

## توانایی شبکه عصبی مصنوعی در برآورد جریان رودخانه میناب استان هرمزگان

مریم حیدرزاده<sup>۱</sup>

استادیار گروه مهندسی آب، مجتمع آموزش عالی میناب، دانشگاه هرمزگان، بندرعباس، ایران

### چکیده

پیش‌بینی دقیق پارامترهای مؤثر در طرح‌های منابع آب، یکی از مهمترین مباحث تحقیقی مهندسان آب می‌باشد از جمله این پارامترها دبی رودخانه است. در این مقاله از شبکه عصبی به دو روش شبکه پرسپترون چند لایه (MLP) و با الگوریتم پس انتشار خطا و تابع پایه شعاعی (RBF) و با استفاده از نرم‌افزار متلب و SPSS ۱۹ به منظور تخمین دبی در حوزه آبخیز میناب با استفاده از داده‌های هم‌زمان بارش روزانه و دبی آب روزانه ایستگاه‌های برنطین، گلاشگرد و فاریاب برای یک دوره ۲۵ ساله استفاده شده است. در این تحقیق به منظور بررسی و تعیین بیش‌ترین تاثیر بارندگی هر یک از ایستگاه‌ها بر دبی آب رودخانه میناب، تاثیر ۵ روز متوالی بارش بر دبی را به صورت هر روز جداگانه ( $p_0, p_1, p_2, p_3, p_4, p_5$ ) برای تک تک ایستگاه‌ها و به صورت مشترک، بارش روز اول و دوم الی روز پنجم برای ایستگاه‌هایی که دو به دو مشترک در نظر گرفته شده، انجام شده است. نتایج بدست آمده نشان داد که روش چند لایه پرسپترون (MLP) کمترین خطا (RMSE) و بالاترین همبستگی ( $R^2$ ) بین بارش روزانه در هر سه ایستگاه با دبی اندازه‌گیری شده را نشان داد. همچنین بارش روز اول در ایستگاه‌های زوجی و بارش روز اول و پنجم در ایستگاه‌های منفرد بیشترین تاثیر را در تولید دبی خروجی حوضه دارد.

کلمات کلیدی: شبکه عصبی، برآورد جریان، رودخانه‌ی میناب، شبکه MLP، شبکه RBF

بارش یک عنصر مهم از منابع آبی در تمام نقاط جهان از جمله مناطق خشک و نیمه خشک می‌باشد. بارندگی یکی از پیچیده‌ترین و اتفاقی‌ترین پدیده‌های طبیعی می‌باشد. در واقع تاثیر عوامل محسوس و یا غیر محسوس آنچنان در ایجاد حادثه دخیل است که این روند را از یک نظام قانونمند روشن به سوی یک ساختار پیچیده و آشوبناک سوق داده است (ناصری، ۱۳۸۲). از آنجایی که ایران در اقلیم خشک و نیمه خشک واقع شده است، پیش بینی بارش برای برنامه‌ریزی و مدیریت منابع آب دارای اهمیت است. تصمیم‌گیرنده‌های منابع آب نیاز به پیش‌بینی مطمئنی برای تصمیم‌گیری‌های مدیریتی دارند. در این بین روش‌های پیش‌بینی مختلفی سعی در تعیین ارتباط بین متغیرهای مستقل و وابسته داشته‌اند و مدل‌های مفهومی و آماری زیادی برای پیش‌بینی و پیش‌آگاهی متغیرهای اقلیمی مورد استفاده قرار گرفته است. محققین با اتخاذ شیوه‌های مختلف درصد برآمده‌اند تا نتایج قابل قبولی را در این زمینه برای نقاط مختلف دنیا به دست آورند (صداقت کردار و فتاحی، ۱۳۸۷). مدل و مدل‌سازی یکی از مباحث مهم در علوم است. مبنای فلسفی هر مدلی نمی‌تواند فارغ از دیدگاه محقق باشد، زیرا در واقع مدل نمای ساده‌ای از فهم و درک ما از واقعیت است. از همین رو هر مدلی از پیش زمینه‌های فکری خاصی که متأثر از دیدگاه محقق است پیروی می‌کند (رامشت، ۱۳۸۵). شبکه‌های عصبی مصنوعی یک سیستم پردازشگر اطلاعات تودهای هستند که به صورت موازی قرار گرفته‌اند و عملکردی شبیه شبکه عصبی مغز انسان دارند (Hykin, ۱۹۹۴). شبکه‌های عصبی مصنوعی جزء سیستم‌های دینامیکی می‌باشند که با پردازش داده‌های تجربی قانون نهفته در ورای اطلاعات را به ساختار شبکه منتقل می‌کنند. به همین خاطر آنها را سیستم‌های هوشمند می‌نامند، چرا که بر اساس محاسبات روی داده‌های عددی و یا مثال‌ها، قوانین کلی را فرا می‌گیرند (Jain et al, ۱۹۹۹). بر اساس چگونگی اتصال نرون‌ها در معماری شبکه، شبکه‌های عصبی به شبکه عصبی پیشخور (پیشرو) و شبکه عصبی پسخور<sup>۱</sup> تقسیم‌بندی می‌شوند. در شبکه‌های عصبی پیشخور<sup>۲</sup>، نرون‌ها در لایه‌های متوالی قرار گرفته‌اند و ارتباط آنها یک‌طرفه است و زمانی که یک الگوی ورودی به شبکه اعمال می‌شود، اولین لایه مقادیر خروجی‌اش را محاسبه کرده و در اختیار لایه بعدی قرار می‌دهد. لایه بعدی این مقادیر را به عنوان ورودی دریافت کرده و مقادیر خروجی‌اش را به لایه بعدی منتقل می‌کند. هر نرون به نرون‌های لایه بعدی سیگنال ارسال می‌کند. شبکه‌های پرسپترون چندلایه<sup>۳</sup> جزء این نوع شبکه‌ها می‌باشد (مهناج؛ ۱۳۷۹. بیل و جکسون، ۱۳۸۰). هر نرون بردار ورودی را در وزن‌های خود ضرب کرده و با اریب جمع می‌کند. حاصل این عبارت ورودی خالص به تابع محرکه خواهد شد، که به صورت زیر بیان می‌شود (معادله شماره ۱):

$$net_j = \sum_{j=1}^L w_{ij} x_j + w_0 \quad (1)$$

$net_j$ : ورودی خالص به تابع محرکه،  $w_{ij}$ : ماتریس وزن‌های شبکه،  $x_j$ : بردار ورودی به شبکه،  $w_0$ : بردار بایاس شبکه می‌باشند. تعداد نرون‌ها در لایه پنهان و تعداد لایه‌های پنهان تابعی از نوع اطلاعات و نوع ارتباط آنها با

<sup>1</sup>. Feedback Neural Network

<sup>2</sup>. Feed-Forward Neural Network

<sup>3</sup>. Multi-Layer Perceptrone (MLP)

یکدیگر می باشند، لیکن در مسائل مهندسی آب نتایج تجربی نشان داده است که بهتر است تعداد نرون‌ها در لایه پنهان با تعداد نرون‌ها در لایه ورودی برابر و یا یکی بیشتر باشد (وزارت نیرو، ۱۳۸۶). یکی از وجوه تمایز بین شبکه‌های مختلف متفاوت بودن توابع فعالیت در آنها می‌باشد. تابع محرکه می‌تواند خطی یا غیر خطی باشد. تابع محرکه بر اساس نیاز مساله انتخاب می‌شود. در عمل تعداد محدودی از توابع محرکه، مورد استفاده قرار می‌گیرند. با توجه به شرایط مذکور، از متداول‌ترین توابع فعالیت مورد استفاده که واجد شرایط کامل فوق باشد می‌توان به تابع سیگموئید باینری و سیگموئید دوقطبی اشاره کرد. در روش شبکه عصبی داده‌ها به دو دسته آموزش و آزمایش تقسیم می‌شوند که معمولاً ۷۰ تا ۸۰ درصد داده‌ها برای آموزش و ۲۰ تا ۳۰ درصد داده‌ها برای آزمایش تقسیم می‌شوند. در طی فرآیند یادگیری میزان فراگیری شبکه توسط توابع هدف مرتباً کنترل شده و در نهایت شبکه‌ای مورد پذیرش قرار می‌گیرد که دارای کم‌ترین میزان خطا و بیش‌ترین ضریب همبستگی برازش باشد امروزه شبکه‌های عصبی در زمینه‌های مختلفی از جمله نروفیزولوژی، فیزیک، مهندسی پزشکی، مهندسی الکترونیک، علوم کامپیوتر، صداشناسی، رباتیک، پردازش تصویر، تجارت و غیره کاربرد پیدا کرده است. از اوایل دهه ۹۰، شبکه‌های عصبی به طور موفقیت‌آمیزی در مسائل مختلف هیدرولوژی همچون مدل‌سازی بارندگی-رواناب (Tokra et al, 1999; Shamsedin 1997)؛ پیش‌بینی جریان رودخانه (Tan Den 1999؛ Goswami et al, 2005)؛ مدل‌سازی آب‌های زیرزمینی (Yang . Nayak 2004, 1997)؛ کیفیت آب (Kashefipour et al, 2002, 2005)؛ آب‌شستگی (Azmathullah et al, 2006)؛ پیش‌بینی بارندگی (Grimes et al, 2003)؛ برآورد رسوب (Kuligowski and Barros, 1998؛ Sinha and Gupta, 2000) و غیره به کار برده شده است. در ایران کم‌کم کاربرد شبکه‌های عصبی در مسائل مختلف مهندسی و از جمله علوم آب شناخته شده‌تر می‌شوند. برآورد رسوب (شمسی و همکاران، ۱۳۸۴)، سدهای خاکی (نقی‌زاده بهبهانی و زمردیان، ۱۳۸۴)، تخمین شیب پایدار (کوره‌پزان‌دزفولی، ۱۳۸۴)، تخمین تبخیر و تعرق (پلنگی و همکاران، ۱۳۸۵) و همچنین پیش‌بینی جریان رودخانه‌ها و شبیه‌سازی فرایند بارش-رواناب (جهانگیر و همکاران، ۱۳۸۷؛ شریفی و همکاران، ۱۳۸۴؛ عراقی‌نژاد و کارآموز، ۱۳۹۴؛ یزدانی و چاوشی، ۱۳۸۴) از جمله مسائلی هستند که اخیراً مورد توجه قرار گرفته‌اند.

### شبکه پرسپترون چند لایه (MLP)

در این شبکه نرون‌های هر لایه تماماً به نرون‌های لایه قبلی متصل شده‌اند. خروجی هر لایه پس از تأثیر گذاشتن تابع محرک، ورودی لایه بعدی می‌گردد و این روند تا بدست آمدن خروجی شبکه ادامه می‌یابد (مهنج، ۱۳۷۹). تابع تحریک بکار رفته جهت شبکه MLP، تابع زیگموئیدی است.

### شبکه تابع پایه شعاعی

شبکه‌های تابع پایه شعاعی<sup>۱</sup> از جمله شبکه‌های پیشرو با سه لایه می باشند. تفاوت عمده این شبکه با شبکه‌های پرسپترون چند لایه در این است که دارای یک لایه میانی بوده و توابع تحریک نرون‌ها بصورت توابع شعاعی بصورت توابع گوسی<sup>۲</sup> همراه با مرکز و عرض خاصی می باشد. در اینجا فاصله بین هر الگو با بردار مرکز هر نرون در لایه میانی

<sup>1</sup> .Radial Basis Funtion

<sup>2</sup> .Gussian Function

بعنوان ورودی تابع تحریک شعاعی محاسبه می‌شود. از تفاوت‌های دیگر این شبکه با شبکه پرسپترون چند لایه این است که توابع تحریک نرون‌های خروجی این شبکه توابع خطی ساده است و به همین دلیل می‌توان از الگوریتم‌های بهینه‌سازی خطی استفاده نمود که هم سرعت پردازش را بالا خواهد برد و هم از افتادن در چاله‌های موضعی که در اکثر شبکه‌های پرسپترون چند لایه در روند یادگیری با آن سر و کار دارند، جلوگیری می‌شود (منتظر و همکاران، ۱۳۸۱). تعداد داده به کار رفته برای این منظور ۸۷۶۷ عدد بوده که از ۷۰ درصد داده‌ها برای آموزش و از ۳۰ درصد داده‌ها برای آزمایش استفاده شد. مطالعات ذاکر مشفق و همکاران، ۲۰۰۴، Kisi، ۱۹۹۹ و همچنین Dawson و Wilby، ۱۹۹۸، بر روی جریان‌ات رودخانه‌ای حاکی از آنست که با کاربرد روش شبکه عصبی مصنوعی می‌توان دبی عبوری از رودخانه را با دقت قابل قبولی برآورد نمود. در نهایت به منظور ارزیابی و مقایسه دقت روش‌ها و مدل‌های بکار برده شده در پیش‌بینی دبی از معیارهای ریشه میانگین مربعات خطا<sup>۲</sup> و ضریب همبستگی<sup>۲</sup> (جهانگیر و همکاران، ۱۳۸۷، ولی و همکاران، ۱۳۹۰، Dawson و Wilby، ۲۰۰۱، Abrahart و See، ۲۰۰۷، Solaimani، ۲۰۰۹، Kalteh، ۲۰۰۸) استفاده شده است. با کاربرد این روش‌ها بهترین مدل جهت پیش‌بینی دبی شناسایی خواهد شد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q_{obs} - Q_{est})^2}{n}} \quad (۲)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (Q_{obs} - Q_{est})^2}{\sum_{i=1}^n (Q_{obs} - \bar{Q}_{obs})^2} \quad (۳)$$

در رابطه بالا  $X_{obs}$  و  $X_{est}$  به ترتیب مقدار مشاهده‌ای و برآورد شده دبی،  $\bar{X}_{obs}$  میانگین مقدار مشاهده‌ای دبی و  $n$  تعداد کل داده‌ها است.

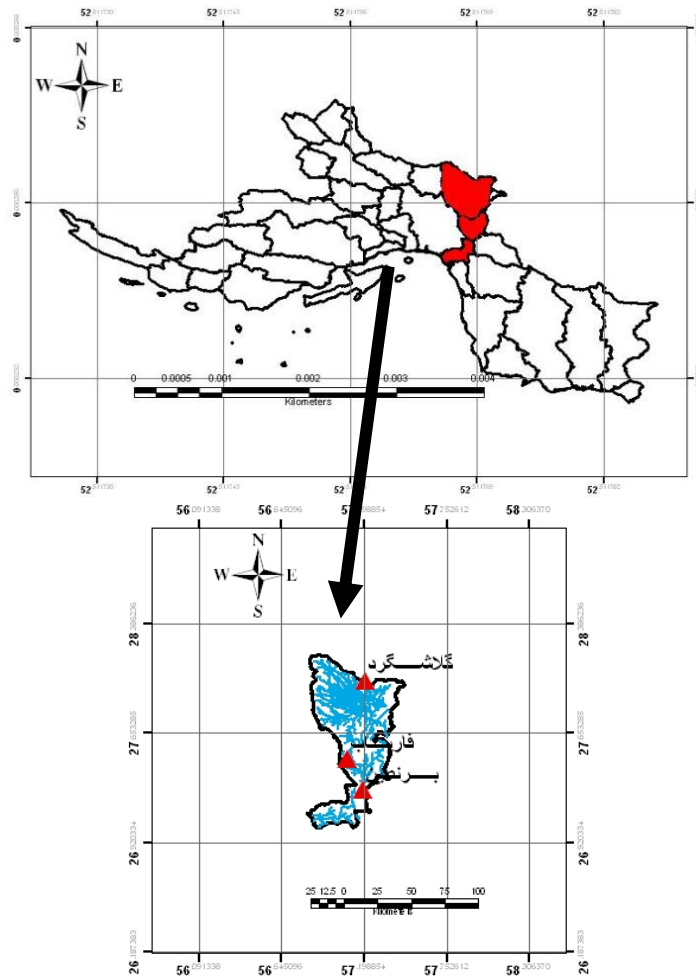
#### مواد و روش کار

##### منطقه مورد مطالعه

منطقه مورد مطالعه، حوزه آبخیز میناب بوده که در بین طول‌های ۵۶° ۴۸' تا ۵۷° ۱۵' شرقی و عرض‌های ۲۳° ۱' تا ۲۷° ۲۷' شمالی واقع شده، وسعت کل آن ۲۱۱/۶۵۶ کیلومتر مربع است. رودخانه اصلی آن میناب بوده که سرشاخه‌های آن از ارتفاعاتی همچون رودان، منوجان، مسافرآباد، فاریاب، گلاشگرد و غیره سرچشمه می‌گیرند. رودخانه میناب یکی از مهم‌ترین رودهای اصلی استان هرمزگان بوده و در تامین منابع آب شرب و کشاورزی نقش بسزایی دارد (شرکت آب منطقه‌ای استان هرمزگان، ۱۳۸۹). (شکل ۱).

<sup>۱</sup> .Local Minimum

<sup>۲</sup> . RMSE



شکل: موقعیت حوزه آبخیز میناب در استان هرمزگان (منبع: نویسنده)

### روش کار:

به منظور انجام این تحقیق از داده‌های بارش و دبی روزانه سه ایستگاه موجود در حوزه آبخیز میناب در یک دوره مشترک ۲۵ ساله (۱۳۷۳-۱۳۹۷) استفاده شده است. در جدول شماره ۱ لیست ایستگاه‌های مورد استفاده در این تحقیق آورده شده است.

جدول شماره ۱: ایستگاه‌های موجود در حوزه آبخیز میناب

نام ایستگاه	نوع ایستگاه	مختصات ایستگاه	
		طول جغرافیایی	عرض جغرافیایی
برنظین	هیدرومتری	57-11-29	7-16-21۲
گلاشگرد	تبخیرسنجی	۵۷-۱۲-۰۰	۲۸-۲-۰۰
فاریاب	تبخیرسنجی	57-05-15	27-28-52

(منبع: نویسنده)

بدین منظور، در ابتدا آزمون همگنی داده‌ها در نرم افزار متلب و SPSS ۱۹ محاسبه شده است. آزمون گردش حول میانگین یا «ران تست»<sup>۱</sup> یکی از متداول‌ترین آزمونهای غیرنموداری مورد استفاده برای تایید همگنی داده‌هاست (مجرد قره باغ، ۱۳۷۶). سپس به بررسی ارتباط بین پارامترهای بارش و دبی رودخانه در طول دوره آماری پرداخته شده است. از آنجا که متداول‌ترین روش در ارزیابی ارتباط بین بارش و دبی بررسی همبستگی بین آنها می

<sup>1</sup>. Run Test

باشد(خسروی و شکیبا، ۱۳۸۹)، لذا از روش ضریب همبستگی و رگرسیونی در نرم افزار SPSS۱۹ به بررسی این ارتباط پرداخته شده است. در جدول شماره ۲ نشان داده شده که بیش‌ترین همبستگی بین کدام ایستگاه‌ها و دبی مشاهده‌ای وجود دارد.

جدول شماره ۲: میزان همبستگی ایستگاه‌های مورد استفاده در تحقیق

ایستگاه تبخیرسنجی - ایستگاه هیدرومتری	ضریب (درصد)
برنطین - برنطین	۹۹
گلاشگرد - برنطین	۹۳
فاریاب - برنطین	۹۹

(منبع: نویسنده)

به منظور بررسی شدت تاثیر بارندگی در چند روز متوالی بر میزان دبی ایجاد شده در رودخانه میناب، از داده‌های بارش پنج روز متوالی در ایستگاه‌های مختلف استفاده شده است (Birikundavy et al, 2002). بدین صورت که شدت تاثیر بارش هر روز بصورت جداگانه و تاثیر بارندگی در ۲ ایستگاه به صورت دو به دو بر میزان دبی ایجاد شده به دو روش مختلف شبکه عصبی RBF و MLP بررسی شده و نتایج نهایی با یکدیگر مقایسه می‌گردد. این عمل برای ۵ روز بارندگی در تمام ایستگاه‌ها انجام می‌شود و نهایتاً بهترین نتایج از طریق معیارهای ریشه میانگین مربعات خطا و ضریب همبستگی مشخص گردید (خسروی و همکاران، ۱۳۹۱).

### نتایج و بحث

درآموز شبکه پرسپترون الگوی یادگیری بعد از تعداد 10000 سیکل با روند ثابتی ادامه م ییابد، و این مقادیر جهت RMSE و همچنین میزان خطای آموزش شبکه پرسپترون انتخاب شدند. پس از آموزش ساختارهای مختلف شبکه با آرایش های مختلف نرونی، ساختار دو لایه با 9 گره در لایه میانی اول و 10 گره در لایه میانی دوم بعنوان شبکه برتر انتخاب شد. با توجه به اینکه شبکه عصبی احتیاج به تعدادی گره در لایه‌ی ورودی، تعدادی گره در لایه‌های مخفی و یک نرون در لایه‌ی خروجی دارد، براساس آمار موجود تعداد ۲ تا ۴ نرون در ورودی، تعداد ۱۲ تا ۱۸ نرون در هر لایه‌ی مخفی و یک نرون برای لایه‌ی خروجی بر اساس دبی اولیه تعیین شده است. مینس و هال (۱۹۹۶) با بررسی شبکه عصبی در مرحله آموزش و استفاده از یک و دو لایه پنهان پیشنهاد کردند که، گرچه به ازای تعداد لایه‌های پنهان بیشتر در اجرای شبکه بهبودی حاصل می‌شود ولی محاسبات اضافی برای تعیین درجه اهمیت آن توجه پذیر نخواهد بود. با توجه به روش کار ذکر شده نتایج بدست‌آمده برای هر یک از ایستگاه‌های برنطین، فاریاب و گلاشگرد، در جدول ۳ نشان‌داده شده‌است. همچنین نتایج حاصل از مقایسه دو روش شبکه پرسپترون چند لایه (MLP) و شبکه تابع پایه شعاعی (RBF) در ایستگاه‌های مورد مطالعه به صورت دو به دو در جدول ۴ نشان داده شده‌است.

جدول شماره ۳: نتایج شبکه عصبی به روش MLP و RBF ایستگاه برنطین، فاریاب و گلاشگرد

		متغیرهای ورودی							
		P-5	P-4	P-3	P-2	P-1	P		
برنطین	RMSE	۰.۵۹	۰.۵۸	۰.۵۸	۰.۵۸	۰.۵۹	۰.۵۴	MLP	
	R	۰.۹۴	۰.۸۸	۰.۹۳	۰.۹۲	۰.۹۱	۰.۹۴		
فاریاب	RMSE	۰.۵۸	۰.۵۸	۰.۵۸	۰.۵۸	۰.۵۷	۰.۵۲	RBF	
	R	۰.۹۳	۰.۵۹	۰.۹۳	۰.۹۴	۰.۸۶	۰.۹۴		

۰.۷۳	۰.۱۶	۰.۵۷	۰.۵۸	۰.۵۷	۰.۵۴	RMSE	MLP	فاریاب
						R		
۰.۲	۰.۹۵	۰.۹۴	۰.۹۴	۰.۹۴	۰.۹۱	RMSE	RBF	
						R		
۰.۷۳	۰.۵۹	۰.۵۳	۰.۵۷	۰.۵۷	۰.۵۳	RMSE	MLP	گلاشگرد
						R		
۰.۲	۱.۵۸	۰.۹۳	۰.۹۳	۰.۹۳	۰.۹۳	RMSE	RBF	
						R		
۰.۱۵	۰.۱۸	۰.۵۷	۰.۵۹	۰.۵۷	۰.۵۵	RMSE	MLP	گلاشگرد
						R		
۰.۹۵	۰.۸۹	۰.۹۱	۰.۷۲	۰.۹۱	۰.۹۲	RMSE	RBF	
						R		
۰.۲۳	۰.۶۰	۰.۶۱	۰.۵۷	۰.۵۷	۰.۵۴	RMSE	MLP	گلاشگرد
						R		
۰.۹۳	۰.۵۸	۰.۹۲	۰.۹۲	۰.۹۱	۰.۹۰	RMSE	RBF	
						R		

P: بارش همان روز، p-1: بارش یک روز قبل، p-2: بارش دو روز قبل، p-3: بارش سه روز قبل، p-4: بارش چهار روز قبل، p-5: بارش پنج روز قبل. (منبع: نویسنده)

با توجه به جدول ۳ ایستگاه برنطین با کمترین مقدار ریشه میانگین مربعات خطا در روش های MLP و RBF با ۰/۵۴ و ۰/۵۲ و بالاترین میزان ضریب همبستگی به میزان ۰/۹۴ بیشترین همبستگی را با بارش روز اول در هر دو روش از خود نشان داده است. ایستگاه فاریاب در روش MLP بهترین نتیجه دبی تولیدی را با بارش چهار روز قبل (RMSE و R به ترتیب، ۰/۱۶ و ۰/۵۹) و در روش RBF دبی با بارش روز اول (RMSE و R به ترتیب، ۰/۵۳ و ۱/۵۸) از خود نشان داده است. و نهایتاً ایستگاه گلاشگرد بالاترین همبستگی را در هر دو روش با بارش ۵ روز قبل داشته است. یکی از دلایل این موضوع احتمالاً مربوط به فاصله مکانی ایستگاه گلاشگرد نسبت به خروجی حوضه است، زیرا بیشترین مسافت را نسبت به ایستگاه هیدرومتری دارد.

جدول شماره ۴: نتایج شبکه عصبی به روش MLP و RBF به صورت دو به دو در ایستگاه‌های مورد مطالعه

P-5	P-4	P-3	P-2	P-1	P	متغیرهای ورودی	
۰/۰۸۷	۰/۰۸۹	۰/۱۰۷۳	۰/۲۸۵	۰/۰۸۵	۰/۰۷۲۳	RMSE	MLP
						R	
۱/۰۷۱	۰/۵۰۶۱	۰/۹۴۶	۱/۰۰۲	۰/۶۱۴	۱/۱۳۵	RMSE	RBF
						R	برنطین و گلاشگرد
۰/۱۰۵	۰/۱۰۸	۰/۱۰۷۳	۰/۱۰۷۳	۰/۱۰۷	۰/۰۹۴	RMSE	MLP
						R	
۰/۹۴۵	۰/۹۴۶	۰/۹۴۶	۰/۶۷۶	۰/۹۵۵	۰/۹۵	RMSE	RBF
						R	برنطین و فاریاب
۰/۰۶۲	۰/۰۶۳	۰/۰۸۱	۲/۵۷۱	۰/۰۷۷	۰/۰۶۵	RMSE	MLP
						R	
۱/۴۲	۱/۰۳۴	۱/۰۰۵	۰/۸۵۴۸	۱/۱۳۵	۰/۹۶۹	RMSE	RBF
						R	برنطین و فاریاب
۰/۱۰۶۶	۰/۱۰۷۷	۰/۰۷۴	۰/۱۰۶۵	۰/۱۰۲۷	۰/۰۹۳	RMSE	MLP
						R	
۰/۹۴۷	۰/۹۵۷	۰/۹۴۹	۰/۹۴۹۸	۰/۹۴۷	۰/۹۴۷۴	RMSE	RBF
						R	گلاشگرد و فاریاب
۰/۰۷۶	۰/۰۸۶	۰/۰۷۳	۰/۱۰۹	۰/۰۷۲	۰/۰۶۱۷	RMSE	MLP
						R	
۱/۱۷۸	۱/۱۳۴	۰/۷۴۴	۰/۹۴۷۶	۰/۵۸۵	۱/۱۹۰۸	RMSE	RBF
						R	گلاشگرد و فاریاب
۰/۱۰۶	۰/۱۰۸	۰/۰۷۷	۰/۱۰۹	۰/۱۰۴۵	۰/۰۸۷۵	RMSE	MLP
						R	
۰/۹۴۶۲	۰/۹۴۸۵	۰/۹۴۶	۰/۹۴۷۲	۰/۹۴۸۵	۰/۹۴۵۳	RMSE	RBF
						R	گلاشگرد و فاریاب

P: بارش همان روز، p-1: بارش یک روز قبل، p-2: بارش دو روز قبل، p-3: بارش سه روز قبل، p-4: بارش چهار روز قبل، p-5: بارش پنج روز قبل. (منبع: نویسنده)

طبق جدول ۴ ایستگاه‌های برنطین - گلاشگرد و گلاشگرد - فاریاب روش MLP بهترین میزان همبستگی و کمترین خطا ناشی از محاسبات دبی حاصله را در روز اول بارش داشته‌اند. و ایستگاه برنطین - فاریاب در روش MLP بهترین نتیجه دبی تولیدی را با بارش ۵ روز قبل و در روش RBF با بارش ۴ روز قبل نشان داده است.

نتیجه‌گیری و دستاورد علمی پژوهشی

در این پژوهش به منظور بررسی جریان دبی رودخانه میناب از داده‌های بارش و دبی روزانه سه ایستگاه هیدرومتری در یک دوره مشترک ۲۵ ساله (۱۳۷۳-۱۳۹۷) استفاده شده‌است با توجه به نتایج بدست آمده از تک‌تک ایستگاه‌ها روش چند لایه پرسپترون (MLP) همبستگی بیشتری داشته و بیشترین همبستگی بین بارش و دبی ماهانه مربوط به بارش روز اول در ایستگاه برنطین و بارش روز ۵ در ایستگاه گلاشگرد می باشد. ایستگاه فاریاب نظم خاصی در تعیین نوع روش و روز از خود نشان نداده است. در رابطه با ایستگاه‌های زوجی نیز روش چند لایه پرسپترون (MLP) بالاترین همبستگی بین داده را نشان داده است. این نتایج موافق با میر باقری و رجائی (۱۳۸۳) است. ایستگاه‌های برنطین-گلاشگرد و گلاشگرد-فاریاب بیشترین همبستگی بین دبی و بارش ماهانه را در روز اول بارندگی از خود نشان داده‌اند. در رابطه با ایستگاه‌های فاریاب-برنطین روش انتخابی و بهترین روز در هر مدل متفاوت است. همچنین نتایج به دست آمده نشان داد شبکه MLP با قابلیت انعطاف‌پذیری بالا در برآورد دبی نتایج موفق‌آمیزتری نسبت به RBF داشته است (خودرنجبر و شیرزاد، ۱۳۹۵؛ درمانی و همکاران ۱۳۹۷) البته شبکه RBF زمان کمتری نیاز دارد.

## منابع

- بیل، آر. و جکسون، تی. ۱۳۸۰. " آشنایی با شبکه‌های عصبی مصنوعی ". ترجمه محمود البرزی. موسسه انتشارات علمی. تهران.
- پلنگی، ع. ج. معاضد، ه. و طارقیان، ر. ۱۳۸۵. " تخمین تبخیر و تعرق پتانسیل گیاه با استفاده از شبکه‌های عصبی در منطقه اهواز ". همایش ملی شبکه‌های آبیاری و (ETO) مرجع زهکشی. اهواز. ایران.
- جهانگیر، ع.، رائینی، م.، احمدی، م. ض. و اکبرپور، الف. ۱۳۸۷. " شبیه سازی فرایند بارش - رواناب با استفاده از شبکه عصبی مصنوعی در حوضه کارده ". مجله آب و خاک (علوم صنایع کشاورزی)، جلد ۲۲. شماره ۲ ایران.
- خسروی، م. شکیبا، ه. ۱۳۸۹. " پیش بینی بارش با استفاده از شبکه‌های عصبی مصنوعی به منظور مدیریت سیل: مورد منطقه ایرانشهر ". مجموعه مقالات چهارمین کنگره بین المللی جغرافی دانان جهان اسلام. ICIWG 2010
- خسروی، م. سلاجقه، ع. مهدوی، م. محسنی ساروی، م. ۱۳۹۱. " پیش‌بینی سیل با استفاده از شبکه عصبی مصنوعی و رگرسیون چندمتغیره غیرخطی (مطالعه موردی: طالقان). مرتع و آبخیزداری. دوره: ۶۵، شماره
- خودرنجبر، م.، شیرزاد، ا. ۱۳۹۵. مقایسه عملکرد شبکه‌های عصبی MLP و RBF در پیش بینی دبی روزانه رودخانه. همایش ملی آب و سازه‌های هیدرولیکی، دزفول، دانشگاه آزاد اسلامی واحد دزفول، [https://www.civilica.com/Paper-NCWHS01-NCWHS01\\_150.html](https://www.civilica.com/Paper-NCWHS01-NCWHS01_150.html)
- درمانی، م.، بهتانی، م.، آرا، ه.، گلکاریان، ع.، شریف آذری، س. ۱۳۹۷. طراحی شبکه‌های عصبی فیدبک تکاملی با استفاده از الگوریتم بهینه‌سازی عنکبوتی در برآورد بار معلق (مطالعه موردی: حوضه آبخیز سد کارده). نشریه تحقیقات کاربردی علوم جغرافیایی سال هجدهم، شماره ۱۵، صفحات ۱۸۳-۱۹۸
- رامشت، م. ح.، ۱۳۸۵. نقشه‌های ژئومرفولوژی (نمادها و مجازها)، انتشارات سمت، ۱۹۰ ص.
- شریفی، ف.، بزرگ حداد، الف. و علیمحمدی، س. ۱۳۸۴. " پیش بینی جریان با استفاده از شبکه - های عصبی فازی ". پنجمین کنفرانس هیدرولیک ایران. کرمان. ایران.
- شمسی، الف. ط.، منهای، م. ب. و احمدیان، ر. ۱۳۸۴. " برآورد رسوب با استفاده از شبکه عصبی برای جریان های فوق بحرانی و زیربحرانی ". پنجمین کنفرانس هیدرولیک ایران. کرمان. ایران.
- صداقت کردار، ع. فتاحی، ا. ۱۳۷۸. " شاخص‌های پیش‌آگاهی خشکسالی در ایران ". مجله جغرافیا و توسعه، بهار و تابستان ۱۳۸۷، شماره ۱۱، صص ۵۹-۷۶.



- عراقی نژاد، ش. و کارآموز، م. ۱۳۸۴. "پیش بینی بلند مدت رواناب با استفاده از شبکه‌های-عصبی مصنوعی و سیستم استنتاج فازی". تحقیقات منابع آب ایران. سال اول، شماره ۲، ص ۲۹. ۴۱.
- کوره‌پزان دزفولی، الف. ۱۳۸۴. "اصول تئوری مجموعه‌های فازی و کاربردهای آن در مدل-سازی مسائل مهندسی آب". انتشارات جهاد دانشگاهی واحد صنعتی امیرکبیر. تهران.
- منهاج، م. ب. ۱۳۷۹. "مبانی شبکه‌های عصبی". انتشارات دانشگاه صنعتی امیرکبیر. تهران.
- منتظر، غ. قدسیان، م. دهقانی، ا. آذرخش، م. ۱۳۸۱. "ارائه روشی هوشمند به منظور برآورد حداکثر عمق آبستتگی دماغه آبشکنها با استفاده از شبکه عصبی". ششمین سمینار بین المللی مهندسی رودخانه، دانشگاه شهید چمران اهواز. ص: ۷۸۷-۷۹۶
- مجرد قره باغ، ف. ۱۳۷۶. "تحلیل و پیش بینی یخبندان در آذربایجان" رساله دوره دکتری، دانشگاه تربیت مدرس، دانشکده علوم انسانی میرباقری، س.ا. رجائی، ط. ۱۳۸۳. "تخمین بار معلق رودخانه زهره با استفاده از شبکه عصبی مصنوعی" اولین کنگره ملی مهندسی عمران. دانشگاه صنعتی شریف.
- نقی زاده بهبهانی، س. ع. و زمردیان، م. ع. ۱۳۸۴. "تعیین مقطع نهایی شکست سدهای خاکی با استفاده از شبکه عصبی مصنوعی". پنجمین کنفرانس هیدرولیک ایران. کرمان. ایران.
- ناصری، م. ۱۳۸۲. "پیش بینی بارندگی در دامنه زمان و مکان با استفاده از شبکه عصبی مصنوعی و الگوریتم ژنتیک". پایان نامه دوره کاشناسی ارشد، دانشگاه صنعتی اصفهان، گروه عمران.
- ولی، ع. رامشت، م. ح. سیف، ع. قضاوی. ر. ۱۳۹۰. "مقایسه کارایی مدل‌های شبکه‌های عصبی مصنوعی و رگرسیون برای پیش بینی بار رسوب جریان مطالعه موردی حوضه آبخیز سمندگان". مجله جغرافیا و برنامه ریزی محیطی، سال ۲۲، شماره پیاپی ۴۴، شماره ۴ وزارت نیرو، شرکت آب و برق خوزستان، معاونت طرح و توسعه سد و نیروگاه، دفتر تحقیقات و استانداردهای سد و نیروگاه. آبان ۱۳۸۶
- یزدانی، م. ر. و چاوشی، س. ۱۳۸۴. "پیش بینی جریان رودخانه با استفاده از مدل شبکه عصبی مصنوعی". پنجمین کنفرانس هیدرولیک ایران. کرمان. ایران.
- Anctil, F., C.H. Perrin and V. Andreassian. 2003. "Impact of the length of observed records on the Performance of ANN and of conceptual parsimonious rainfall-runoff forecasting models". *Environmental Modeling & Software*, 19: 357-368.
- Azmathullah, H. M., Deo, M. C. and Deolalikar, P. B. 2006. "Estimation of Scour Blow Spillways Using Neural Networks". *J. Hydraulic Research*; 44 (1): 155-163.
- Abrahart, R.J., See, L.M., 2007. "Neural network emulation of a rainfall-runoff model". *Journal of Hydrology and Earth System Sciences*. 4, 287-326, 2007.
- Birikundavy, R. Labib, H. T. Trung and J. Rousselle. 2002. "Performance of Neural Networks in Daily Stream Flow Forecasting," *Journal of Hydrologic Engineering*, Vol. 7, No. 5, 2002, pp. 392-398. doi:10.1061/(ASCE)1084-0699(2002)7:5(392)
- Dawson C .W. and Wilby. R. (1998) A comparison of artificial neural network used for river flow forecasting, *J. of ydrology and Earth System Sciences*, 3(4), 529-540.
- Dawson, C.W., Wilby, R.L., 2001. "Hydrological modelling using artificial neural networks". *Progress in Physical Geography* 25,1 (2001) pp. 80-108.
- Goswami, M. and O'connor, K. M. 2005. "Application of Artificial Neural Networks for River Flow Simulation in Three French Catchments". *The Fourth Inter- Celtic Colloquium on Hydrology and Management of Water Resources*". Guimaraes, Portugal.
- Grimes, D. I. F. Coppola, E., Verdecchia, M. and Visconti, G. 2003. "A Neural Network Approach to Real-Time Rainfall Estimation for Africa using Satellite Data". *J ydrometeorology*; 4: 1119-1133.
- Haykin, S., 1994. "Neural network: A comprehensive foundation". MacMillan College publishing Co., New York.
- Jain, S.K., A. Das, and D.K. Srivastava. 1999. "Application of ANN for reservoir inflow Prediction and operation". *Journal of Water Resources Planning and Management, ASCE*, 125(5):263-271.
- Kashefipour, S. M., Falconer, R. A. and Lin, B. 2002. "Modeling Longitudinal Dispersion in Natural Channel Flows Using ANNs". *International Conference on Fluvial Hydraulics, River Flow 2002*. Louvain-La. Belgium.

- Kashefipour, S. M., Lin, B. and Falconer, R. A. 2005. "Neural Networks for Predicting Seawater Bacterial Levels". Proceedings of the Institution of Civil Engineers (ice), Water Management; 158 (WM3): 111-118.
- Kalteh A. M. 2008. "Rainfall-runoff modelling using artificial neural networks (ANNs): modelling and understanding". Caspian J. Env. Sci. Vol. 6 No.1 pp. 53~58
- Kisi, O. (1999). "River flow modeling using artificial network". *J. of Hydrology*, Vol.214, 32-48.
- Minns, A.W. and M.J. Hall. 1996. "Artificial neural network as rainfall-runoff models". *Hydrological Sciences Journal*, 41: 399-417
- Nayak, P. C., Sudheer, K. P., Rangan, D. M. and Ramasastri, K.S. 2004. "A Neuro-Fuzzy Computing Technique for Modeling Hydrological Time Series". *J. Hydrology*; 291: 52-66.
- Solaimani, K., 2009. "Rainfall-runoff Prediction Based on Artificial Neural Network (A Case Study: Jarahi Watershed)". *American-Eurasian Journal of Agriculture and Environment. Science*, 5 (6): 856-865, 2009, ISSN 1818-6769.
- Shamseldin, A. Y. 1997. "Application of a Neural Network Technique to Rainfall- Runoff Modeling". *J. Hydrology, Amsterdam*; 199 (1997): 272-294.
- Sinha, N. K. and Gupta, M. M. 2000. "Soft Computing and Intelligent Systems: Theory & Applications". Academic Press. San Diego.
- Tan Danh, N., Phien, H. N. and Gupta, A. D. 1999. "Neural Network Models for River Flow Forecasting". *Water SA*; 25 (1): 45-56.
- Tokar, A. S. and Johnson, P. A. 1999. "Rainfall-Runoff Modeling Using Artificial Neural Networks". *J. Hydrologic Engineering, ASCE*; 4 (3): 232-239.
- Yang, C. C., Prasher, S. O., Lacroix, R., Srekanth, S., Patni, N. K. and Masse, L. 1997. "Artificial Neural Network Model for Subsurface-Drained Farmland". *J. Irrigation and Drainage Engineering, ASCE*; 123 (4): 285-292.
- Zaker Moshfeg, M., Ghodsian, M., and Montazer. Gh. A. (2004). "River flow forecasting using artificial neural networks. Proceeding of the hydraulics of dams and river structures". Yazdandoost and Attari (eds). London.