

## ارزیابی مدل‌های هوشمند عصبی و تجربی در تخمین رواناب سالانه

حمید زارع‌ایبانه<sup>۱\*</sup> - مریم بیات ورکشی<sup>۲</sup>

تاریخ دریافت: ۸۹/۵/۴

تاریخ پذیرش: ۸۹/۹/۲۸

### چکیده

از دیرباز معادله‌های متنوعی برای تعیین رواناب به منظور مدیریت منابع آب توسط پژوهش‌گران ارایه شده که کاربرد گسترده‌ای در علوم هیدرولوژی دارند. در پژوهش حاضر با بهره‌گیری از داده‌های مشاهده‌ای، کاربرد مدل‌های تجربی، شبکه عصبی مصنوعی (ANN) و شبکه عصبی-فازی (CANFIS) در برآورد رواناب بررسی شد. بدین منظور با استفاده از اطلاعات فیزیوگرافی و اقلیمی سه ایستگاه آب‌سنجی پل زمانخان، قلعه شاهرخ و سد زاینده رود واقع در حوضه زاینده‌رود، مقادیر رواناب برآورد شده از مدل‌های تجربی و مدل‌های هوشمند عصبی با مقادیر رواناب سالانه مقایسه گردید. پارامترهای ورودی شامل متوسط بارش سالانه، متوسط دمای هوا، دمای حداقل و حداکثر هوا بود. نتایج نشان داد مدل‌های هوشمند عصبی از دقت مناسبی در برآورد رواناب برخوردار بودند. در بین روش‌های تجربی نیز، روش دی سوزا مناسب تشخیص داده شد. مقایسه شاخص‌های خطاسنجی بین روش‌های برگزیده تجربی با مدل‌های هوشمند عصبی نشان داد میانگین درصد خطای (MPE) در ANN، CANFIS و مدل تجربی دی‌سوزا به ترتیب ۷، ۱۲ و ۴۳ درصد بود که موید اختلاف قابل توجه بین روش‌ها می‌باشد. ضمن آن که ترکیب منطق فازی با شبکه عصبی مصنوعی در قالب مدل CANFIS کارایی لازم را در بهبود نتایج شبکه عصبی مصنوعی نداشت. همچنین نتایج این پژوهش نشان داد با کاهش متغیرهای ورودی از ۴ پارامتر به یک پارامتر بارش، خطای مدل‌سازی به حداکثر مقدار خود (از  $MPE=7\%$  به  $MPE=16\%$ ) می‌رسد. در مقابل ساختار بهینه شبکه عصبی به حذف پارامتر میانگین دمای هوا، حساسیت کمتری (از  $MPE=7\%$  به  $MPE=10\%$ ) نشان داد. بنابراین با توجه به محدودیت اطلاعات مورد نیاز روابط تجربی و دقت بالای مدل‌های هوشمند، کاربرد مدل عصبی قابل توصیه است.

**واژه‌های کلیدی:** برآورد رواناب، روش تجربی، شبکه عصبی مصنوعی، عصبی-فازی، حوضه زاینده‌رود

### مقدمه

روش عمومی برآورد رواناب از بارش است در نواحی کوهستانی با رژیم برفی دارای خطا می‌باشد (۲۱). ادامه تلاش‌ها منجر به ارائه روابط تجربی براساس یک‌سری عوامل اقلیمی و فیزیوگرافی حوضه شد که اغلب محدود به منطقه خاص بوده و ضرایب آن‌ها با توجه به تفاوت شرایط اقلیمی و صرف زمان و هزینه زیاد، بایستی تصحیح گردند (۱۵ و ۲۷). از جمله مطالعات صورت گرفته بدین روش، می‌توان به تحقیق بشول (۱) در حوضه آبخیز دشت نیشابور اشاره داشت. صلواتی و همکاران (۱۳) با استفاده از ۲۶ خصوصیت فیزیوگرافی و اقلیمی، تولید رواناب در حوضه‌های آبخیز استان کردستان را به روش رگرسیون غیرخطی مدل‌سازی نمودند. توکلی و رستمی‌نیا (۴) رواناب ۱۱ ایستگاه هیدرومتری استان ایلام را براساس ۱۴ خصوصیت فیزیوگرافی و بارندگی برای هر یک از زیرحوضه‌ها بررسی و برآورد نمودند. بررسی‌های انجام شده در سایر مناطق جهان نیز مبتنی بر برآورد رواناب از عوامل اقلیمی و فیزیوگرافی حوضه بوده است. لوگان و تانگ (۳۵) با استفاده از پارامتر مساحت، طول آبراهه و متغیر

یکی از نیازهای عمده در طراحی پروژه‌های آبی و خاکی، مقدار رواناب ناشی از بارندگی است که جهت برآورد آن از روش‌های مختلف استفاده می‌شود. اولین مطالعات صورت گرفته برای برآورد مستقیم رواناب از رگبار، در قالب اشکال ترسیمی در مطالعات شرمان (۴۵)، ماکوس (۳۶)، آندروز (۲۴) و آگراسکی (۱۹۵۶) می‌باشد. محققین بعدی با افزایش پارامترهای تاثیرگذار در رواناب، سعی در بهبود دقت نمودارهای ترسیمی داشتند (۳۴). سازمان حفاظت خاک آمریکا<sup>۳</sup> (SCS) نیز به منظور برآورد رواناب در سال ۱۹۷۲ رابطه جامع شماره منحنی<sup>۴</sup> (SCS-CN) را ارائه داد (۲۹). لیکن این روش که

۱-۲ استادیار و دانش‌آموخته کارشناسی ارشد گروه مهندسی آب، دانشکده

کشاورزی، دانشگاه بوعلی‌سینا، همدان

\*- نویسنده مسئول: (Email: zareabyaneh@gmail.com)

3- Soil Conservation Number

4- Curve Number

تحقیقات انجام شده توسط داوسون و ویلی (۲۸)، اچسو و همکاران (۳۱)، مینز و هال (۳۸) و توکار و جانسون (۴۸) با معرفی اطلاعاتی چون بارندگی، دما، تبخیر، مساحت و شیب حوضه به مدل شبکه عصبی مصنوعی، حجم و دبی رواناب در محل خروجی پیش‌بینی شد که نتایج قابل قبولی را در بر داشت. همچنین در تحقیقی دیگر، شبکه عصبی پیش‌خور با ساختار چهار لایه، برای مدل نمودن رواناب با تعداد ۲۲ ورودی مورد بررسی قرار گرفت (۲۳). نتیجه تحقیق رضایی و همکاران (۷) در مدل نمودن رابطه بارش - رواناب، برتری روش شبکه عصبی مصنوعی نسبت به روش رگرسیون چند متغیره گزارش شد. رابطه بارش - رواناب در مطالعات دیگر محققین نظیر شریستا و همکاران (۴۴) و کارآموز و همکاران (۱۷) هم به کمک شبکه‌های عصبی مصنوعی انجام شد. همچنین علاوه بر بکارگیری شبکه عصبی مصنوعی از ترکیب روش‌های عصبی و منطق فازی در زمینه‌های مختلف استفاده شده است که از آن جمله می‌توان به تحقیقات یارار و همکاران (۵۱) در مدل‌سازی تغییرات جریان رودخانه اشاره کرد که برتری مدل ترکیبی عصبی-فازی را نسبت به دو روش شبکه عصبی و SARIMA نشان داد. توران و یوردوسو (۵۰) با بکارگیری تکنیک مدل‌های هوشمند عصبی در تخمین جریان رودخانه، مدل عصبی-فازی را نسبت به دیگر مدل‌های هوشمند عصبی کاراتر دانست.

هدف اصلی این پژوهش انتخاب مدلی با سازگاری مناسب از بین مدل‌های تجربی و دو مدل هوشمند عصبی و عصبی-فازی با سری‌های زمانی رواناب در حوضه زاینده‌رود براساس حداقل داده‌های موجود است. نتایج به‌دست آمده از این پژوهش می‌تواند در توسعه روش مناسب برآورد رواناب در حوضه‌های فاقد ایستگاه آب‌سنجی مورد استفاده قرار گیرد.

## مواد و روش‌ها

### منطقه مورد مطالعه

رودخانه زاینده‌رود به طول حدود ۳۵۰ کیلومتر از رشته کوه‌های زاگرس در غرب ایران به سمت شرق جریان دارد و در انتها به باتلاق گاوخونی که یک نم‌زار طبیعی است ختم می‌شود. متوسط سالیانه دبی عبوری از کلیه ایستگاه‌های آب‌سنجی واقع در امتداد طولی رودخانه ۴۷ مترمکعب در ثانیه می‌باشد. این رودخانه به عنوان بزرگ‌ترین و پرآب‌ترین رودخانه فلات مرکزی ایران در استان اصفهان قرار دارد. جریان جاری در زاینده‌رود حاصل تلاقی چندین شاخه کوچک پرآب به نام‌های چم‌رود، دره زری، دره قاضی، دره خوریه و دره دولت‌آباد است. با بهره‌برداری از تونل اول کوه‌رنگ در سال ۱۳۳۳ حدود ۱۰ مترمکعب در ثانیه و تونل دوم کوه‌رنگ در سال ۱۳۶۵ حدود ۸ مترمکعب در ثانیه به آب زاینده‌رود اضافه گردید (۸). رژیم رودخانه به صورت برفی بارانی است و تغذیه رودخانه در فصل

بارندگی سالانه در ۱۵ حوزه آبخیز نیوزلند، اقدام به برآورد دبی جریان نمودند. در تحقیقی دیگر با استفاده از روش تحلیل رگرسیون خطی چند متغیره بین پارامترهای فیزیکی و اقلیمی حوضه آبخیز، سطح حوضه، معنی‌دارترین متغیر مرتبط با دبی سیلابی در رودخانه‌های ایالت جورجیای<sup>۱</sup> امریکا شناخته شد (۴۷). جباری و عارفی (۵) هم با بکارگیری عوامل شیب و پوشش گیاهی موفق به برآورد رواناب از یک رویداد بارشی در حوضه کبوتر لانه کنگاور شدند. سینغ و همکاران (۴۶) و کادی‌اوغلی و شن (۳۲) سعی در برآورد رواناب از عوامل بارش یا دما به ترتیب در حوضه‌های آبریز سوران<sup>۲</sup> هیمالیا و شهر استانبول داشتند. در حالی که در اندازه‌گیری مستقیم جریان در ایستگاه‌های آب‌سنجی، مشکلاتی از قبیل افزایش یا کاهش سریع سرعت جریان، حمل مقدار زیاد رسوب، بارش‌های رگباری و غیره وجود دارد. محدودیت‌های یاد شده و لزوم تولید آمار و اطلاعات دقیق، موجب بهره‌جویی از روش‌های محاسباتی نرم<sup>۳</sup> یا هوش مصنوعی<sup>۴</sup> با قدرت انعطاف‌پذیری بالا شده است (۷). شبکه‌های هوشمند عصبی ابزار مناسبی برای مدل‌سازی سیستم‌های غیرخطی می‌باشند که توانمندی بالایی در شبیه‌سازی متغیر مجهول براساس تنوع محدود داده‌های ورودی و ناقص و حتی حاوی خطا را دارند (۶، ۹، ۲۸ و ۴۹). از جمله مزیت‌های شبکه هوشمند عصبی، عدم نیاز به تعیین یک تابع خاص برای بیان رابطه میان داده‌های ورودی و خروجی است. ضمن آن که این شبکه‌ها قادر به استخراج حداکثر اطلاعات از داده‌های موجود هستند (۴۳). راجورکار و همکاران (۴۱) از مدل غیرخطی شبکه عصبی مصنوعی برای شبیه‌سازی جریان روزانه در دو حوضه بزرگ مقیاس و کوچک مقیاس استفاده کردند و نشان دادند با تقسیم یک حوضه بزرگ به چند زیر حوضه کوچک، نتایج بهتری حاصل می‌شود. جهانگیر و همکاران (۶) رواناب ناشی از بارندگی در حوضه آبریز کارده واقع در شمال شرقی خراسان رضوی را به کمک مدل شبکه عصبی مصنوعی<sup>۵</sup> (ANN) و مدل آبخشختی<sup>۶</sup> (HEC-HMS) پیش‌بینی نمودند. نتایج آنان حاکی از دقت شبکه عصبی نسبت به مدل HEC-HMS بود. تاکر و مارکوس (۴۹) نیز دقت و سرعت دستیابی به جواب‌های مناسب در شبکه‌های عصبی برای پیش‌بینی رواناب نسبت به مدل مفهومی را گزارش نمودند. پیش‌بینی جریان ماهانه رودخانه صوفی‌چای از ۶ متغیر دمای حداقل، دمای حداکثر، میانگین دما، بارش و دبی توسط نوری و همکاران (۲۰) انجام گرفت. محمدی و همکاران (۱۹) براساس سه پارامتر دما، بارش و زمان وقوع بارش، موفق به پیش‌بینی رواناب با شبکه عصبی مصنوعی شدند. در

- 1- Jourjia
- 2- Sur Un
- 3- Soft Computing
- 4- Artificial Intelligence
- 5- Artificial Neural Network
- 6- Hydrologic Modeling System

### مدل‌های تجربی

بر اساس اطلاعات موجود در منطقه، چندین مدل مختلف تجربی انتخاب گردید. نیاز اطلاعاتی مدل‌ها، مطابق با اندازه‌گیری‌های به‌عمل آمده از سوی شرکت سهامی آب منطقه‌ای بود که امکان مقایسه آن‌ها را میسر می‌ساخت. مدل‌های انتخابی براساس لحاظ عوامل فیزیکی و اقلیمی حوضه آبخیز شامل بارش، کمبود جریان سطحی و مشخصات فیزیوگرافی هر حوضه بود. شکل کلی هر یک از مدل‌ها، در جدول ۱ نمایش داده شده است.

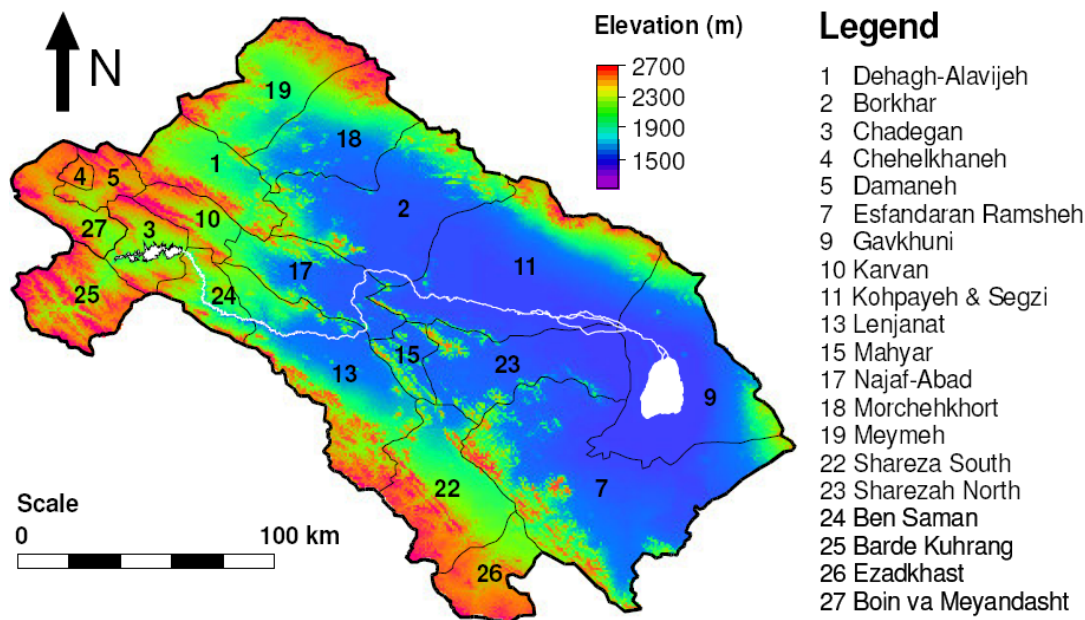
در روابط ارائه شده در جدول ۱،  $R$  = رواناب سالانه (سانتی‌متر)،  $P$  = بارندگی سالانه (سانتی‌متر)،  $T$  = متوسط درجه حرارت سالانه (سانتی‌گراد)،  $F$  = پارامتر مربوط به دوام بارش،  $D$  = کمبود جریان سالانه و  $Z$  = ضریب مربوط به مشخصات فیزیوگرافی حوضه (جدول ۲) است (۱).

مقدار ضرایب پیشنهادی برای روابط لیبسی و سازمان هواشناسی جهانی به ترتیب از جداول ۲ و ۳ قابل دسترسی هستند.

شایان ذکر است به دلیل عدم ثبت برخی پارامترها از سوی شرکت سهامی آب منطقه‌ای و عدم دسترسی به برخی اطلاعات فیزیوگرافی زیر حوضه‌های زاینده‌رود، مدل‌های دیگر مورد استفاده قرار نگرفت. لذا امکان مقایسه آن‌ها در این تحقیق میسر نگردید. همچنین برای بررسی کارایی مدل‌های تجربی در منطقه، اقدام به واسنجی مدل بهینه در قالب آماره‌های خطاسنجی شد.

بهار حاصل ذوب تدریجی برف‌ها می‌باشد. بلندترین نقطه رودخانه در ارتفاعات چادگان با ۲۷۰۰ متر ارتفاع از سطح دریا و پایین‌ترین نقطه در محل خروجی رودخانه (باتلاق گاوخونی) می‌باشد که حدود ۱۵۰۰ متر از سطح دریا بلندتر است (شکل ۱).

از آنجایی که استفاده از داده‌های بلند مدت در دقت نتایج تاثیر دارد به همین دلیل تنها از اطلاعات سه ایستگاه آب‌سنجی قلعه شاهرخ، سد زاینده‌رود و پل زمان‌خان با طول دوره ۳۶-۳۱ ساله استفاده شد. معیار گزینش ایستگاه‌ها، قابلیت دسترسی به آمار رواناب و اطلاعات اقلیمی در یک دوره زمانی بلند مدت بود تا نتایج با اطمینان بیشتری ارائه شود. لازم به ذکر است که به دلیل وجود خطا در بازسازی اطلاعات رواناب، از داده‌های موجود ثبت شده استفاده گردید (ساری صراف و همکاران، ۱۳۸۸). در این مطالعه برای پیش‌بینی رواناب، دو رویکرد مورد استفاده و تحلیل قرار گرفت. در رویکرد اول رواناب در بازه زمانی مدنظر به عنوان تابعی از اطلاعات فیزیوگرافی و اقلیمی در قالب مدل‌های تجربی محاسبه گردید. در رویکرد دوم با در نظر گرفتن ارتباط عوامل اقلیمی با رواناب، مقدار آن به کمک دو ساختار متفاوت از مدل‌های هوشمند عصبی برآورد شد. دلیل اصلی برای استفاده از رویکرد دوم دقت و سرعت دستیابی به جواب با لحاظ حداقل اطلاعات اقلیمی در شرایط ناکافی بودن داده‌های در دسترس بود.



شکل ۱- امتداد طولی رودخانه زاینده‌رود و موقعیت‌های ارتفاعی قسمت‌های مختلف حوضه (گیسگ و همکاران، ۲۰۰۰)

جدول ۱- مدل‌های تجربی مورد استفاده جهت برآورد رواناب

رواناب محاسباتی از	مؤلف	رابطه	ملاحظات
بارندگی	دی‌سوزا	$R = 0.85 p - 30.5$	--
	دپارتمان آبیاری هندوستان	$R = P - 1.17 P^{0.86}$	--
کمبود جریان سطحی	تورک	$R = P - D$	$D = \frac{P}{\sqrt{0.9 + (\frac{P}{LT})^2}}$ $LT = 300 + 25 T + 0.05 T^3$
	کوتاین	$R = P - D$	$D = P - LT \times P^2$ $LT = \frac{1}{0.8 + 0.14 T}$
مشخصات فیزیوگرافی	لیسی	$R = \frac{P}{1 + \frac{304.8}{P} (\frac{F}{Z})}$	نسبت F/Z از جدول پیشنهادی لیسی (جدول ۲)
دما-بارندگی	سازمان هواشناسی جهانی	$LT = 10^{0.027 T + 0.886}$ $T_{\text{mean monthly}} > 0$	برآورد رواناب براساس جدول پیشنهادی WHO (جدول ۳)

جدول ۲- ضرایب پیشنهادی روش لیسی

نوع بارش	نوع اراضی حوضه آبریز		
	کوتاه	متوسط	طولانی
فلات، دشت‌های مسطح با خاک‌های عمیق و پوشش گیاهی مناسب	۲	۴	۶
تا حدودی مسطح با خاک نیمه‌عمیق با پوشش گیاهی مرتعی	۰/۸۳	۱/۶۷	۲/۵
تپه‌های نسبتاً مرتفع با خاک کم‌عمق و پوشش گیاهی نسبتاً ضعیف	۰/۵	۱	۱/۵
اراضی شنی همراه با مقدار زیادی سنگریزه با شیب زیاد در ارتفاعات	۰/۲۳	۰/۵۸	۰/۸۸
اراضی سنگلاخی با ارتفاع و شیب بسیار زیاد و بدون پوشش گیاهی	۰/۱۴	۰/۲۸	۰/۴۳

جدول ۳- نسبت‌های برآورد شده در رابطه با سازمان هواشناسی جهانی

جهانی						
$\frac{P}{LT}$	۱	۷	۸	۱۰	۱۲	۱۴
$\frac{R}{LT}$	۰/۰۲۶	۲/۷	۳/۴	۵	۷	۹
$\frac{P}{LT}$	.	۲	۳	۴	۵	۶
$\frac{R}{LT}$	۰/۰۰۹	۰/۰۷۵	۰/۲	۰/۴۱۵	۱	۱/۹

### تعریف پارامترهای مدل‌های هوشمند

برای ایجاد یک شبکه هوشمند عصبی باید پارامترهای مؤثر ورودی و خروجی مدل به درستی مشخص شوند. در تحقیق حاضر داده‌های مربوط به میزان رواناب سالانه‌ی هر یک از سه ایستگاه آب‌سنجی واقع در امتداد رودخانه زاینده‌رود، به‌عنوان خروجی شبکه هوشمند عصبی بود. برای پیش‌بینی رواناب از متغیرهای بارندگی، دمای حداکثر، حداقل و متوسط هوا در مقیاس سالانه استفاده شد. بارش و دما دو پارامتر اصلی قابل دسترس در هر ایستگاه است که به‌عنوان نیاز اطلاعاتی روابط تجربی نیز محسوب می‌شود (۱). ضمن

آن که عوامل فوق به‌طور گسترده‌ای در دیگر پژوهش‌ها نیز به‌کار گرفته شده‌اند (۱۹، ۲۰ و ۴۲). از طرفی باید توجه داشت که تعدد متغیرهای ورودی نیز می‌تواند سبب پیچیدگی ساختار شبکه و ناپایداری آن گردد و در بعضی موارد همبستگی بالای بین متغیرها هم به منزله استفاده از اطلاعات تکراری است (۲۰). از این رو بر خلاف نظر صلواتی و همکاران (۱۳) که به استفاده هرچه بیشتر متغیرهای مستقل برآورد کننده رواناب اعتقاد دارند، استفاده از روشی ساده با حجم اطلاعاتی کم و دستیابی به جواب در زمان کوتاه‌تر حتی در روش‌های سنتی مورد توجه است (۵). بنابراین با کاهش تعداد متغیرهای ورودی به شرط محفوظ ماندن کارایی مدل، بر ارزش کاربری آن افزوده می‌شود. به‌همین منظور میزان تاثیرگذاری هر یک از ورودی‌ها (متغیرهای مستقل) در تغییرات عامل خروجی (متغیر وابسته) ارزیابی شد. نظر به آن که همه متغیرهای ورودی در شبکه‌های هوشمند عصبی دارای اهمیت یکسان نبوده و مقادیر برخی از آن‌ها توأم با عدم قطعیت و یا عدم رابطه معنی‌داری با متغیر خروجی است لذا تعیین درجه اهمیت اطلاعات ورودی بر خروجی، یکی از مراحل مهم در فرآیند توسعه مدل‌های عصبی می‌باشد (۳۷). برای تعیین میزان اهمیت هر یک از عوامل بر مقدار صحیح خروجی ابتدا ماتریس همبستگی ضرایب در سطح ۵ درصد در نرم‌افزار SPSS

بین میزان تغییرات رواناب‌های محاسباتی و مشاهداتی به عنوان تابع هدف می‌باشد که در صورت یکسان بودن هر دو مقدار، میزان خطای لحظه‌ای طبق رابطه ۱ صفر خواهد بود.

$$j_i(n) = t_i(n) - a_i(n) \quad (1)$$

که در آن،  $j_i(n)$  خطای لحظه‌ای شبکه،  $t_i$  خروجی عنصر نام شبکه در  $n$ امین تکرار،  $a$  خروجی واقعی شبکه در هر تکرار است. با برآورد خطای خروجی و انتشار آن به عقب (به داخل سیستم)، وزن انتخاب شده در مدل اصلاح می‌گردد (۷ و ۲۲). تصحیح وزن‌ها با استفاده از تئوری کاهش شیب<sup>۴</sup> از رابطه زیر انجام می‌شود:

$$W_{ij}(n+1) = w_{ij}(n) + \eta \delta_j(n) x_i(n) \quad (2)$$

که در آن  $w_{ij}(n+1)$  عبارتست از وزن اتصال عنصر  $i$  به عنصر  $j$  در  $n+1$ امین تکرار و  $w_{ij}(n)$  مقدار این وزن در  $n$ امین تکرار است.  $\delta_j(n)$  خطای موضعی که مستقیماً از  $j_i(n)$  در  $n$ امین تکرار محاسبه شده است.  $\eta$  اندازه قدم محاسباتی<sup>۵</sup> است.

برای مدل‌سازی رواناب از شبکه عصبی مصنوعی، توابع محرک (تابع انتقال) مختلفی نظیر سیگموئید و تانژانت هایپربولیک با قوانین آموزش لوبنبرگ مارکوات و مونتوم استفاده گردید (زارع ابیانه و همکاران، ۱۳۸۸). در ساختار عصبی-فازی نیز توابع عضویت زنگوله‌ای و گوسین بکارگرفته شد (۹). کلیه عملیات مدل‌سازی در نرم‌افزار NeuroSolutions تحت ویندوز انجام گرفت. نرم‌افزار فوق قابلیت استانداردسازی اطلاعات ورودی در محدوده صفر و یک را به منظور افزایش سرعت اجرا دارد. این نرم‌افزار نتایج خروجی را به صورت غیراستاندارد (غیرنرمال) در قالب جدول و شکل ارائه می‌دهد. پس از اجرای نرم‌افزار و پایان محاسبات، داده‌ها به صورت غیرنرمال درآمده تا مفهوم فیزیکی آن‌ها قابل مشاهده و مقایسه باشد. در نهایت برای مقایسه نتایج حاصل از مدل‌های تجربی و مدل‌های هوشمند عصبی با مشاهدات انجام شده، از سه پارامتر باقی‌مانده ریشه میانگین مربعات خطا<sup>۶</sup> (RRMSE) و میانگین درصد خطا<sup>۷</sup> خطا<sup>۸</sup> (MPE) و ضریب همبستگی<sup>۸</sup> (r) استفاده شد. معیارهای فوق برای سنجش عملکرد مدل‌های بکارگرفته شده می‌باشند. RRMSE و MPE دو شاخص کمی مناسب در برآورد دقت مدل به صورت تفاضل بین مقادیر واقعی و پیش‌بینی شده و  $r$  نیز بیان‌کننده میزان همبستگی بین مقادیر واقعی و پیش‌بینی است (روابط ۳، ۴ و ۵).

$$RRMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2}}{\frac{1}{n} \sum_{i=1}^n O_i} \quad (3)$$

4- Gradient

5- Step Size

6- Residual Root Mean Square Error

7- Mean Percentage Error

8- Correlation of Coefficient

محاسبه و سپس با اعمال روش حذف متناوب ورودی‌ها اثر تغییر بر فضای خروجی مورد ارزیابی قرار گرفت (۱۶). به عبارت دیگر با حذف هر یک از ۴ پارامتر ورودی، خروجی شبکه نسبت به ساختار اولیه (۴ ورودی)، مقایسه شد.

اطلاعات خام اولیه مورد نیاز در سطح ایستگاه‌های آب‌سنجی لحاظ شده در این مطالعه از شرکت سه‌پامی آب منطقه‌ای اصفهان تهیه گردید. جدول ۴ خلاصه‌ای از میانگین دراز مدت متغیرها را نشان می‌دهد.

در این تحقیق دو مدل هوشمند عصبی شامل شبکه عصبی مصنوعی (ANN) و مدل ترکیبی عصبی-فازی<sup>۱</sup> (CANFIS)، بکار گرفته شد. هر دو شبکه جزء شبکه‌های پیش‌خور<sup>۲</sup> با ناظر محسوب شده که به وسیله الگوریتم انتشار به عقب<sup>۳</sup> آموزش داده می‌شوند. ساختار عصبی طرح شده برای هر دو شبکه از نوع پرسپترون چند لایه است که در عین سادگی به عنوان پرکاربردترین ساختار در مطالعات هیدرولوژیکی می‌باشد (۱۴ و ۲۵). شکل ۲ شماتیکی ساده از شبکه عصبی مصنوعی و عصبی-فازی مورد استفاده را نشان می‌دهد. در هر دو شبکه از چهار بردار ورودی مطابق جدول ۴ و یک بردار هدف استفاده گردید.

برای رسیدن به یک مدل هوشمند عصبی، علاوه بر تعیین ورودی‌های مناسب و مستقل، انجام مرحله‌ای شامل پیش‌پالایش داده‌ها، معماری شبکه، آموزش شبکه و آزمون آن ضرورت دارد. مدل‌های هوشمند عصبی باید توسط داده‌های مناسبی که در برگیرنده ورودی و خروجی می‌باشد آموزش داده شود که به این داده‌ها، داده‌های آموزشی اطلاق می‌گردد که نقش مهمی در یادگیری مدل دارند. در این راستا و به منظور توسعه مدل‌های عصبی و ارزیابی آن‌ها، داده‌های مورد استفاده به صورت تصادفی به دو بخش تقسیم شد. بخش اول شامل ۸۰ درصد داده‌ها برای آموزش شبکه و از باقی‌مانده آن‌ها در ارزیابی عملکرد مدل‌های آموزش یافته و تعیین خطای مدل‌سازی استفاده گردید.

بعد از طراحی ساختار شبکه عصبی، تعداد نرون‌های لایه میانی، با هدف دسترسی به نتایج همگون با داده‌های واقعی و طبیعی، به صورت کاملاً دستی با استفاده از قضاوت مهندسی به روش تصحیح مکرر وزن بین نرون‌ها و محاسبه بهترین برآزش بین رواناب‌های محاسباتی و مشاهداتی انتخاب شد. به این ترتیب تعداد نرون‌ها بین ۱-۲۵ عدد در لایه میانی برای شبکه عصبی در نظر گرفته شد. در طراحی شبکه عصبی-فازی نیز با لحاظ تعداد ۲ تا ۵ تابع عضویت ورودی، به صورت سعی و خطا تعداد بهینه آن انتخاب گردید. اختلاف


1- Co-active Neuro Fuzzy Inference System

2- Feed Forward Network

3- Back Propagation

جدول ۴- میانگین بلندمدت متغیرهای ورودی و خروجی در هر دو ساختار هوشمند عصبی

ایستگاه آب‌سنجی				نماد	متغیر
قلعه شاهرخ سدزاینده رود پل زمان خان					
میانگین					
۳۳۷/۳	۳۶۶	۳۴۹	۳۹۷	$P_{mean}$	میانگین بارش (میلی‌متر)
۱۱/۴۶	۱۲/۹	۱۲/۲	۹/۳	$T_{mean}$	میانگین دما (درجه سلسیوس)
۳/۲۸	۴/۶۱	۴/۷۳	۰/۵۰	$T_{min}$	حداقل دما (درجه سلسیوس)
۱۹/۵۵	۲۰/۹۴	۱۹/۶۳	۱۸/۰۹	$T_{max}$	حداکثر دما (درجه سلسیوس)
۴۴/۶	۴۵/۵	۴۵/۸	۴۲/۴	R	خروجی از شبکه رواناب (سانتی‌متر)



شکل ۲- شماتیکی ساده از شبکه عصبی مصنوعی (ANN) و عصبی-فازی (CANFIS) مورد استفاده

جدول ۵ نشان می‌دهد، دقت روش‌های بکارگرفته شده در هر یک از مدل‌های تجربی متفاوت است که این تفاوت با توجه به اختلاف در ماهیت متغیرهای ورودی برای هر روش (جدول ۱) منطقی است. بر مبنای میانگین معیارهای آماری ارایه شده در جدول ۵، روش دی‌سوزا با ۴۳ درصد خطای برآورد رواناب بهترین و در مقابل روش لیبسی با ۹۳ درصد خطای نامناسب بود. برتری روش دی‌سوزا موید ارتباط قوی بین بارش و رواناب می‌باشد به طوری که وجود دیگر پارامترهای اقلیمی نظیر دما در روابط سازمان جهانی هواشناسی، تورک و کوتاین و مشخصات فیزیوگرافی در رابطه لیبسی توانست دقت نتایج را بهبود بخشد. عدم تناسب روش لیبسی با نتایج واقعی بیان‌گر نقش کمتر مشخصات فیزیوگرافی در برآورد رواناب منطقه مورد مطالعه است. به همین دلیل پارامترهای ورودی شبکه عصبی نیز براساس پارامترهای اقلیمی طراحی گردید. با توجه به لزوم واسنجی مدل‌های تجربی با شرایط منطقه، نسبت به تصحیح ضرایب مدل دی‌سوزا به عنوان مدل بهینه، اقدام و نتایج به صورت آماره‌های خطا سنجی در جدول ۶ آورده شد (۱۵ و ۲۷).

$$MPE = \sum_{i=1}^n \frac{|O_i - P_i|}{O_i} \times 100 \quad (۴)$$

$$r = \frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2 (P_i - \bar{P})^2}} \quad (۵)$$

که در آن  $O_i$  مقدار مشاهده شده رواناب نام (میلی‌متر)،  $P_i$  مقدار برآورد شده رواناب نام (میلی‌متر)،  $\bar{O}$  میانگین مقدار مشاهده شده (میلی‌متر)،  $\bar{P}$  میانگین مقدار برآورد شده (میلی‌متر) و  $n$  تعداد داده‌ها می‌باشد.

## نتایج و بحث

نتایج رواناب برآورد شده از شش مدل تجربی در قالب محاسبات پارامترهای آماری در جدول ۵ آورده شده است.

جدول ۵- مقایسه آماره‌های مدل‌های تجربی در ایستگاه‌های مورد مطالعه

نام ایستگاه	روشن آماره	دی‌سوزا	دپارتمان آبیاری هندوستان	لیسی تورک کوتاین	سازمان جهانی هواشناسی
قلعه شاهرخ	MPE (%)	۲۸/۶۱	۵۳/۱۷	۱۳۶/۲۶	۹۱/۹۰
	RRMSE	۰/۳۳	۰/۵۷	۱/۷۵	۱/۳۷
	r	۰/۷۷	۰/۷۷	۰/۷۸	۰/۸۱
سد زاینده‌رود	MPE (%)	۵۹/۷۲	۷۴/۳۳	۴۱/۵۰	۵۲/۷۱
	RRMSE	۰/۶۴	۰/۷۸	۰/۵۶	۰/۵۸
	r	۰/۴۵	۰/۴۵	۰/۴۲	۰/۳۸
پل زمانخان	MPE (%)	۳۹/۲۱	۵۹/۸۳	۱۰۰/۲۳	۶۲/۷۶
	RRMSE	۰/۴۳	۰/۶۳	۱/۲۵	۰/۹۵
	r	۰/۶۲	۰/۶۲	۰/۶۲	۰/۶۱
میانگین	MPE (%)	۴۲/۵	۶۲/۴۴	۹۲/۶۶	۸۴/۷
	RRMSE	۰/۴۷	۰/۶۶	۱/۱۹	۰/۹۷
	r	۰/۶۱	۰/۶۱	۰/۶۱	۰/۶

ایستگاه پل زمانخان با اصلاح ضرایب مدل دی‌سوزا، میانگین درصد خطا از ۴۲ درصد به ۱۶ درصد کاهش یافت.

پس تعیین مدل تجربی مناسب، مشخصات ساختار بهینه هر یک از مدل‌های ANN و CANFIS با اجرای آرایش‌های مختلف مدل‌های هوشمند عصبی، در جدول ۷ ارائه شده است.

جدول ۷ برتری قانون آموزش مومنتوم و تابع محرک تانژانت در ANN و نیز تعداد دو تابع عضویت از نوع گوسین برای CANFIS را نشان می‌دهد. ساختارهای فوق با ساختارهای بکارگرفته شده در مطالعه بهروزی خزایی و همکاران (۲) و توران و یوردوسو (۵۰) برای شبکه عصبی و مقدم‌نیا و همکاران (۳۹) و سلطانی (۱۱) برای CANFIS هم‌خوانی دارد. با در نظر گرفتن ساختار بهینه مدل‌های هوشمند عصبی، نتایج رواناب برآورد شده از هر دو مدل ANN و CANFIS، در قالب محاسبه پارامترهای آماری در جدول ۸ آورده شده است.

جدول ۶- مقایسه نتایج مدل دی‌سوزا با مدل کالیبره شده آن در ایستگاه‌های مورد مطالعه

ایستگاه	مدل دی-سوزا	MPE (%)	RRMSE	r
قلعه شاهرخ	اولیه	۲۸/۶۱	۰/۳۳	۰/۷۷
	واسنجی	۱۶/۲	۰/۱۷۷	۰/۷۷۳
زاینده رود	اولیه	۵۹/۷۲	۰/۶۴	۰/۴۵
	واسنجی	۱۷/۸۱	۰/۲۲	۰/۴۵۳
پل زمانخان	اولیه	۳۹/۲۱	۰/۴۳	۰/۶۲
	واسنجی	۱۳/۴۵	۰/۱۸	۰/۶۱۷
میانگین	اولیه	۴۲/۵	۰/۴۷	۰/۶۱
	واسنجی	۱۵/۸۲	۰/۱۹۲	۰/۶۱۴

همان‌گونه که در جدول ۶ مشاهده می‌گردد، واسنجی مدل پیشنهادی دی‌سوزا، منجر به بهبود برآورد رواناب شد. اگرچه اختلاف قابل ملاحظه‌ای بین ضریب همبستگی وجود ندارد لیکن اختلاف برای سایر آماره‌های خطاسنجی چشم‌گیر است. به‌طوری‌که در

جدول ۷- مشخصات ساختارهای بهینه هر یک از مدل‌های ANN و CANFIS

نام ایستگاه	مشخصات			نوع شبکه
پل زمانخان	سد زاینده‌رود	قلعه شاهرخ	آرایش مدل	عصبی
۴-۲۱-۱	۴-۴-۱	۴-۲۰-۱	تابع محرک/ قانون آموزشی	عصبی
تانژانت/مومنتوم	تانژانت/لونیبرگ مارکوات	تانژانت/مومنتوم	تعداد تابع عضویت/نوع تابع عضویت ورودی	عصبی فازی
۳/گوسین	۲/زنگوله‌ای	۲/گوسین		



جدول ۸- مقایسه آماره‌های مدل‌های هوشمند عصبی در ایستگاه‌های

مورد مطالعه		
نام	روش	عصبی عصبی - فازی
ایستگاه	آماره	
	MPE (%)	۷/۹۲
۱۲/۰۶		
قلعه شاهرخ	RRMSE	۰/۱۰
۰/۱۳		
	r	۰/۹۳
۰/۸۸		
	MPE (%)	۵/۸۲
۱۲/۶۶		
سد زاینده‌رود	RRMSE	۰/۰۹
۰/۱۶		
	r	۰/۹۴
۰/۷۵		
	MPE (%)	۷/۱۵
۱۰/۸۴		
پل زمانخان	RRMSE	۰/۱۰
۰/۱۶		
	r	۰/۹۱
۰/۷۳		
	MPE (%)	۶/۹۶
۱۱/۸۵		
میانگین	RRMSE	۰/۰۹۷
۰/۱۵		
	r	۰/۹۲
۰/۷۹		

از جدول ۸ این‌گونه استنباط می‌شود که دقت روش‌های عصبی با توجه به ساختار هر یک از مدل‌ها (شکل ۲)، متفاوت است. مقایسه نتایج هر دو مدل هوشمند نشان می‌دهد مدل شبکه عصبی مصنوعی با ۷ درصد خطا، در مقایسه با مدل CANFIS با ۱۲ درصد خطا، برآوردهای مناسب‌تری از رواناب داشته‌اند. بنابراین می‌توان اظهار داشت ترکیب منطق فازی در شبکه عصبی نه تنها سبب بهبود نتایج شبکه عصبی مصنوعی نشد، بلکه خطای آن را به میزان قابل توجهی (حدود ۲ برابر) افزایش داد. در توجیه علت این امر می‌توان به ضریب تغییرات رواناب و کارایی مدل عصبی - فازی در مدل‌سازی متغیر خروجی با ضریب تغییرات بالا اشاره نمود. بررسی‌ها نشان داد ضریب

تغییرات مقادیر رواناب در مطالعه حاضر کم و در حد ۰/۲۵ بود که دسته‌های فازی موجب بهبود نتایج نشد. نتیجه برخی مطالعات نیز موید مطلب فوق می‌باشد به طوری که مطالعه کیسی (۳۳) در برآورد تخیل با ضریب تغییرات بیش از ۰/۶ نشان داد مدل عصبی - فازی بهتر از شبکه عصبی است. مطالعه بازارتسرن و همکاران (۲۶) در برآورد تغییرات سطح آب رودخانه نیز نشان از برتری نسبی شبکه عصبی مصنوعی نسبت به عصبی - فازی داشت. همچنین مقایسه نتایج مدل‌های هوشمند با مدل تجربی دی‌سوزا نشان می‌دهد خطای روش دی‌سوزا حدود ۶ برابر روش شبکه عصبی و دقت مدل عصبی - فازی حدود ۳/۶ برابر مدل دی‌سوزا می‌باشد که موید برتری مدل‌های هوشمند در مقایسه با روابط تجربی می‌باشد. هرچند کالیبره کردن مدل تجربی دی‌سوزا موجب بهبود نتایج شده است، با این حال نتایج مدل‌های هوشمند از قابلیت اطمینان بالاتری برخوردارند.

به‌منظور تعیین نقش عوامل انتخابی در ایجاد رواناب، ضریب همبستگی رواناب با هر یک از عوامل اقلیمی به صورت دوه‌دو در سطح هر ایستگاه محاسبه و در جدول ۹ آورده شد. این جدول میزان همبستگی رواناب با متغیرهای ورودی را در سطح ۰/۰۵ درصد اطمینان نشان می‌دهد.

همان‌گونه که از جدول ۹ مشخص است بیشترین ضریب همبستگی به عوامل رواناب و بارش تعلق دارد. به طوری که بالاترین ضریب همبستگی رواناب با بارش در ایستگاه قلعه شاهرخ معادل ۰/۷۷ با حداکثر مقدار بارندگی و کمترین ضریب در ایستگاه سد زاینده‌رود برابر ۰/۴۵ با حداقل بارندگی بود. بیشتر بودن ضریب همبستگی رواناب با بارش به دلیل ارتباط تنگاتنگ بین هر دو متغیر است. طبق جدول ۹، بیشترین ضریب همبستگی با علامت مثبت به عامل بارش و کمترین ضریب همبستگی توأم با علامت منفی به عوامل مختلف دمایی اختصاص داشت.

وجود ضریب همبستگی کمتر (بدون در نظر گرفتن علامت) برای متغیر ورودی بیان‌گر اثرگذاری کم متغیرها در مقایسه با متغیر بارش است. بنابراین اگرچه تاثیر متغیر دمایی حداکثر در مقایسه با بارش کمتر است ولی قابل اغماض نمی‌باشد زیرا علامت منفی آن به‌عنوان اثرگذاری کاهشی در اندازه رواناب است. به همین دلیل با اجرای روش حذف متناوب بر عوامل بردارهای ورودی در مدل شبکه عصبی به‌عنوان مناسب‌ترین مدل هوشمند در برآورد رواناب (طبق جدول ۸) آماره‌های خطاسنجی برای هر حالت محاسبه و در جدول ۱۰ آورده شد.



جدول ۹- ماتریس همبستگی بین عوامل اقلیمی هر ایستگاه

عامل	ایستگاه	دمای میانگین	دمای حداکثر	دمای حداقل	بارش	رواناب
دمای میانگین	قلعه شاهرخ	۱				
	پل زمانخان	۱				
	سدزایندهرود	۱				
دمای حداکثر	قلعه شاهرخ	۰/۷۴	۱			
	پل زمانخان	۰/۸۲	۱			
	سدزایندهرود	۰/۸۷	۱			
دمای حداقل	قلعه شاهرخ	۰/۸۹	۰/۳۸	۱		
	پل زمانخان	۰/۹۱	۰/۵۲	۱		
	سدزایندهرود	۰/۶۶	۰/۳۶	۱		
بارش	قلعه شاهرخ	-۰/۲۹	-۰/۳۹	-۰/۱۸	۱	
	پل زمانخان	-۰/۴۸	-۰/۳۲	-۰/۴۹	۱	
	سدزایندهرود	-۰/۰۹	-۰/۰۵	-۰/۱	۱	
رواناب	قلعه شاهرخ	-۰/۰۵	-۰/۵۶	-۰/۳۳	۰/۷۷	۱
	پل زمانخان	-۰/۰۷	-۰/۰۸	-۰/۱	۰/۶۲	۱
	سدزایندهرود	-۰/۱	-۰/۱۷	-۰/۰۴	۰/۴۵	۱

جدول ۱۰- مقایسه آماره‌های مدل شبکه عصبی مصنوعی با حذف متناوب عوامل بردار ورودی

نام ایستگاه	آماره	بردار ورودی در شبکه عصبی مصنوعی			
		بارش، دمای میانگین، حداکثر و حداقل	بارش، دمای میانگین، حداکثر و حداقل	بارش، دمای میانگین، حداکثر و حداقل	بارش، دمای میانگین، حداکثر و حداقل
قلعه شاهرخ	MPE (%)	۷/۹۲	۱۵/۶۱	۱۲/۱۳	۱۰/۱۰
	RRMSE	۰/۱۰	۰/۱۹	۰/۱۷	۰/۱۲
	r	۰/۹۳	۰/۵۳	۰/۶۱	۰/۸۳
سد زایندهرود	MPE (%)	۵/۸۲	۱۱/۴	۱۰/۶	۱۱/۴
	RRMSE	۰/۰۹	۰/۱۶	۰/۱۸	۰/۱۹
	r	۰/۹۴	۰/۶۱	۰/۶۰	۰/۵۲
پل زمانخان	MPE (%)	۷/۱۵	۱۱/۱	۹/۲	۱۲/۳۰
	RRMSE	۰/۱۰	۰/۱۸	۰/۱۳	۰/۱۸
	r	۰/۹۱	۰/۴۲	۰/۷۰	۰/۴۲
میانگین	MPE (%)	۶/۹۶	۱۲/۷۱	۱۰/۶۴	۱۱/۲۳
	RRMSE	۰/۰۹۷	۰/۱۸	۰/۱۶	۰/۱۶
	r	۰/۹۲	۰/۵۲	۰/۶۲	۰/۵۹

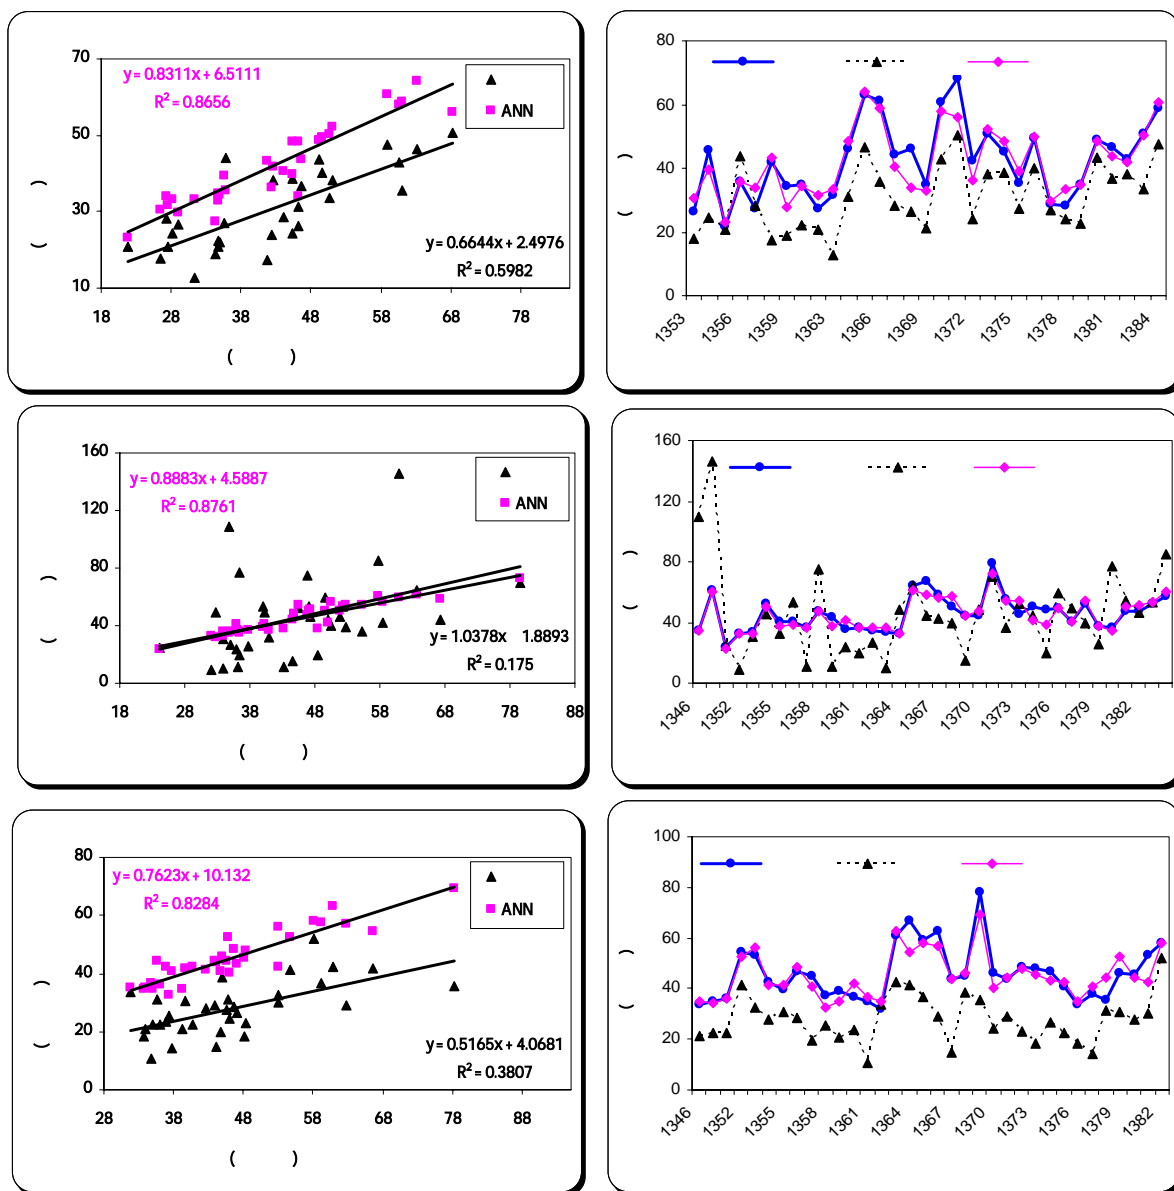
نشان‌دهنده تاثیر کران‌های بالا و پایین دما نسبت به میانگین آن در برآورد رواناب است. در این راستا شایان‌نژاد و همکاران (۱۲) و کوچک‌زاده و بهمنی (۱۶) نیز بر استفاده از کران‌های بالا و پایین دما در سری‌های زمانی تاکید نمودند. در مجموع می‌توان اظهار داشت حذف هر یک از عوامل اقلیمی ضمن کاهش تعداد ورودی به مدل شبکه عصبی لزوماً منجر به بهبود یافتن عملکرد آن نمی‌شود. این

براساس جدول ۱۰، با محدود کردن پارامترهای ورودی اختلاف قابل توجهی بین نتایج حاصل شد. به طوری که با کاهش پارامترهای ورودی از ۴ پارامتر به یک پارامتر اصلی (بارش)، خطای مدل از ۶/۹۶ درصد به ۱۵/۸ درصد افزایش یافت. همچنین نتایج جدول ۱۰ نشان داد که حذف عامل دمای میانگین هوا کمترین تاثیر را در نتایج حاصله دارد به طوری که خطا از ۶/۹۶ درصد به ۹/۸۸ درصد تغییر یافت که

ساختار  $4-n-1$ ،  $n$  تعداد نرون لایه میانی) مقدار رواناب برآورد گردید. مقادیر رواناب برآورد شده از مدل‌های بهینه تجربی و شبکه عصبی مصنوعی برای هر یک از ایستگاه‌ها به صورت رگرسیون خطی در شکل ۳ ارائه شده است. همچنین رواناب برآوردی و اندازه‌گیری به عنوان تابعی از سال‌های مشاهداتی نیز برای هر ایستگاه ترسیم و نتایج با یکدیگر مقایسه شد.

نتیجه بیان‌گر آن است که ادغام و یا حذف عوامل موثر در یک پدیده منجر به افزایش خطا و هر چه بیشتر اختصاصی شدن مدل ساخته شده برای یک ناحیه جغرافیایی خاص خواهد بود (۲۰). ضمن آن‌که جدول ۵ نشان داد مقادیر ضریب همبستگی عوامل انتخابی در مدل‌سازی رواناب یکسان نمی‌باشد که به منزله عدم استفاده از اطلاعات تکراری است (۲۰).

با در نظر گرفتن مدل‌های بهینه تجربی برای هر ایستگاه و استفاده از اطلاعات تعریف شده در بردار ورودی شبکه عصبی با



شکل ۳- مقایسه رواناب برآوردی از شبکه عصبی مصنوعی و روش‌های تجربی بهینه برای هر ایستگاه

حوضه به بارش تحت اثر عوامل فیزیوگرافی و اقلیمی رواناب می‌باشد، در این پژوهش میزان برآورد رواناب از مدل‌های تجربی و هوشمند عصبی بررسی گردید. نتایج نشان داد عملکرد مدل‌های هوشمند مشتمل بر شبکه عصبی مصنوعی و عصبی-فازی با پارامترهای ورودی بارش و دما نسبت به روش‌های تجربی بهتر بود. لیکن ترکیب منطق فازی نتوانست دقت شبکه عصبی را افزایش دهد. به نظر می‌رسد علت مناسب‌تر بودن نتایج شبکه عصبی، دسته‌بندی فازی داده‌ها در شبکه عصبی فازی باشد. زیرا با تقسیم داده‌ها به دو یا چند دسته فازی اثرات چندین کرانه‌های بالا و پایین هر دسته استفاده می‌شود. لیکن در شبکه عصبی ضمن وجود یک کرانه بالا و پایین، به دلیل لحاظ تمامی داده‌ها به صورت یک‌جا، اثرات آن در تمامی مراحل اجرایی تا حصول نتیجه مطلوب باقی می‌ماند. به طور کلی مدل شبکه عصبی مصنوعی از بین سه روش مورد استفاده بهترین نتایج را ارائه داد. ضمن آن که شبکه عصبی براساس اطلاعات زودیافت اقلیمی به عنوان ورودی عمل می‌نماید که اندازه‌گیری و ثبت آن‌ها در مقایسه با اطلاعات فیزیوگرافی حوضه از خطای کمتری برخوردار است. همچنین نتایج این پژوهش نشان داد با کاهش متغیرهای ورودی از ۴ پارامتر بارش، متوسط دمای هوا، حداقل و حداکثر دمای هوا به یک پارامتر بارش، خطای مدل‌سازی به حداکثر مقدار خود می‌رسد. در مقابل ساختار بهینه شبکه عصبی به حذف پارامتر میانگین دمای هوا، حساسیت کمتری نشان داد. از آن‌جا که شبکه عصبی به خطای اطلاعات ورودی حساسیت کمتری دارد، بنابراین استفاده از آن نسبت به مدل‌های تجربی برتری دارد. با توجه به مشخص شدن ساختار بهینه شبکه عصبی، برای سال‌های آتی نیز می‌توان با وارد نمودن داده‌های بارش، متوسط دمای هوا، دمای حداقل و حداکثر هوا، مقدار رواناب را برآورد نمود. طبیعتاً با گذشت زمان و افزایش اطلاعات در دسترس، دقت آن نیز افزایش می‌یابد.

آنالیزهای رگرسیون خطی در شکل ۳ نشان می‌دهد تغییرات رواناب برآوردی را می‌توان از مدل شبکه عصبی با ضریب تعیین ( $R^2$ ) نسبتاً زیاد برآورد نمود. براساس شکل ۳،  $R^2$  برای مدل‌های شبکه عصبی در ایستگاه‌های قلعه شاهرخ، سد زاینده رود و پل زمانخان به ترتیب ۰/۸۶، ۰/۸۷ و ۰/۸۳ است در حالی که این مقدار برای مدل‌های تجربی در ایستگاه‌های فوق به ترتیب ۰/۱۸، ۰/۱۶ و ۰/۳۸ می‌باشد. این شکل ضمن نشان دادن برآوردهای کم مدل تجربی نسبت به مقادیر واقعی، بیان‌گر مناسب‌تر بودن مدل شبکه عصبی است. در بسیاری از تحقیقات، کاربرد روش‌های مختلف تجربی و مدل‌های هوشمند مورد آزمون قرار گرفته است (۳۲ و ۴۶) که از میان آن‌ها، مدل‌های هوشمند عصبی به عنوان مدل مناسب شناخته شده است (۴۱ و ۴۹). از طرف دیگر مدل عصبی پیشنهادی بر مبنای حداقل عوامل اقلیمی (۴ عامل) بود که ضمن سهولت اندازه‌گیری از دقت کافی نیز برخوردار بود. در حالی که برخی محققین به استفاده از تعداد زیادی متغیر مستقل فیزیوگرافی و اقلیمی اعتقاد دارند (۴ و ۱۳). تغییرات زمانی مقدار رواناب برآوردی از مدل شبکه عصبی در این پژوهش طی سال‌های مورد مطالعه نوسان‌های کمتری را نسبت به روش‌های تجربی نشان داد که با توجه به یکنواختی عملکرد مدل‌های هوشمند عصبی طبق نتایج جدول ۸ و ۵ در مقابل مدل‌های تجربی توجیه‌پذیر است. در این راستا کارآموز و همکاران (۱۷) توانمندی شبکه عصبی مصنوعی در کاهش خطای مدل‌سازی جریان ورودی به مخزن سد زاینده‌رود از متغیرهای هواشناسی را گزارش نمودند که با نتایج مطالعه حاضر هم‌خوانی دارد.

## نتیجه‌گیری

فرآیند تبدیل بارش به رواناب بسیار پیچیده است و برهم-کنش‌های زیادی بین اجزای مختلف آن وجود دارد. از آن‌جا که پاسخ

## منابع

- ۱- بشول ر. ۱۳۸۱. کاربرد مدل‌های تجربی جهت برآورد رواناب سالانه رودخانه‌ها در مناطق خشک و نیمه خشک. مجموعه مقالات ششمین سمینار مهندسی رودخانه، دانشگاه شهید چمران اهواز.
- ۲- بهروزی خزایی ن، امیری چایجان ر، توکلی هاشجین ت. و خوش تقاضا م. ۱۳۸۶. بررسی شاخص‌های مهم خشک شدن انگور در روش خشک کردن با جریان هوای گرم به کمک شبکه‌های عصبی مصنوعی. مجله پژوهش کشاورزی. جلد ۷. شماره ۳: ۱۵۴-۱۴۱.
- ۳- بیات ورکشی م، زارع ابیانه ح، معروفی ص، سبزی‌پرور ع.ا. و سلطانی ف. ۱۳۸۸. شبیه‌سازی تخییر تعرق روزانه گیاه مرجع به روش هوش مصنوعی و روش‌های تجربی در مقایسه با اندازه‌گیری‌های لایسیمتری در اقلیم نیمه‌خشک سرد همدان. مجله پژوهش‌های حفاظت آب و خاک. شماره چهارم: ۱۰۰-۷۹.
- ۴- توکلی م. و رستمی نیا م. ۱۳۸۵. ارائه مدل منطقه‌ای سیلاب در حوضه‌های آبخیز استان ایلام. علوم کشاورزی ایران ۲۰ (۲): ۳۴۷-۳۵۶.
- ۵- جباری ا. و عارفی م.ر. ۱۳۸۵. برآورد عمق رواناب حوضه بدون ایستگاه کبوتر لانه کنگاور با استفاده از یک رویداد بارش. فصلنامه مدرس علوم انسانی (ویژه نامه جغرافیا). پاییز. ۴۸-۲۹.

- ۶- جهانگیر ع.ر.، رائینی م. و ضیاتیاراحمدی م. ۱۳۸۷. شبیه‌سازی فرآیند بارش - رواناب با شبکه عصبی مصنوعی (ANN) و مقایسه با مدل HEC-HMS در حوضه معرف کارده. مجله آب و خاک (علوم و صنایع کشاورزی) ۲۲ (۲): ۷۲-۸۴.
- ۷- رضایی ع.، مهدوی م.، لوکس ک.، فیض‌نیا س. و مهدیان م.ح. ۱۳۸۶. مدل‌سازی منطقه‌ای دبی‌های اوج در زیر حوضه‌های آبخیز سد سفیدرود با استفاده از شبکه عصبی مصنوعی. مجله علوم و فنون کشاورزی و منابع طبیعی ۱۱ (۱ الف): ۲۵-۴۰.
- ۸- زارع ایبانه ح.، نوری ح. و نوری ح. ۱۳۸۷. تعیین رابطه باقی‌مانده املاح (شوری) با دبی در رودخانه زاینده رود. سومین کنفرانس مدیریت منابع آب ایران. دانشکده مهندسی عمران، دانشگاه تبریز.
- ۹- زارع ایبانه ح.، قاسمی ع.، بیات ورکشی م.، سبزی‌پرور ع.ا. و محمدی ک. ۱۳۸۸. ارزیابی کارایی دو نرم‌افزار شبکه عصبی مصنوعی در پیش‌بینی تبخیر- تعرق گیاه مرجع. مجله دانش آب و خاک. جلد ۱۹/۱: ۱۶۳-۱۵۱.
- ۱۰- زارع ایبانه ح.، بیات ورکشی م.، معروفی ص. و امیری چایجان ا. ۱۳۸۹. ارزیابی سیستم‌های هوشمند عصبی در کاهش پارامترهای تخمین تبخیر تعرق گیاه مرجع. مجله آب و خاک (علوم و صنایع کشاورزی). ۲۴ (۲): ۳۰۵-۲۹۷.
- ۱۱- سلطانی ف. ۱۳۸۵. بهره‌برداری بهینه کمی - کیفی از مخازن سدها به کمک تلفیق سیستم استنتاج تطبیقی عصبی-فازی و الگوریتم ژنتیک. پایان‌نامه کارشناسی ارشد مهندسی عمران گرایش مهندسی آب. دانشکده مهندسی عمران، دانشگاه تهران.
- ۱۲- شایان‌نژاد م.، ساداتی‌نژاد ج. و فهیمی ه. ۱۳۸۶. تعیین تبخیر و تعرق بالقوه با استفاده از روش رگرسیون فازی. مجله تحقیقات منابع آب ایران، سال سوم. شماره ۳: ۱۹-۹.
- ۱۳- صلواتی ب.، صادقی س.ج. و تلوری ع. ۱۳۸۹. مدل‌سازی تولید رواناب حوضه‌های آبخیز استان کردستان با استفاده از متغیرهای فیزیوگرافی و اقلیمی. آب و خاک (علوم و صنایع کشاورزی). ۲۴ (۱): ۹۶-۸۴.
- ۱۴- صیادی ح.، صدرالدینی ع.، فرسادی‌زاده د. و قربانی م. ۱۳۸۸. شبیه‌سازی هوشمند تغییرات الگوی توزیع آب از آبپاش منفرد در اثر باد. مجله آبیاری و زهکشی ایران. ۱ (۳): ۳۵-۲۵.
- ۱۵- فضل اولی ر.، آخوندعلی م.ع. و بهنیا ع. ۱۳۸۵. تعیین روابط پیش‌بینی رواناب در حوضه‌های آبریز کوهستانی (مطالعه موردی، حوضه‌های آبریز معرف امامه و کسلیان). مجله علوم کشاورزی و منابع طبیعی. ۱۳ (۶): ۱۳-۱.
- ۱۶- قربانی دشتکی ش.، همایی م. و مهدیان م.ح. ۱۳۸۸. برآورد پارامترهای نفوذ آب به خاک با استفاده از شبکه‌های عصبی مصنوعی. مجله آب و خاک (علوم و صنایع کشاورزی). جلد ۲۳، شماره ۱: ۱۹۸-۱۸۵.
- ۱۷- کارآموز م.، عراقی‌نژاد ش. و رضوی س.س. ۱۳۸۳. مدل‌سازی هیدرواقلمی پیش‌بینی جریان ورودی به مخزن: کاربرد شبکه‌های عصبی مصنوعی. مقالات اولین کنفرانس سالانه مدیریت منابع آب ایران. دانشکده فنی دانشگاه تهران.
- ۱۸- کوچک زاده م. و بهمنی ع. ۱۳۸۴. ارزیابی عملکرد شبکه‌های عصبی مصنوعی در کاهش پارامترهای مورد نیاز، جهت برآورد تبخیر و تعرق مرجع. مجله علوم کشاورزی، جلد ۱۱. شماره ۴: ۹۷-۸۷.
- ۱۹- محمدی ی.، فتحی پ.، نجفی‌نژاد ع. و نورا ن. ۱۳۸۷. تخمین دبی متوسط ماهانه با استفاده از شبکه‌های عصبی مصنوعی (مطالعه موردی: آبخیز قشلاق سنندج). مجله علوم کشاورزی و منابع طبیعی. ۱۵ (۴): ۲۶۸-۲۵۸.
- ۲۰- نوری ر.، فرخ‌نیا ا.، مرید س. و ریاحی مدوار ح. ۱۳۸۸. تاثیر پیش‌پردازش متغیرهای ورودی به شبکه عصبی برای پیش‌بینی جریان ماهانه با آنالیز مولفه‌های اصلی و موجک. آب و فاضلاب. ۶۹: ۲۲-۱۳.
- ۲۱- ولی خوجینی ع. ۱۳۷۷. بررسی شماره منحنی (CN) روش SCS در برآورد عمق رواناب و بده اوج در حوضه‌های آبخیز معرف سلسه جبال البرز. پژوهش و سازندگی. ۳۸.
- 22- Abdi H., Valentin D., Edelman B., and O'Toole A.J. 1996. A Widrow-Hoff learning rule for a generalization of the linear auto-associator. J. Mathematical Psychology. 40(2): 175-182.
- 23- Abrahart R.J., See L., and Kneale E. 1999. Using pruning algorithms and genetic algorithms to optimize network architectures and forecasting inputs in a neural network rainfall-runoff model. J. Hydro in format ics. 1: 103-114.
- 24- Andrews R.G. 1954. The use of relative information indices in computing run off (no published). Soil Conservation Service, Fort Worth, Texas.
- 25- Aytak A. 2008. Co-active neurofuzzy inference system for evapotranspiration modeling. Soft

- Computing-A Fusion of Foundations, Methodologies and Applications. 13(7): 691-700.
- 26- Bazartseren B., Hildebrandt G., and Holz K. 2003. Short-term water level prediction using neural networks and neuro-fuzzy approach. *J. Neurocomputing*. 55. 439 – 450.
  - 27- Chow V.T. 1964. *Handbook of Applied Hydrology*, Mc-Graw Hill Book Company, New York, USA, 1418 pp.
  - 28- Dawson C.W., and Wilby R. 1998. An artificial neural network approach to rainfall-runoff modeling. *J. Hydrol. Sci.* 43: 14-66.
  - 29- Dingman S.L. 1994. *Physical Hydrology*; Prenice Hall.
  - 30- Gieske A., Miranzadeh M., and Mamanpoush A. 2000. *Groundwater Chemistry of the Lenjanat District, Esfahan Province, Iran*. IAERI-IWMI Research Reports 4.
  - 31- HSU K., Gupta H.V., and Sorooshian S. 1995. Artificial neural network modeling the rainfall-runoff process. *J. Water Resour. Res.* 31(10): 2517-2530.
  - 32- Kadioglou M., and Sen Z. 2001. Monthly precipitation-runoff polygons and mean coefficients. *Hydrological Sciences Journal*. 46 (1): 3-11.
  - 33- Kisi O. 2006. Daily pan evaporation modelling using a neuro-fuzzy computing technique. *J. Hydrology*. 329: 636– 646.
  - 34- Kohler M.A., and Linsly R.K. 1951. Predicting runoff from storm rainfall. U.S. Weather Bureau, Res. Paper, No. 34.
  - 35- Lawgun N., and Toong A.T. 1985. Regional flood-frequency analysis of small catchments in North Auckland and Coromandel (New Zealand), *J. Hydrology (New Zealand)*. 24(2): 64-76.
  - 36- Mackus V. 1949. Estimation of total (and peak rates of) surface run off for individual storm; Exhibit A of Appendix B., Interim Survey Report, Grand (Neosho) River Watershed, USDA Soil Conservation Service.
  - 37- Maier H.R., and Dandy G.C. 2000. Neural networks for the prediction and forecasting of water resources variables: A review of modeling issues and application. *Environmental modeling and software*. 15: 101-124.
  - 38- Minns A.W., and Hall M.J. 1996. Artificial neural networks as rainfall-runoff models. *J. Hydrol. Sci.* 43(1): 399-417.
  - 39- Moghaddamnia A., Ghafari Gousheh M., Piri J., Amin S., and Han D. 2009. Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques. *Advances in Water Resources*. 32(1): 89-97.
  - 40- Ogrosky H.O. 1956. Service objectives in the field of hydrology. (Unpublished). Soil Conservation Service, Lincoln, Ne.
  - 41- Rajurkar M.P., Kothiyari U.C., and Chube U.C. 2004. Modeling of the daily rainfall-runoff relationship with artificial neural network. *J. Hydrology*, 285: 96-113.
  - 42- Ramirez M., Velho H., and Ferreira N. 2005. Artificial neural network technique for rainfall forecasting applied to the Saõ Paulo region. *J. Hydrology* 301: 146–162.
  - 43- Schap M.G., Leij F.L., and Van Genuchten T.H. 1998. Neural network analysis for hierarchical prediction of soil hydraulic properties. *J. Soil Sci. Soc. Am.* 62: 847-855.
  - 44- Shresta R.R., Theobald S., and Nestmann F. 2005. Simulation of flow in a river system using artificial neural networks. *J. Hydrology and Earth System Sciences*. 9 (4): 313-321.
  - 45- Sherman L.K. 1942. The unit hydrograph method. In: *Physics of the Earth, IX, Hydrology*, O.E. Meinzer, ed. National Research Council, MacGra-Hill, NY.
  - 46- Sing P., Rasatri K.S., Kumar N., and Arora M. 2001. Correlations between discharge and meteorological parameters and runoff forecasting from a highly glacier zed Himalayan basin. *J. Hydrological Sciences*. 45(5): 637-652.
  - 47- Stamy T.C., and Hess G.W. 1993. Techniques for estimating magnitude and frequency of floods in rural basins in Georgia. *Water Resources Investigation Report 93-4016*, USGS Publication, 94 Pp.
  - 48- Tokar S.A., and John Son Pa. 1999. Rainfall-runoff modeling using artificial neural networks. *J. Hydrol. Eng.* 4(3): 232-239.
  - 49- Tokar A.S., and Markus M. 2000. Precipitation runoff modeling using artificial neural network and

- conceptual models. J. Hydrol. Eng. ASCE. 5: 156-161.
- 50- Turan M.E., and Yurdusev A. 2009. River flow estimation from upstream flow records by artificial intelligence methods. J. Hydrology. 369: 71-77.
- 51- Yarar A., Onucyıldız M., and Copty N.K. 2009. Modelling level change in lakes using neuro-fuzzy and artificial neural networks. J. Hydrology. 365: 329-334.

## Evaluation of Artificial Intelligent and Empirical Models in Estimation of Annual Runoff

H. Zare Abyaneh<sup>1\*</sup>- M. Bayat Varkeshi<sup>2</sup>

Received:26-7-2010

Accepted:19-12-2010

### Abstract

From Longley, the various equations for determining the runoff to water management are presented by the researchers that are widely used in hydrologic sciences. In this study by using observational data, was evaluated empirical, artificial neural network (ANN) and ca-active neuro-fuzzy inference system (CANFIS) models in estimation of runoff. For this purpose, by using climatic and physiographic information in three stations of Pole Zamankhan, Ghale Shahrokh and Sade Zayandeh Rood, runoff values were estimated from empirical models and intelligent models were compared to annual runoff values. Input parameters include rain, mean temperature, minimum temperature and maximum temperature. The results showed that the artificial intelligent models had good accuracy in estimating runoff. Among the empirical methods, method of Di Souza was appropriate. Comparison statistical parameters between methods was showed that mean percent error (MPE) in ANN, CANFIS and empirical method was 7, 12 and 43 percent respectively that confirmed differences of between the methods is significant. Also, CANFIS model did not artificial improve ANN results. The results showed, with reduction of input variables from 4 parameters to one parameter of precipitation, modeling error reaches its maximum value (from MPE=7% to MPE=16%). Versus, the optimal structure of ANN had less sensitivity to remove the mean air temperature parameter (from MPE=7% to MPE=10%). Therefore, according to empirical models required information limitations and high accuracy of artificial intelligent models, intelligent models application is recommended.

**Keywords:** Estimation of runoff, Empirical method, ANN, CANFIS, Zayandeh rood Basin

---

1,2- Assistant Professor and Graduate Student, Department of Irrigation and Drainage Engineering, Agriculture Faculty, Bu-Ali Sina University, Hamedan  
(\*-Corresponding Author Email: zareabyaneh@gmail.com)