود قزل‌اوزن است که از کوه‌های مرکزی و شرقی کوهستان سهند و کوه‌های اربت‌داغ، آغ‌داغ و هرم‌داغ سرچشمه می‌گیرد و در مسیر غربی - شرقی به سوی شهرستان هشتروود و میانه جریان می‌یابد. برف سنگین کوهستان سهند بزرگ‌ترین منبع آب رودخانه قرانقو است. برای پیش‌بینی رواناب در زمان داده‌شده از داده‌های بارش و رواناب مشاهداتی در بازه‌های زمانی گذشته استفاده شده است.

قرانقو چای حدفاصل بین شهرستان هشتروود و چاراویماق است. دره عمیقی که قرانقوچای در آن جاری است به نام دربند ضحاک معروف است. سد سهند به مختصات ۲۴' ۳۷° شمالی ۵۳' ۴۶° شرقی به‌منظور تأمین آب کشاورزی و شرب منطقه هشتروود بر روی این رودخانه احداث شده است.

از لحاظ تئوری ثابت شده است که در شبکه عصبی، یک لایه مخفی برای تخمین هرگونه تابع پیچیده غیرخطی کافی است )



شکل ۱۳). برای تعیین بردار ورودی و نیز تعداد نرون‌های لایه پنهان از روش سعی و خطا استفاده شده است.



شکل ۱۳- تعیین معماری شبکه عصبی

در راه‌های قراردادی که برای ساختن شبکه عصبی جهت حل مسأله‌ای وجود دارد عموماً معماری خاصی را فرض می‌کند و به‌طور خودکار طرح مناسبی برای داده‌های آزمایشی خاص پیدا نمی‌کند. الگوریتم‌های تکاملی برای تطبیق خودکار معماری شبکه عصبی و وزن‌های آن، متناسب با شرایط مسأله بدون مداخله قابل توجه انسان استفاده می‌شود. در این تحقیق راه‌برد GA با کد کردن اعداد به‌صورت حقیقی و نیز الگوریتم انتشار به عقب BP اتخاذ شده است. عمل‌گرهای ژنتیک با دقت طراحی شده‌اند تا شبکه عصبی را بهینه کرده، از همگرایی نارس و مشکل جاگست جلوگیری کنند.

برای لایه مخفی از تابع تبدیل تانژانت هایپربولیک رابطه (۷) و برای لایه خروجی از تابع تبدیل خطی رابطه (۸) استفاده

شده است.

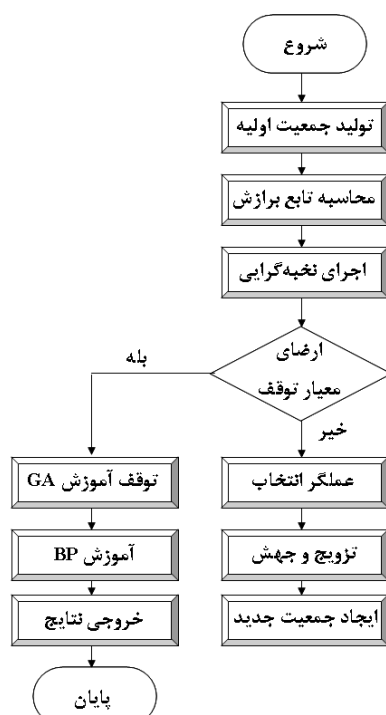


$$X_j = \tanh\left(\sum_{i=1}^n x_i w_{ji} + w_{j0}\right) \quad (7)$$

$$\hat{y} = \sum_{j=1}^m X_j W_{ji} + W_{k0} \quad (8)$$

ترکیب GA و شبکه عصبی برای آموزش شبکه از سه مرحله تشکیل شده است:

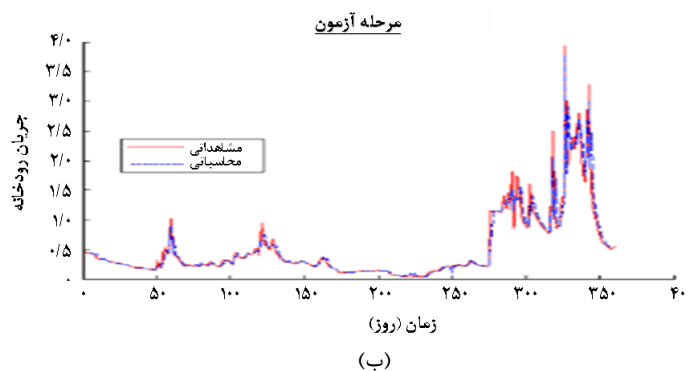

- (۱) انتخاب فرم باینری یا حقیقی برای نشان دادن وزن ها. در این مطالعه از فرم حقیقی برای معرفی هر وزن استفاده شده است.
  - (۲) بررسی مقدار تابع خطا برای هرکروموزوم. ژن های هرکروموزوم وزن های شبکه هستند که باید تعدیل شوند.
  - (۳) اجرای GA. مراحل انتخاب، تزویج و جهش انجام می شوند. فرآیند تکاملی زمانی که مقدار تابع خطا از یک مقدار تعیین شده ای کوچک تر شود متوقف می شود. پس از برقراری شرط توقف توسط BP نیز وزن ها تعدیل نهایی می شوند.
- آموزش شبکه به طور کلی از دو گام تشکیل شده است. ابتدا توسط GA وزن های بهینه یا نزدیک به بهینه پیدا شده و سپس توسط الگوریتم BP وزن های شبکه تعدیل نهایی می شوند. روندنمایی که برای روش GA-BP به کار رفته است به صورت شکل ۱۴ است.



شکل ۱۴- روندنمای روش BP-GA

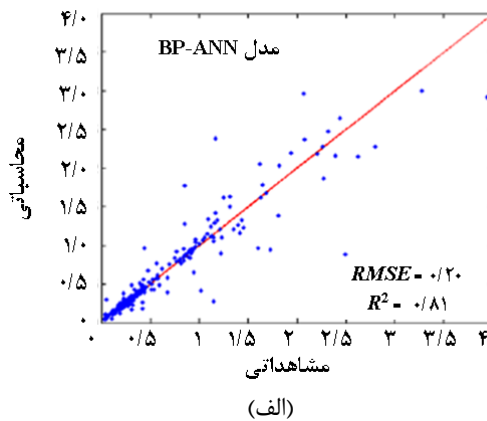
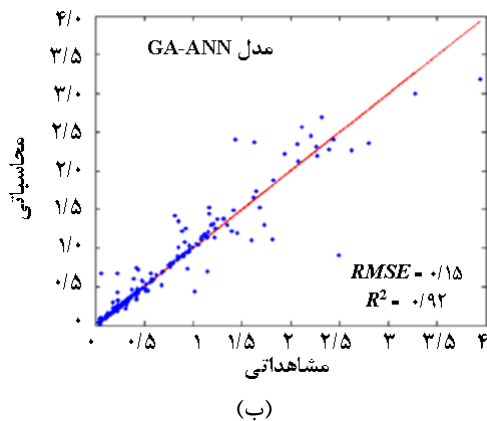
## نتایج

توسط مدل به دست آمده داده های آموزش و آزمون پیش بینی شده اند. نتایج حاصل از این پیش بینی و مقایسه آن با مقادیر مشاهداتی در نمودار زیر مشاهده می شود.



شکل ۱۵- مقایسه داده‌های محاسباتی و مشاهداتی در دو مرحله آموزش و (الف) آزمون و (ب) آزمون

همچنین مدل به دست آمده با حالتی که تنها از BP برای تعدیل وزن‌ها استفاده شده است مقایسه شده است. نتایج این مقایسه در شکل ۱۶ و جدول ۱ آورده شده است.



شکل ۱۶- نمودار مقایسه دو مدل BP (الف) و BP-GA (ب)



معیاری که برای مقایسه مورد استفاده قرار گرفته است، معیار  $RMSE$  می‌باشد. همان‌طور که مشاهده می‌شود مدل GA-BP نتیجه بهتری را داده است.

جدول ۱- مقایسه دو مدل BP و GA-BP

BP		GA-BP	
$R^2$	$RMSE$	$R^2$	$RMSE$
۰/۸۱	۰/۲۵	۰/۹۲	۰/۱۵

### نتیجه‌گیری

شبکه‌های عصبی مصنوعی در برخی موارد کاربرد و کارایی خوبی دارند. لازمه گرفتن نتیجه مطلوب از این مدل، شناخت انواع مختلف و کاربردهای هر کدام از این انواع در جای مناسب خود، متناسب با نوع مسأله است. به‌طور مثال برای پیش‌بینی، مدل MLP کاربرد بیش‌تری دارد، یا به‌صورت جزئی‌تر برای تخمین رگرسیون در لایه‌های مخفی از توابع سیگموئید یا تانژانت هایپربونیک و در لایه خروجی از تابع خطی استفاده می‌شود، در صورتی که برای مسأله طبقه‌بندی در همه لایه‌ها از تابع سیگموئید یا تانژانت هایپربونیک استفاده می‌شود. مسأله مهم بعدی تعیین معماری شبکه است. به‌طور ثنوری ثابت شده است که شبکه‌های عصبی مصنوعی با یک لایه مخفی قادر به حل پیچیده‌ترین توابع غیرخطی هستند. هرچقدر معماری شبکه مورد استفاده ساده‌تر و با اتصالات کم‌تری باشد بهتر بوده، آموزش شبکه سریع‌تر و ساده‌تر خواهد بود. البته ممکن است با افزودن تعداد لایه‌ها شبکه ساده‌تری به‌دست آید، اما الزاماً تعداد لایه‌های بیش‌تر برای حل مسائل پیچیده‌تر بهینه نمی‌باشد. برای به‌دست آوردن معماری مناسب به‌طور معمول از روش سعی و خطا استفاده می‌شود، اما روش‌های تکاملی مانند GA نیز می‌توانند گزینه مناسبی برای حل این مسأله باشند.

### منابع

- Chen, S. M., and Wang, Y. M., and Tsou, I. (2013). "Using artificial neural network approach for modelling rainfall-runoff due to typhoon" *Journal of Earth System Science*, 122, 399-405, Doi: 10.1007/s12040-013-0289-8.
- Gholami, V. AND Sahour, H. (2022). "Simulation of rainfall-runoff process using an artificial neural network (ANN) and field plots data", *Theoretical and Applied Climatolgy*, 147, 87-98, DOI 10.1007/s00704-021-03817-4.
- Hasanpour Kashani, M., Ghorbani, M.A., Dinpashoh, Y. et al. (2014). "Comparison of Volterra model and artificial neural networks for rainfall-runoff simulation", *Natural Resources Research*, 23, 341-354, DOI: 10.1007/s11053-014-9235-y.
- Meng, X., Yin, M., Ning, L. et al. (2015). "A threshold artificial neural network model for improving runoff prediction in a karst watershed", *Environmental Earth Science*, 74, 5039-5048, DOI: 10.1007/s12665-015-4562-9.
- Poonia, V. and Tiwari, H. L. (2020). "Rainfall-runoff modeling for the Hoshangabad Basin of Narmada River using artificial neural network", *Arabian Journal of Geosciences*, 13, 944, DOI: 10.1007/s12517-020-05930-6.
- Sedighi, F., Vafakhah, M., and Javadi, M. R. (2016). "Rainfall-runoff modeling using support vector machine in snow-affected watershed", *Arabian Journal Science and Engineering*, 41, 4065-4076, DOI: 10.1007/s13369-016-2095-5.

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

.....  
**WATERCONF**      [www.WaterConf.ir](http://www.WaterConf.ir)

چهارمین همایش ملی  
راهکارهای پیش روی

**بحران آب**  
**در ایران و**  
**خاورمیانه**



Vidyarthi, V. K., Jain, A., and Chourasiya, S. (2020). "Modeling rainfall-runoff process using artificial neural network with emphasis on parameter sensitivity", Modeling Earth Systems and Environment, 6, 2177–2188, DOI: 10.1007/s40808-020-00833-7.