



## شبیه سازی فرآیند بارش-رواناب با استفاده از شبکه عصبی مصنوعی در حوزه آبخیز کورکورس نوشهر

کمال قادری<sup>۱</sup>، بهارک معتمد وزیری<sup>۲</sup>، پروانه محمودی<sup>۳</sup>

kamalghaderi1986@gmail.com

bmvaziri@gmail.com

parvanehmahmudi65@gmail.com

### چکیده

برای برنامه ریزی شهری، کاربری اراضی و مدیریت منابع آب حوزه آبخیز فراهم آورد که نقش پیش بینی صحیح پدیده های هیدرولوژیک، مانند فرآیند بارش-رواناب می تواند اطلاعات موثری مهمی در کاهش اثرات سیلاب و خشکسالی بر سیستم های منابع آب دارد. هدف از این تحقیق بررسی کارایی مدل شبکه عصبی مصنوعی در شبیه سازی فرآیند بارش-رواناب و شناسایی تأثیر رواناب به عنوان ورودی در کارایی مدل بوده است. نتایج نشان می دهد که مدل MLP با مقدار RMSE برابر ۰/۱۱۰۵، مقدار ضریب کارایی ناش ساتکلیف برابر ۰/۷۲۸۸۳ و ضریب همبستگی برابر ۰/۸۵۷۲۸، با خطای کم و همبستگی دقت و کارایی بالا می تواند فرآیند بارش - رواناب را مدل سازی و پیش بینی کند. ترکیب هایی که رواناب را نیز به عنوان ورودی دارند نسبت به ترکیب هایی که فقط بارش را به عنوان ورودی لحاظ می کنند کارایی بیشتری داشتند. بهترین پیش بینی با ترکیب (بارش روز جاری، بارش روز قبل، دبی روز قبل، دبی دو روز قبل و دبی سه روز قبل) انجام می شود و در صورت نبود داده های دبی، ترکیب (بارش جاری و بارش روز قبل) نیز به طور قابل قبولی می تواند دبی خروجی را پیش بینی کند.

کلمات کلیدی: بارش - رواناب، مدل جعبه سیاه، هوش مصنوعی، ANN، کورکورس

### مقدمه

پیش بینی صحیح پدیده های هیدرولوژیک، مانند فرآیند بارش-رواناب می تواند اطلاعات موثری برای برنامه ریزی شهری، کاربری اراضی و مدیریت منابع آب حوزه آبخیز فراهم آورد که نقش مهمی در کاهش اثرات سیلاب و خشکسالی بر سیستم های منابع آب دارد. فرآیند بارش - رواناب یک حوزه آبخیز یکی از پیچیده ترین فعالیت های هیدرولوژیک می باشد، چرا که در

<sup>۱</sup> کاندیدای دکتری علوم و مهندسی آبخیزداری دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران

<sup>۲</sup> استادیار گروه علوم و مهندسی آبخیزداری دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران

<sup>۳</sup> دانشجوی دکتری علوم و مهندسی آبخیزداری دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران



برگیرنده تغییرپذیری زمانی و مکانی بسیار گسترده ای است. مسائل با میزان بالای پیچیدگی و عدم قطعیت که در نظر گرفتن همه پارامترهای فیزیکی موثر مشکل است، مدل‌های جعبه سیاه که داده‌های ورودی را به مقادیر خروجی تبدیل می‌کنند، می‌توانند نتایج دقیق‌تری از مدل‌های فیزیکی داشته باشند. روش‌های هوش مصنوعی (شبکه عصبی و سیستم عصبی فازی) ابزارهای مدل‌سازی جعبه سیاه هستند که اخیراً در بخش‌های مختلفی از جمله مدل‌سازی بارش - رواناب کاربرد پیدا کرده‌اند. (Nourani and Komasi, 2013)

پیش‌بینی دبی رودخانه یکی از مهم‌ترین مسائل هیدرولوژیکی است که برای مدیریت سیلاب بسیار مهم است. پیش‌بینی منطقی از دبی روزانه تنها اطلاعات مفیدی برای مدیریت منابع آب در اختیار ما قرار می‌دهد، بلکه برنامه ریزی دقیق‌تری جهت استحصال مناسب‌تر آب ایجاد کرده و نیز از حوادث غیر قابل تصور جلوگیری می‌کند. (ذرتی پور و همکاران، ۱۳۸۸). از اهداف شناخت فرآیند بارش رواناب می‌توان به ذخیره آب، کنترل سیلاب، آبیاری، زهکشی، کیفیت آب، تولید انرژی، مراکز تفریحی، پرورش ماهی، گسترش حیات وحش و ... اشاره کرد (اعلمی و همکاران، ۱۳۸۸). حوزه آبخیز کورکورسر در بالادست شهر نوشهر قرار دارد لذا پیش‌بینی هر چه دقیق‌تر دبی این رودخانه با توجه به موقعیت این حوضه جهت طرح‌های مهار سیل ضرورت دارد. هدف از این تحقیق شبیه‌سازی فرآیند بارش-رواناب با استفاده از شبکه عصبی مصنوعی در حوزه آبخیز کورکورسر نوشهر، بررسی کارایی مدل ANN در شبیه‌سازی فرآیند بارش-رواناب و شناسایی تأثیر رواناب به عنوان ورودی در کارایی مدل است.

### فرآیند بارش - رواناب

هرگاه بارش به وقوع پیوسته بر روی یک حوزه آبخیز بیش از ظرفیت نفوذ خاک باشد، بخشی از آب حاصله از بارش به صورت رواناب بر روی سطح حوضه جاری می‌شود. یکی از مهم‌ترین محاسبات هیدرولوژیکی برای یک حوضه، تعیین ارتباط بین بارش - رواناب در آن است. میزان تبدیل آب حاصل از بارش به حجم رواناب وابسته به پارامترهای اقلیمی و فیزیکی حوضه است (کارآموز و عراقی نژاد، ۱۳۹۳:ص ۱۸۵).

### شبکه عصبی مصنوعی

محاسبات نرم یک روش جدید محاسباتی است که توانایی‌های شاخص ذهن انسان را برای استدلال و فراگیری در یک محیط نامعین و نادقیق گرد هم می‌آورد (لطفی زاده، ۱۹۹۲). شبکه عصبی مصنوعی که الهام گرفته از شبکه عصبی بیولوژیکی مغز انسان است، شامل شبکه‌ای از نرون‌ها بوده که قادر است رفتار پیچیده بین نرون‌ها را نشان دهد. توانایی یادگیری، مهم‌ترین ویژگی شبکه عصبی و هر سیستم هوشمند است که با پردازش داده‌ها، قوانین نهفته در انبوه داده‌ها را به ساختار شبکه عصبی انتقال می‌دهد (اعلمی و همکاران، ۱۳۹۲:ص ۹۸). یکی از مهم‌ترین انواع شبکه‌های عصبی، شبکه‌های MLP (پرسپترون چند لایه<sup>۱</sup>) می‌باشند. در هر لایه تعدادی نرون در نظر گرفته می‌شود که به نرون‌های لایه‌های مجاور وصل می‌شوند. در این شبکه‌ها ورودی موثر هر نرون، حاصل ضرب خروجی نرون‌های لایه قبل در وزن‌های میان آن نرون‌ها است. نرون‌های لایه اول اطلاعات ورودی را گرفته و از طریق اتصالات مربوطه به نرون‌های لایه مخفی منتقل می‌کنند. در لایه مخفی پس از محاسبه ورودی موثر هر نرون، این ورودی از یک تابع محرک گذرانده می‌شود. برای این کار توابع محرک

<sup>1</sup> Multilayer Perceptron



مختلفی ارائه شده است. گرایش بیشتر محققان به استفاده از توابع محرک کران دار می باشد که مشهورترین آن ها تابع سیگموئید است (اعلمی و حسین زاده، ۱۳۸۹).

### پیشینه تحقیق

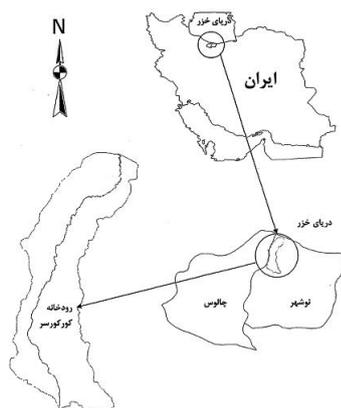
نصری و همکاران (۱۳۸۸؛ ۱۳۸۹) در دو تحقیق جداگانه با به کار بردن شبکه های عصبی مصنوعی در حوزه آبریز سد زاینده رود، گزارش کرده اند که شبکه عصبی پرسپترون با ۴ نورون لایه مخفی اعتبار بیشتری نسبت به سایر شبکه ها دارد و پیشنهاد نموده اند که اعتبار شبکه های عصبی مورد استفاده در شبیه سازی رابطه بارندگی رواناب از طریق آماری نیز مورد آزمون قرار گیرد. طباطبایی و همکاران (۱۳۸۹) پژوهشی با عنوان بررسی تأثیر پارامترهای ورودی بر عملکرد مدل های شبکه عصبی مصنوعی بارش - رواناب در حوزه آبریز طرق - خراسان رضوی انجام داده اند و بیان داشته اند: با توجه به طبیعت غیرخطی و اتفاقی پدیده های هیدرولوژیکی کاربرد شبکه های عصبی مصنوعی در این علم کاملاً قابل توجیه است در این تحقیق نیز نوعی از شبکه های عصبی مصنوعی یعنی شبکه های پرسپترون چند لایه برای مدل سازی رواناب ناشی از بارندگی استفاده شده است بدین منظور سه شبکه عصبی مجزا با ورودی های مختلف مورد بررسی قرار گرفته که از این طریق تأثیر عوامل مختلف بر روی دبی محاسباتی توسط شبکه بررسی شده است همچنین هر سه شبکه با توابع محرک متفاوت آزمایش شده و نتایج حاصل از کلیه حالات با استفاده از معیارهای سنجش خطا و نکویی برازش مقایسه گردیده شده است و در نهایت دو مدل شبکه عصبی MLP با هشت نورون ورودی و یازده نورون در لایه میانی بهترین عملکرد را ارائه نمودند. عملکرد مدل های مختلف با افزایش تعداد پارامترهای موثر در لایه ورودی بهبود می یابد. صف شکن و همکاران (۱۳۹۰) شبیه سازی آب نمود بارش - رواناب را با توجه به الگوی زمان بارش و استفاده از شبکه عصبی مصنوعی در حوزه آبریز معرف کسلیان انجام داده اند و اظهار داشته اند که در شرایط نبود اطلاعات جزئی، مدل شبکه عصبی مصنوعی می تواند برای شبیه سازی پارامترهای آب شناختی مورد استفاده قرار گیرد. در پژوهش میرزایی و خزایی (۱۳۹۰) با عنوان مدل سازی بارش - رواناب (تأثیر تغییر پارامترهای شبکه در میزان دقت پیش بینی)، از دو نوع شبکه عصبی MLP و RBF<sup>۱</sup> به عنوان پرکاربردترین نوع شبکه های عصبی استفاده شده است. نتایج نشان داد که هر دو نوع شبکه عصبی مصنوعی بکار رفته در تحقیق حاضر قادر به شبیه سازی رواناب در ایستگاه های مورد بررسی بجز ایستگاه پل زهره را نشان می دهد. در مجموع نتایج شبکه RBF قابلیت و کارایی بیشتری در شبیه سازی رواناب در ایستگاه های مورد بررسی را نشان داده است. هم چنین در مقایسه با مراحل آموزش و تست، در مرحله تست رواناب شبیه سازی شده به رواناب مشاهداتی مقادیر نزدیک تری را ارائه داده است. در مقاله طاهرشمسی و همکاران (۱۳۹۱) با عنوان مدل سازی بارش - رواناب با استفاده از ۲ مدل مختلف شبکه عصبی در حوزه آبریز آقچای واقع در استان آ.غربی، رابطه بارش - رواناب با استفاده از سه مدل مختلف شبکه های عصبی از جمله: شبکه های عصبی پرسپترون چند لایه (MLP) و توابع شعاعی پایه (RBF) ارائه شده است. در نهایت با مقایسه نتایج، مدل شبکه RBF که با استفاده از الگوریتم خوشه بندی K-means آموزش داده شده است، به عنوان مدل برتر برای پیش بینی رواناب در حوزه آبریز آقچای انتخاب شد. نتایج تحقیق موتلو<sup>۲</sup> و همکاران (۲۰۰۸) در مقایسه مدل های شبکه عصبی مصنوعی برای پیش بینی های هیدرولوژیک در چندین ایستگاه در یک حوزه آبخیز با کاربری کشاورزی حاکی از آن بوده است که مدل های ANN ابزار مفیدی برای پیش بینی پاسخ هیدرولوژیک در چندین نقطه مورد نظر در حوزه های آبخیز کشاورزی هستند. نتایج تحقیق چن و چانگ (۲۰۰۹) با عنوان شبکه های عصبی



مصنوعی تکاملی برای پیش بینی سیستم‌های هیدرولوژیکی نشان داد که EANN به طور موثر و کارایی یک واحد پیش بینی مناسبی برای جریان ورودی مخزن ۱۰ روزه می‌سازد، و دقت آن برتر از مدل‌های AR و ARMAX است. نورانی و همکاران (۲۰۱۴) مروری بر کاربردهای مدل‌های هیبرید هوش مصنوعی- موجک در هیدرولوژی داشته‌اند و بیان داشته‌اند که مدل‌های هیبرید هوش مصنوعی- موجک در بین بهترین مدل‌ها در شبیه سازی فرآیندهای هیدرولوژیک هستند. در این تحقیق به تعریف مدل سازی هیبرید، مزایای این مدل‌های ترکیبی و همچنین پیشینه و چشم انداز کاربرد آن‌ها در هیدرولوژی برای پیش بینی فرآیندهای مهم چرخه هیدرولوژی پرداخته است. نورانی و کلانتری (۲۰۱۰) در مقاله خود، یک مدل شبکه عصبی مصنوعی یکپارچه برای مدل سازی زمانی مکانی فرآیندهای بارش- رواناب- رسوب را پیشنهاد داده‌اند و نتایج نشان داده است که مدل ANN یکپارچه پیشنهادی، عملکرد قابل قبولی در مدل سازی زمانی مکانی قبل و بعد از کلاسترینگ داشته است و کلاسترینگ پیچیدگی مدل را کاهش داده است.

#### موقعیت حوزه آبخیز کورکورسر در استان مازندران و ایران

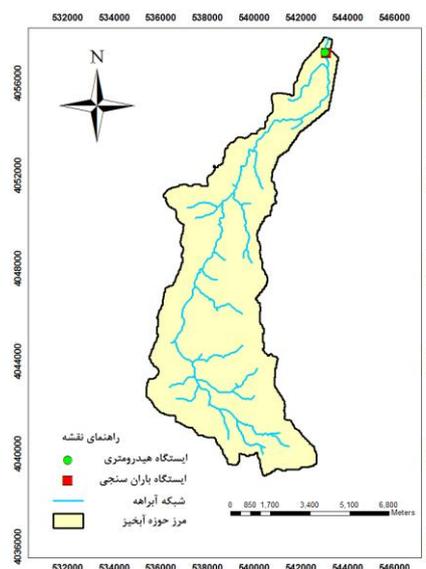
حوزه آبخیز کورکورسر در شمال ایران و از نظر تقسیمات سیاسی در استان مازندران و جزء شهرستان نوشهر، و از لحاظ تقسیمات هیدرولوژیکی به عنوان یکی از زیرحوضه‌های آبریز مازندران محسوب می‌گردد که در طول  $42^{\circ} 51'$  تا  $29^{\circ} 51'$  شرقی و عرض جغرافیایی  $29^{\circ} 36'$  تا  $40^{\circ} 36'$  شمالی واقع شده است (شکل ۱). این حوزه دارای جهت شمالی- جنوبی و شکلی کشیده است و مساحت حوزه حدود  $45/67$  کیلومتر مربع می‌باشد که از شمال به دریای مازندران و از جنوب به رودخانه هریسک (زیر حوضه رودخانه چالوس) از غرب به حوزه آبخیز رودخانه چالوس و از شرق به حوزه آبخیز ماشک محدود شده است. در این آبخیز جمعاً ۶ روستا قرار دارند و قسمت اعظم بخش خروجی آن جزء منطقه شهری به حساب می‌آید. (ابراهیمی، ۱۳۸۵: فصل ۳ ص ۲)



شکل ۱. موقعیت جغرافیایی حوزه آبخیز کورکورسر (احمدنژاد، ۱۳۸۴: ص ۴)

#### روش پژوهش

ایستگاه‌های باران سنجی و هیدرومتری از شرکت مدیریت منابع آب ایران و شرکت آب منطقه ای استان مازندران دریافت گردید و بازسازی نواقص آماری انجام شد (مهدوی، ۱۳۸۱: ص ۲۴۷). ایستگاه‌های موجود در حوضه، به شرح جدول ۱ است که موقعیت آنها در شکل ۲ نشان داده شده است و آنالیز آماری داده‌ها به شرح جدول ۲ است.



شکل ۲. موقعیت ایستگاه های باران سنجی و هیدرومتری داخل حوزه آبخیز کورکورس

جدول ۱. مشخصات ایستگاه های هواشناسی و هیدرومتری داخل حوزه

ردیف	نام ایستگاه	نوع	تجهیزات	طول جغرافیایی	عرض جغرافیایی	ارتفاع از سطح دریا (متر)
۱	نوشهر (کورکورس)	تبخیرسنجی	ثبات	۵۱۲۸۴۳	۳۶۳۹۲۶	-۱۰
۲	نوشهر (کورکورس)	هیدرومتری	اشل، دیتالاگر، پل تلفریک	۵۱۲۸۴۱	۳۶۳۹۲۷	-۲۴

جدول ۲. آنالیز آماری داده مشاهداتی دوره ایستگاه تبخیرسنجی و هیدرومتری نوشهر (کورکورس)

مرحله	پارامتر	تعداد	میانگین	حداقل	حداکثر	آماره	
						انحراف معیار	ضریب چولگی
آموزش	دبی ( $m^3/s$ )	۳۲۸۷	۱/۴۱۴	۰/۰۱	۷۳/۱	۲/۴۴۲	۱۳/۰۱۴
	بارندگی (mm)	۳۲۸۷	۳/۴۸۷	۰	۱۴۹	۱۱/۳۸۳	۶/۱۶۲
آزمون	دبی ( $m^3/s$ )	۱۰۹۶	۱/۰۱۸	۰/۰۰۲	۱۶/۸	۱/۳۰۳	۳/۸۶۸
	بارندگی (mm)	۱۰۹۶	۳/۰۳۴	۰	۹۲	۹/۷۹۶	۵/۴۴۳
اعتبارسنجی	دبی ( $m^3/s$ )	۱۰۹۶	۱/۱۷۳	۰/۰۰۴	۴۱/۴	۱/۹۴۰	۱۰/۱۰۵
	بارندگی (mm)	۱۰۹۶	۳/۶۹۶	۰	۱۴۷	۱۱/۴۷۲	۶/۰۴۷

به منظور بی بعد سازی داده‌ها جهت ورود به مدل، داده های ورودی (بارش (I)، رواناب (Q) و خروجی (رواناب) نرمال سازی شدند. سپس تقسیم بندی داده‌ها (از سال ۷۷-۷۸ تا ۹۱-۹۲) به سه دسته آموزش، آزمون و اعتبارسنجی به ترتیب ۶۰٪ (۹ سال)، ۲۰٪ (۳ سال) و ۲۰٪ (۳ سال) انجام شد. (Nourani and Komasi, 2013) در مرحله بعد اجرای شبکه عصبی مصنوعی ترکیب‌های مختلف بارش و رواناب با نرم افزار Matlab است.



### نتایج تعیین تعداد تأخیرها

جهت تعیین تعداد تأخیرها برای مدل سازی از توابع خود همبستگی و خود همبستگی جزئی و همبستگی متقاطع بین رواناب و بارش استفاده شد (Vafakhah, 2012). برای تعیین تعداد تأخیرها، ضرایب خود همبستگی و خود همبستگی جزئی و همبستگی متقابل بارش و دبی برای همه ایستگاه های باران سنجی و هیدرومتری تا ۱۰ تأخیر محاسبه گردید و نتایج آن در جدول های ۳ و ۴ قابل مشاهده است. (مقادیری که در سطح اطمینان ۵٪ معنی دار هستند پررنگ نشان داده شده است) همانطور که از جدول ۳ مشخص است ضرایب خود همبستگی و خود همبستگی جزئی بارش فقط در تأخیر اول در سطح اطمینان ۵٪ معنی دار است. نتایج همبستگی متقابل بارش و دبی نیز در تأخیر اول معنی دار است در نتیجه بارش با یک تأخیر به عنوان ورودی مدل انتخاب شد. ضرایب خود همبستگی دبی در کل ۱۰ تأخیر در سطح اطمینان ۵٪ معنی دار است و ضرایب خود همبستگی جزئی تا تأخیر ششم معنی دار است و برای اینکه تعداد ترکیب ها خیلی زیاد نشود، تصمیم گرفته شد که دبی تا سه تأخیر در مدل استفاده شود.

جدول شماره ۳. نتایج ضرایب خود همبستگی و خود همبستگی جزئی در تأخیرهای مختلف بارش

ایستگاه	ضرایب خود همبستگی									
	r1	r2	r3	r4	r5	r6	r7	r8	r9	r10
تبخیر	۰/۱۹۴	۰/۰۱۷	-۰/۰۰۹	۰/۰۰۴	-۰/۰۰۴	-۰/۰۱۷	۰/۰۰۹	۰/۰۱۴	۰/۰۳۶	۰/۰۲۶
سنجی	ضرایب خود همبستگی جزئی									
	r1	r2	r3	r4	r5	r6	r7	r8	r9	r10
نوشهر (کورکورسر)	۰/۱۹۴	-۰/۰۲۱	-۰/۰۰۹	۰/۰۰۰	۰/۰۰۳	۰/۰۱۹	۰/۰۰۲	۳۳	۰/۰۲۴	۰/۰۱۴

جدول شماره ۴. نتایج ضرایب خود همبستگی و خود همبستگی جزئی در تأخیرهای مختلف دبی

ایستگاه	ضرایب خود همبستگی									
	r1	r2	r3	r4	r5	r6	r7	r8	r9	r10
هیدرومتری	۰/۴۶۳	۰/۲۹۷	۰/۲۵۱	۰/۲۳۹	۰/۲۲۴	۰/۲۰۹	۰/۱۸۸	۰/۱۶۹	۰/۱۷۵	۰/۱۷۱
نوشهر(کورکورسر)	ضرایب خود همبستگی جزئی دبی									
	r1	r2	r3	r4	r5	r6	r7	r8	r9	r10
	۰/۴۶۳	۰/۱۰۵	۰/۱۰۱	۰/۰۹۴	۰/۰۷۰	۰/۰۵۶	۰/۰۳۶	۰/۰۲۶	۰/۰۳۸	۰/۰۳۵

جدول شماره ۵. نتایج همبستگی متقابل در تأخیرهای مختلف بارش و دبی

همبستگی متقابل بارش و دبی	همبستگی متقابل بارش و دبی										
	r0	r1	r2	r3	r4	r5	r6	r7	r8	r9	r10
	۰/۵۶۵	۰/۰۹۴	-۰/۰۰۹	۰/۰۱۰	-۰/۰۰۳	-۰/۰۰۴	۰/۰۰۳	۰/۰۱۱	۰/۰۴	۰/۰۱۶	۰/۰۰۹

### انتخاب ترکیب های مختلف

بر اساس نتایج ضرایب خود همبستگی و خود همبستگی جزئی و همبستگی متقابل بارش و دبی، ۸ ترکیب مختلف بارش و رواناب به عنوان ورودی های مدل بارش رواناب اولیه برای ANN انتخاب شدند (جدول ۶).

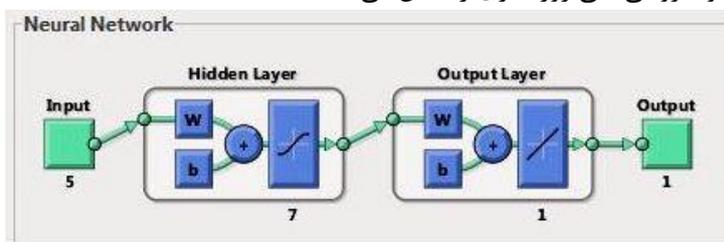


جدول ۶- ترکیب های مختلف بارش و دبی برای مدل سازی اولیه برای ANN

ترکیب	ردیف
بارش روز جاری	۱
بارش روز جاری، دبی روز قبل	۲
بارش روز جاری، دبی روز قبل، دبی دو روز قبل	۳
بارش روز جاری، دبی روز قبل، دبی دو روز قبل، دبی سه روز قبل	۴
بارش روز جاری، بارش روز قبل	۵
بارش روز جاری، بارش روز قبل، دبی روز قبل	۶
بارش روز جاری، بارش روز قبل، دبی روز قبل، دبی دو روز قبل	۷
بارش روز جاری، بارش روز قبل، دبی روز قبل، دبی دو روز قبل، دبی سه روز قبل	۸

### اجرای ANN

مدل سازی شبکه عصبی مصنوعی با استفاده از برنامه نویسی m-file در محیط نرم افزار MATLAB نسخه (R2010b) انجام شد. ورودی ها بر اساس روش تقسیم داده (divideblock) به سه دسته آموزش (۶۰٪)، آزمون (۲۰٪) و اعتبارسنجی (۲۰٪) تقسیم شدند. نوع شبکه عصبی، شبکه پس انتشار پیش خور<sup>۱</sup> و از بین شبکه های پیش خور نیز، پرسپترون چند لایه<sup>۲</sup> (MLP) استفاده شد. برای تابع آموزش، از الگوریتم بهینه سازی لونیبرگ مارکواردت<sup>۳</sup> (LM) و برای تابع آموزشی تطبیقی نیز از کاهش شیب با مومنتوم<sup>۴</sup> (GDM) استفاده شد. برای لایه اول، تابع تانژانت هیپربولیک سیگموئید (tansig) و برای لایه دوم، تابع خطی (pureline) به عنوان تابع های انتقال انتخاب شدند. خطای مطلوب، صفر در نظر گرفته شد. تعداد نورون لایه میانی، با آزمون و خطا تعیین شد. به طوری که تا دو برابر تعداد ورودی به علاوه یک نورون (مثلاً برای ۷ ورودی، از ۲ تا ۱۵ نورون) امتحان شد. فرآیند آموزش مدل در تکراری متوقف شد که خطای اعتبارسنجی طی ۶ تکرار متوالی افزایش یابد (کیا، ۱۳۹۱:ص ۸۳، علمی، ۱۳۹۲:صص ۱۰۷ تا ۱۰۸). شکل ۳ به عنوان مثال یکی از مدل های شبکه عصبی مصنوعی پیش خور (tansig/pureline) با ۷ ورودی (بارش روز جاری، بارش روز قبل، دبی روز قبل، دبی دو روز قبل و دبی سه روز قبل) و ۷ نورون لایه میانی و خروجی دبی روز جاری را نشان می دهد.



شکل ۳ یک مدل شبکه عصبی مصنوعی (۷-۱-۵)

<sup>1</sup> Feed-forward Back Propagation

<sup>2</sup> Multilayer Perceptron

<sup>3</sup> Levenberg-Marquardt optimization algorithm

<sup>4</sup> Gradient descent with momentum



در ادامه برای اجرای مدل دو سناریو طراحی شد (Nourani and Komasi, 2013). در سناریوی اول، رواناب در ورودی مدل تاثیر داده نشد تا بررسی شود که در صورت نبود داده رواناب قبلی، با استفاده از بارش می توان رواناب روز جاری را پیش بینی کرد.

$$Q_i(t) = f(I_i(t), I_i(t-1)) \quad (1)$$

در معادله فوق  $I_i(t)$ ،  $I_i(t-1)$  و  $Q_i(t)$  به ترتیب بارش روز جاری، بارش روز قبل و دبی روز جاری (خروجی مدل) هست. در سناریوی دوم، رواناب قبلی به عنوان ورودی مدل تاثیر داده شد تا بهترین مدل ANN انتخاب شود.

(2)

$$Q(t) = f(Mat[I(t), I(t-1), Q(t-1), Q(t-2), Q(t-3)])$$

### معیارهای کارایی

برای بررسی کارایی مدل ها و ترکیب های مختلف مورد استفاده این تحقیق، از معیارهای کارایی ریشه میانگین مربعات خطا، ضریب کارایی ناش ساتکلیف استفاده گردیده است. در معیارهای کارایی زیر  $N$  تعداد مشاهدات،  $Q_{obs_i}$  دبی مشاهداتی،  $Q_{com_i}$  دبی محاسباتی،  $\bar{Q}_{com}$  میانگین دبی های محاسباتی، هستند (Nourani and Komasi, 2013)؛ Vafakhah, 2012).

ریشه میانگین مربعات خطا (RMSE): این معیار برای اندازه گیری دقت پیش بینی استفاده شد. مقادیر RMSE به دلیل به توان رساندن مقادیر خطا، مثبت هستند و از صفر (برای پیش بینی های کاملاً دقیق) تا مقادیر بالای مثبت (وقتی که اختلاف مقادیر مشاهداتی و محاسباتی زیادتر می شود) تغییر می کند (Nourani and Komasi, 2013).

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Q_{obs_i} - Q_{com_i})^2}{N}} \quad (3)$$

ضریب کارایی ناش ساتکلیف (Nash and Sutcliffe, 1970): هر چه ضریب کارایی بیشتر باشد (حداکثر 1) کارایی مدل بیشتر است (Nourani and Komasi, 2013).

$$NSE = 1 - \frac{\sum_{i=1}^N (Q_{obs_i} - Q_{com_i})^2}{\sum_{i=1}^N (Q_{obs_i} - \bar{Q}_{com_i})^2} \quad (4)$$

### نتایج

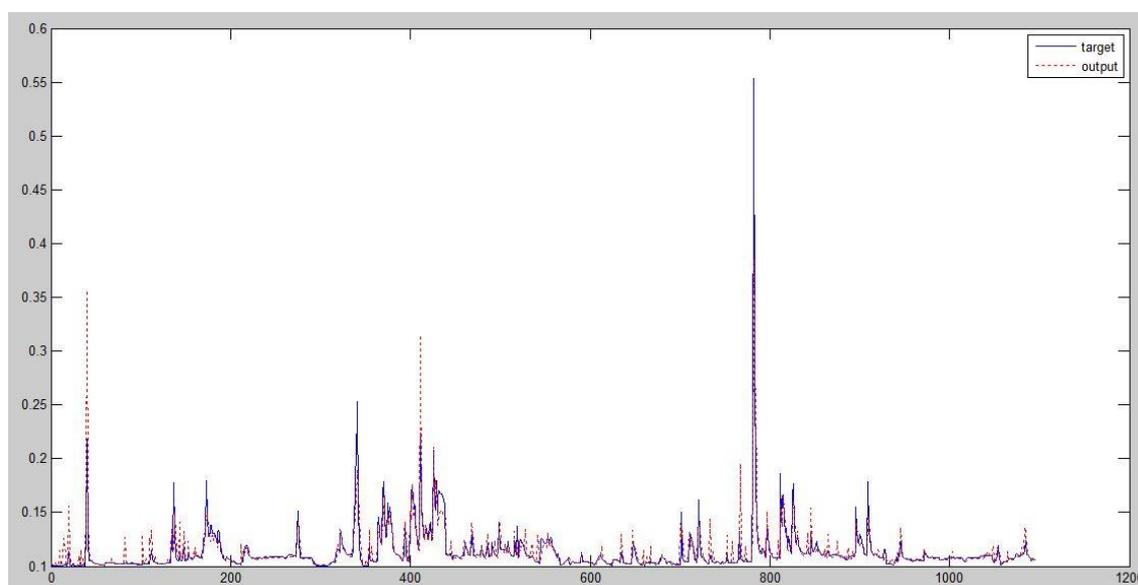
مقادیر ریشه میانگین مربعات خطا (RMSE) و ضریب کارایی ناش ساتکلیف (NSE) مراحل آموزش، آزمون و اعتبارسنجی ترکیبات مختلف در جدول ۷ قابل مشاهده است و دبی محاسباتی و مشاهداتی سال آخر (دوره اعتبارسنجی) ترکیب  $R_t R_{t-1} Q_{t-1} Q_{t-2} Q_{t-3}$  را می توان در شکل ۴ مشاهده نمود.



جدول ۷. مقادیر ریشه میانگین مربعات خطا (RMSE) و ضریب کارایی ناش ساتکلیف (NSE) ترکیبات مختلف مدل ANN

ردیف	ترکیب	تعداد نرون	معیار	آموزش	آزمون	اعتبارسنجی
۱	Rt	۲	RMSE	۰/۰۲۲۰۵	۰/۰۱۵۲۲	۰/۰۱۶۴۳
			NSE	۰/۰۳۱۸۹۹	-۰/۱۴۰۴۱	۰/۴۰۱۰۱
۲	RtQt-1	۲	RMSE	۰/۰۱۹۳۳	۰/۰۱۱۲۱	۰/۰۱۲۹۷
			NSE	۰/۴۷۶۷۲	۰/۰۳۸۰۹۶	۰/۶۲۶۲۴
۳	RtQt-1Qt-2	۵	RMSE	۰/۰۱۹۴۲	۰/۰۱۲۰۹	۰/۰۱۲۹۲
			NSE	۰/۴۷۱۸۴	۰/۲۸۰۲۱	۰/۶۲۹۴۰
۴	RtQt-1Qt-2Qt-3	۲	RMSE	۰/۰۱۹۵۵	۰/۰۱۱۸۶	۰/۰۱۲۵۶
			NSE	۰/۴۹۱۴۲	۰/۳۰۷۰۳	۰/۶۴۹۵۱
۵	RtRt-1	۲	RMSE	۰/۰۲۱۴۹	۰/۰۱۴۹۸	۰/۰۱۵۶۳
			NSE	۰/۳۵۳۴۰	-۰/۱۰۴۶۵	۰/۴۵۷۷۵
۶	RtRt-1Qt-1	۲	RMSE	۰/۰۱۴۸۵	۰/۰۰۶۸۲	۰/۰۱۲۹۹
			NSE	۰/۰۶۹۱۲	۰/۷۷۰۵۶	۰/۶۲۵۵۰
۷	RtRt-1Qt-1Qt-2	۶	RMSE	۰/۰۱۷۲۵	۰/۰۱۰۱۴	۰/۰۱۲۲۸
			NSE	۰/۵۸۲۹۱	۰/۴۹۳۰۱	۰/۶۶۴۹۱
۸	RtRt-1Qt-1Qt-2Qt-3	۷	RMSE	۰/۰۱۷۹۸	۰/۰۰۹۹۳	۰/۰۱۱۰۵
			NSE	۰/۵۴۷۰۷	۰/۵۱۴۵۱	۰/۷۲۸۸۳

به علت نرمال سازی داده‌ها، مقادیر RMSE بدون واحد هستند



شکل شماره ۴. مقایسه دبی محاسباتی و مشاهداتی سال آخر (دوره اعتبارسنجی) ترکیب  $R_tR_{t-1}Q_{t-1}Q_{t-2}Q_{t-3}$



## نتیجه گیری

با توجه به جدول ۷ در ترکیب‌هایی که فقط بارش به عنوان ورودی مدل لحاظ شده است، ترکیب (1-RtRt: بارش روز جاری، بارش روز قبل) عملکرد بهتری نسبت به (Rt: بارش روز جاری) داشته است که نشان دهنده تأثیر بارش روز قبل در افزایش اشباع شدگی، کاهش نفوذپذیری خاک و افزایش رواناب دارد. ولی در ترکیب‌هایی که بارش و رواناب روزهای قبل به عنوان ورودی مدل لحاظ شده‌اند، بهترین ترکیب‌های بارش و رواناب در مرحله آموزش و آزمون (1-1Qt-RtRt: بارش روز جاری، بارش روز قبل، دبی روز قبل) بوده است که نشان دهنده اهمیت بالای شرایط جاری و اخیر حوزه آبخیز در تولید رواناب است ولی در مرحله اعتبارسنجی بهترین ترکیب (3-2Qt-1Qt-1RtRt: بارش روز جاری، بارش روز قبل، دبی روز قبل، دبی دو روز قبل و دبی سه روز قبل) بوده است (شکل ۴) و دلیل آن را می‌توان به ماهیت اتورگرسیو رواناب و کارایی بالای شبکه عصبی مصنوعی در مدل سازی دقیق تر با ورودی های زیاد در مقایسه با سیستم های فازی تعمیم داد که با نتایج (قادری، ۱۳۹۳:ص ۷۶) همخوانی دارد.

همچنین با توجه به اینکه کارایی این ترکیب (با ورودی بارش و رواناب) از ترکیب‌های با ورودی فقط بارش بیشتر بوده است می‌توان نتیجه گرفت که با لحاظ کردن دبی روزهای قبل در ماتریس ورودی، ویژگی مارکوفی و اتورگرسیو رواناب به طور دقیقی در نظر گرفته شده است (Nourani and Komasi, 2013) و این با نتایج دستورانی و همکاران (۱۳۹۰) و نورانی و کماسی (۲۰۱۳) نیز همسو است.

از نتایج مدل بارش رواناب با شبکه عصبی مصنوعی می‌توان دریافت که مدل MLP با مقدار RMSE برابر ۰/۰۱۱۰۵، مقدار ضریب کارایی ناش ساتکلیف برابر ۰/۷۲۸۸۳ و ضریب همبستگی برابر ۰/۸۵۷۲۸ با خطای کم و همبستگی دقت و کارایی بالا می‌تواند فرآیند بارش - رواناب را مدل سازی و پیش بینی کند و این نشان دهنده قدرت ساختار عصبی مدل در آموزش مدل است و با نتایج نصری و همکاران (۱۳۸۸؛ ۱۳۸۹)، جعفرطباطبایی و همکاران (۱۳۸۹)، صف شکن و همکاران (۱۳۹۰)، ثنائی فر و همکاران (۱۳۹۱)، عظیمی و عرب (۱۳۹۳) و ذونعمت کرمانی و همکاران (۲۰۱۳) همسو است. نتایج کاربرد شبکه عصبی مصنوعی در پیش بینی دبی خروجی حوزه آبخیز کورکورس بسیار امیدوارکننده بود و پیش بینی دبی با دقت بالای و خطای کم توسط مدل انجام شد. بهترین پیش بینی با ترکیب (بارش روز جاری، بارش روز قبل و دبی روز قبل، دبی دو روز قبل و دبی سه روز قبل) انجام می‌شود و در صورت نبود داده های دبی ترکیب (بارش جاری و بارش روز قبل) نیز به طور قابل قبولی می‌تواند دبی خروجی را پیش بینی کند.

## پیشنهادات

۱. سیستم استنتاج عصبی فازی تطبیقی برای پوشش عدم قطعیت ها در مدل سازی بارش رواناب بررسی شود.
۲. جهت افزایش کارایی مدل‌های ANN از تابع موجک برای تجزیه سری زمانی با مقیاس‌های مختلف استفاده شود.
۳. خصوصیات فیزیکی و ژئومورفولوژیک حوزه آبخیز جهت بررسی امکان بهبود کارایی، قابلیت بررسی دارد.
۴. اثر دما، تبخیر و رطوبت نسبی در حوضه های با میانگین دما و رطوبت نسبی بالا به عنوان ورودی بررسی شود.



## مراجع

- ۱- اعلمی، محمد تقی، حسین زاده، حجت (۱۳۸۹) «مدل سازی فرآیند بارش - رواناب در حوضه ليقوان چای با استفاده از نرون شرطی آستانه دمایی» مجله دانش آب و خاک، جلد ۲۰/۱ (۲).
- ۲- اعلمی، محمد تقی، ملکانی، لیلا، امامی، سپیده (۱۳۹۱) «مقایسه کارایی روش‌های سیستم فازی - عصبی تطبیقی و شبکه بیزین در شبیه سازی رواناب» نهمین کنگره بین‌المللی مهندسی عمران، دانشگاه صنعتی اصفهان.
- ۳- اعلمی، محمد تقی، صادق فام، سینا، فاضلی فرد، محمدحسن، تقی پور، لیلا (۱۳۹۲) «مدل سازی سری داده‌ها» انتشارات دانشگاه تبریز، چاپ اول، ص ۹۸ و صص ۱۰۷ تا ۱۰۸.
- ۴- احمدنژاد، امین رضا (۱۳۸۴) «شبیه سازی فرایند بارش - رواناب ومولفه های بیلان آب در حوضه ی آبریز رودخانه ها» پایان نامه کارشناسی ارشد دانشگاه مازندران ص ۴.
- ۵- ابراهیمی، زهرا (۱۳۸۵) «ارزیابی و واسنجی مدل های نسبت تحویل رسوب SDR (مطالعه موردی حوزه آبخیز کورکورسر)» پایان نامه کارشناسی ارشد آبخیزداری. دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران. فصل ۳ ص ۲.
- ۶- ثنائی فر، ملیکا، طاهری شهرآئینی، حمید، میرباقری، سید احمد، شیخی، رضا (۱۳۹۱) «شبیه سازی بارش - رواناب روزانه رودخانه جلا» همایش ملی جریان و آلودگی آب، دانشگاه تهران.
- ۷- جعفرطباطبایی، بهرام، اژدری مقدم، مهدی، فلاح حقگو لبالستانی، محمد رضا (۱۳۸۹) «بررسی تأثیر پارامترهای ورودی بر عملکرد مدل‌های شبکه عصبی مصنوعی بارش - رواناب در حوزه آبریز طرق - خراسان رضوی» نهمین کنفرانس هیدرولیک ایران، تهران، انجمن هیدرولیک ایران، دانشگاه تربیت مدرس.
- ۸- ذرتی پور، امین، سلاجقه، علی، المعالی، نگار، عسگری، حسین محمد (۱۳۸۸) «بررسی مدل بارش - رواناب با استفاده از روش‌های شبکه عصبی مصنوعی و رگرسیون دو متغیره آماری (مطالعه موردی در حوزه آبخیز میناب)» پژوهش‌های آبخیزداری، ۸۳.
- ۹- طاهرشمسی، احمد، عباس زاده، پیمان، اسدی، شاهرخ (۱۳۹۱) «مدل سازی بارش - رواناب با استفاده از ۲ مدل مختلف شبکه عصبی مورد مطالعاتی: حوزه آبریز آقچای واقع در استان آذربایجان غربی» یازدهمین کنفرانس هیدرولیک ایران، دانشگاه ارومیه.
- ۱۰- عظیمی، وحید، عرب، صفورا (۱۳۹۳) «مقایسه مدل‌های هوشمند در شبیه سازی بارش رواناب روزانه حوضه ليقوان - آذربایجان شرقی» پانزدهمین کنفرانس دانشجویان عمران سراسر کشور، ارومیه، انجمن علمی دانشجویی عمران دانشگاه ارومیه.
- ۱۱- صف شکن، فرشید، پیرمادیان، نادر، افشین شریفان، رضا (۱۳۹۰) «شبیه سازی آب نمود بارش - رواناب با توجه به الگوی زمان بارش و استفاده از شبکه عصبی مصنوعی در حوزه آبریز معرف کسلیان» علوم و مهندسی آبخیزداری ایران، ۵ (۱۵).
- ۱۲- قادری، کمال (۱۳۹۳) «شبیه سازی فرآیند بارش رواناب با استفاده از شبکه مصنوعی و سیستم استنتاج عصبی فازی تطبیقی مبتنی بر ژنومورفولوژی در حوزه آبخیز چالوس» پایان نامه کارشناسی ارشد، دانشگاه آزاد اسلامی واحد نورص ۷۶.
- ۱۳- دستورانی، محمدتقی، شریفی دارانی، حامد، طالبی، علی، مقدم نیا، علیرضا (۱۳۹۰) «کارایی روش‌های شبکه عصبی مصنوعی و سیستم استنتاج عصبی - فازی در مدل سازی بارش - رواناب در حوضه آبخیز سد زاینده رود» آب و فاضلاب، (۴) : ۱۱۴ - ۱۲۵.
- ۱۴- کارآموز، محمد، عراقی نژاد، شهاب (۱۳۹۳) «هیدرولوژی پیشرفته» چاپ سوم، انتشارات دانشگاه صنعتی امیرکبیر، ص ۱۸۵.
- ۱۵- کیا، سید مصطفی (۱۳۹۱) «شبکه های عصبی در MATLAB» انتشارات کیان رایانه سبز، چاپ دوم، ص ۸۳.
- ۱۶- میرزایی، محمد رضا، خزایی، مجید (۱۳۹۰) «مدل سازی بارش - رواناب (تأثیر تغییر پارامترهای شبکه در میزان دقت پیش بینی) (مطالعه موردی: حوزه آبخیز زهره)» پنجمین کنفرانس سراسری آبخیزداری و مدیریت منابع آب و خاک، کرمان.



- ۱۷- مهدوی، محمد (۱۳۸۱) «هیدرولوژی کاربردی، انتشارات دانشگاه تهران» جلد اول، چاپ چهارم، ص ۲۴۷.
- ۱۸- نصری، مسعود، مدرس، رضا، دستورانی، محمدتقی (۱۳۸۸) «کاربرد مدل شبکه عصبی در برآورد رواناب مطالعه موردی: حوضه آبریز پلاسجان - حوضه آبریز زاینده رو» آمایش محیط، ۲(۵).
- ۱۹- نصری، مسعود، مدرس، رضا، دستورانی، محمدتقی (۱۳۸۹) «اعتبارسنجی مدل شبکه عصبی مصنوعی رابطه بارندگی - رواناب در حوضه آبریز سد زاینده رود» پژوهش‌های آبخیزداری، (۸۸).
- ۲۰- نورانی، وحید، صالحی، کامران (۱۳۸۷) «مدل سازی بارش - رواناب با استفاده از روش شبکه عصبی فازی تطبیقی و مقایسه آن با روش‌های شبکه عصبی و استنتاج فازی مطالعه موردی: حوضه آبریز لیقوان چای واقع در استان آ.شرقی» چهارمین کنگره ملی مهندسی عمران، دانشگاه تهران.

- 21- 21Chen, Y. H., Chang, F. J. (2009). *Evolutionary artificial neural networks for hydrological systems forecasting*. Journal of Hydrology, 367(1), 125-137.
- 22- Zadeh, L.A. (1965). *Fuzzy Sets*. Information and Control, 8: 338-353.
- 23- Mutlu, E., Chaubey, I., Hexmoor, H., Bajwa, S.G.( 2008). *Comparison of artificial neuralnetwork models for hydrologic predictions at multiple gauging stations in an agricultural watershed*. Hydrol. Process, 22, 5097-5106.
- 24- Nourani, V., Kalantari, O. (2010). *Integrated artificial neural network for spatiotemporal modeling of rainfall-runoff-sediment processes*. Environ. Eng Sci. 27 (5), 411-422.
- 25- Nourani, V., Komasi, M. A geomorphology-based ANFIS model for multi-station modeling of rainfall-runoff process. Journal of Hydrology.(2013). 490, 41-55.
- 26- Nourani, V., Baghanam, A. H., Adamowski, J., Kisi, O.( 2014). *Applications of hybrid wavelet-Artificial Intelligence models in hydrology: A review*. Journal of Hydrology, 514, 358-377.
- 27- Nash, J. and Sutcliffe, J. (1970). *River Flow Forecasting Through Conceptual Models Part I- A Discussion of Principles*. Journal of Hydrology, (10): 282-290.
- 28- Vafakhah, M.( 2012).Application of artificial neural networks and adaptive neuro-fuzzy inference system models to short-term streamflow forecasting. Canadian Journal of Civil Engineering, 39: 402-414
- 29- Zounemat-Kermani, M., Kisi, O., Rajaei, T.( 2013). *Performance of radial basis and LM-feed forward artificial neural networks for predicting daily watershed runoff*. Applied Soft Computing, 13(12), 4633-4644



## Simulation of Rainfall-Runoff Process Using Artificial Neural Network in Kurkursar Watershed, Nowshahr

Kamal Ghaderi<sup>1\*</sup>, Baharak Motamedvaziri<sup>2</sup>, Parvaneh Mahmudi<sup>3</sup>

1. Ph.D Candidate in Watershed Management Science and Engineering, Islamic Azad University - Science and Research Branch, kamalghaderi1986@gmail.com
2. Assistant Professor, Department of Watershed Management, Islamic Azad University - Science and Research, bmvaziri@gmail.com
3. Ph.D Student in Watershed Management Science and Engineering, Islamic Azad University - Science and Research Branch, Parvenehmahmudi65@gmail.com

### Abstract

The correct prediction of hydrological phenomena such as rainfall-runoff process can provide effective information for city planning, land use and water resource management of a watershed. It also plays an important role in mitigating the impacts of flood or drought on water resources systems. This research has been conducted in order to investigate the efficiency of Artificial Neural Network in simulating the rainfall-runoff process and identify the effect of using runoff as an input in the model efficiency. The results indicate that MLP model with RMSE=0.01105, NSE=0.72883 and R=0.85728 could model and simulate rainfall-runoff process with low error and high precision. The compositions which include runoff as an input as well as rainfall showed better performance than those which had only rainfall as an input. The best composition of rainfall and runoff was (rainfall at the current time, 1-day lag rainfall, 1-day lag discharge, 2-day lag discharge, and 3-day lag discharge). In the case of lack of discharge data, the composition (rainfall at the current time and 1-day lag rainfall) can predict outlet discharge in an acceptable manner.

**Keywords:** Rainfall-Runoff, Black Box Mode, Artificial Intelligence, ANN, Kurkursar