

کاربود مدل‌های شبکه عصبی مصنوعی و مدل M5 در شبیه‌سازی جریان ماهانه (مطالعه موردی: رودخانه استور)

الهام رفیعی ساردوئی

دانشجوی دکتری آبخیزداری، دانشکده منابع طبیعی دانشگاه تهران، تهران، ایران

فرشاد سلیمانی ساردو^۱

مرتبی دانشکده منابع طبیعی، دانشگاه جیرفت، جیرفت، ایران

علی آذره

دانشجوی دکتری بیابان‌زدایی، دانشکده منابع طبیعی دانشگاه تهران، تهران، ایران

تاریخ پذیرش مقاله: ۱۳۹۵/۰۴/۳۰

تاریخ دریافت مقاله: ۱۳۹۵/۰۲/۱۳

چکیده

مدیریت موثر منابع آبی در یک رودخانه نیازمند شناخت صحیح و کامل از فرآیندهایی است که در آن رخ می‌دهد. روش‌های هوش مصنوعی می‌توانند کارایی بالایی جهت شبیه‌سازی جریان رودخانه در مقیاس‌های مختلف زمانی و مکانی داشته باشند. در این مطالعه از روش شبکه عصبی مصنوعی و مدل نمودار درختی M5 جهت شبیه‌سازی ماهانه جریان رودخانه در ایستگاه استور استفاده گردید. جهت شبیه‌سازی داده‌های دبی ایستگاه، از داده‌های دبی ثبت شده در چهار ایستگاه هیدرومتری بالادست و یک ایستگاه اقلیمی استفاده گردید. جهت مقایسه نتایج دو روش شبکه عصبی مصنوعی و مدل M5، از دو معیار مجدور میانگین مربعات خطأ و ضریب تبیین استفاده گردید. نتایج نشان داد شبکه عصبی مصنوعی با ساختار یک لایه مخفی با چهار نرون کارایی بیشتری نسبت به مدل M5 دارد. خطای مدل شبکه عصبی مصنوعی ۲۵/۴۰ با ضریب همبستگی ۰/۹۳ و خطای مدل M5 ۰/۹۲ با ضریب همبستگی ۰/۸۱۸ متصوّر می‌گردند. با افزایش نرون‌های محاسباتی در لایه مخفی کارایی شبکه عصبی مصنوعی کاهش یافت.

واژگان کلیدی: شبکه عصبی مصنوعی، مدل M5، جریان ماهانه، استور.

مقدمه

ثبت و تحلیل داده‌های رودخانه اهمیت بسیار زیادی در برنامه‌ریزی، طراحی و مدیریت منابع آبی در یک حوزه ایفا می‌کند (Turan, ۲۰۰۹). پیش‌بینی جریان رودخانه به عنوان یک جز اصلی در مدیریت سیلاب مورد نیاز است، از این رو دستیابی به روش‌های مطمئن پیش‌بینی جریان رودخانه‌ها به منظور برنامه‌ریزی در بهره برداری به موقع از منابع آب از اهمیت روزافزونی برخوردار است. در مناطق بدون سدهای مخزنی و نیز در مناطقی که جریان رودخانه با تاسیسات ویژه‌ای کنترل می‌شود، مدل‌های پیش‌بینی جریان رودخانه‌ها به عنوان ابزار مناسبی در برنامه‌ریزی و مدیریت منابع آب مورد بهره‌گیری قرار می‌گیرند.

در نتیجه پیچیدگی و ابهام پدیده‌ها، تاکنون روش قطعی جهت پیش‌بینی جریان رودخانه وجود ندارد. از سوی دیگر کمبود آب در ترکیب با تغییرات اقلیمی و گرمایش جهانی برآورد دقیق از جریان رودخانه را ایجاد می‌کند. علاوه بر روش‌های مبتنی بر تحلیل سری‌های سری زمانی، تکنیک‌های هوش مصنوعی^۱ از جمله شبکه عصبی مصنوعی (ANN) و منطق فازی^۲ (FL) به فراوانی مورد استفاده قرار می‌گیرد. اگرچه مدل‌های فیزیکی و مفهومی در فهم فرآیندهای هیدرولوژیک بسیار مهم هستند، با این وجود موقعیت‌هایی وجود دارد که در آن‌ها هدف اصلی پیش‌بینی‌های صحیح در نقاط مشخص مدنظر مدیران می‌باشد. در چنین شرایطی به کارگیری یک مدل جعبه سیاه^۳ ساده جهت مشخص کردن ارتباط بین ورودی و خروجی بدون در نظر گرفتن جزئیات ساختار درونی سیستم فیزیکی می‌تواند سودمند باشد. از جمله مدل‌های جعبه سیاه برای پیش‌بینی پاسخ هیدرولوژیک (رواناب) یک حوزه آبخیز بر اساس سری‌های زمانی هیدرولوژیک و اقلیمی می‌تواند به کارگیری شبکه عصبی مصنوعی باشد. سولوماتین و تورس (۱۹۹۶) روش شبکه عصبی مصنوعی را جهت مدل‌سازی هیدرولوژیک در حوزه رودخانه آپور در ونزوئلا به کار گرفتند. روش شبکه عصبی مصنوعی کاربردهای مختلفی را در علوم هیدرولوژیک داشته است که عبارتند از از پیش‌بینی سیل (See و همکاران، ۱۹۹۷)، پیش‌بینی رسوب (Cigizoglu, ۲۰۰۲)، مدل‌سازی بارندگی رواناب (Shamseldin, ۱۹۹۶؛ Furundzic, ۱۹۹۷؛ Sajikumar, ۱۹۹۸؛ Abrahart, ۱۹۹۹؛ Minns, ۲۰۰۱) و Alp (۲۰۰۴).

یکی دیگر از روش‌های داده‌کاوی استفاده مدل نمودار درختی M5 است که در طول دهه‌های گذشته در مدیریت منابع آب مورد استفاده قرار گرفته است (Stravas, Solomatine, ۲۰۰۵؛ ۲۰۰۷) و در بعضی موارد نتایج مشابه و یا بهتر از مدل شبکه عصبی مصنوعی داشته‌اند.

Tokar (۱۹۹۹) روش شبکه عصبی مصنوعی را درک حوزه آبخیز رودخانه پاتوزنت ۲ در ایالت مریلند آمریکا به عنوان یک تابعی از بارندگی روزانه، درجه حرارت و ذوب برف به کار برdenد. نتایج پژوهش نشان داد که مدل‌سازی بارش-رواناب با استفاده از شبکه عصبی مصنوعی نتایج مطلوب تری نسبت به مدل‌های معادله‌ی همبستگی و مفهومی ساده ارایه می‌نماید.

¹-Artificial intelligent systems (AIS)

²-fuzzy logic

³-Black box

Xiong (۱۹۹۹) کاربرد مدل شبکه عصبی در پیش‌بینی سیل در حوزه کارستی فرگوس کشور ایرلند را مورد مطالعه و بررسی قرار دادند. نتیجه نشان داد که آن مدل می‌تواند برای پیش‌بینی سیل در حوزه‌های کارستی استفاده بشود زیرا در آن مناطق روابط بارش-رواناب غیر خطی و پیچیده می‌باشد.

Toker و Markus (۲۰۰۰) با استفاده از شبکه عصبی مصنوعی رابطه بارندگی-رواناب را برای پیش‌بینی جریان ماهانه در سه حوزه‌ی آبخیز با شرایط آب و هوا بی و فیزیوگرافی متفاوت در مرلند آمریکا مدل سازی کرده و نتایج حاصله را با مدل Watbal مقایسه کردند. نتایج نشان داد مدل شبکه عصبی مصنوعی در همه موارد دارای کارایی بالاتری است.

Dibek و Solumtin (۲۰۰۶) با استفاده از شبکه عصبی مصنوعی پرسپترون چند لایه و شبکه عصبی شعاعی روابط بارش-رواناب را در حوزه آپور و نزوئلا شبیه سازی کردند. آن‌ها نتیجه گرفتند که شبیه سازی جریان رودخانه با شبکه عصبی شعاعی از دقت بالاتری نسبت به شبکه عصبی مصنوعی پرسپترون چند لایه برخوردار است.

Shrivastava و صالحی (۱۳۸۴) برای پیش‌بینی جریان رودخانه‌های کشفرود و هریروود در حوضه کارده با دو مرحله پیش‌بینی روزانه و ماهانه، از شبکه عصبی مصنوعی پرسپترون چند لایه استفاده کردند. همچنین، برای ارزیابی مدل ساخته شده با شبکه عصبی مصنوعی، از مدل HEC۴ استفاده شد. نتایج نشان داد که در این حوضه، مدل شبکه عصبی مصنوعی روزانه دقت بیشتری در قیاس با مدل ماهانه دارد. با مقایسه نتایج حاصل از شبیه‌سازی توسط HEC۴ و همچنین شبکه عصبی دیده شد که با شبکه عصبی بسیار بهتر و دقیق‌تر جریان رودخانه تخمین زده می‌شود و عملکردی به مراتب بهتر از خود نشان می‌دهد.

در این مطالعه سعی گردیده است توانایی مدل شبکه عصبی مصنوعی و مدل نسودار درختی M5 در شبیه‌سازی جریان ماهانه رودخانه استور با استفاده از داده‌های ایستگاه‌های آب‌سنجدی و اقلیمی بالادست حوزه مورد بررسی قرار گیرد و به مقایسه نتایج آن‌ها پرداخته شود.

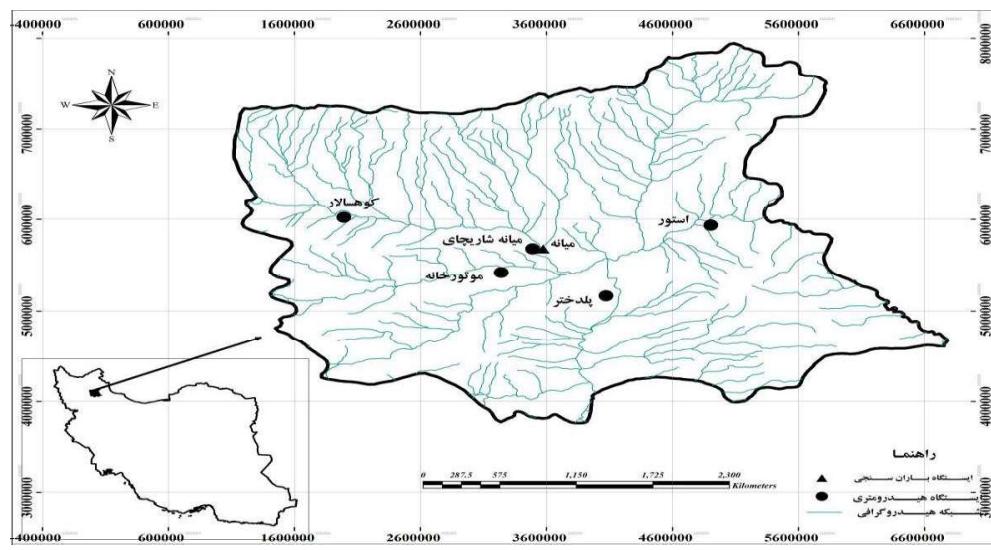
مواد و روش‌ها

منطقه مورد مطالعه

جهت انجام این تحقیق از داده‌های ماهانه دبی و بارش مربوط به ۴ ایستگاه هیدرومتری و یک ایستگاه سینوپتیک واقع در جنوب شرق آذربایجان شرقی استفاده گردید. موقعیت جغرافیایی منطقه مورد مطالعه در شکل ۱ نشان داده شده است. ایستگاه ایستور در خروجی حوزه قرار گرفته است و ۴ ایستگاه هیدرومتری کوه‌سالار، میانه شاریچای، موتورخانه و پلدختر و ایستگاه سینوپتیک میانه در بالادست این ایستگاه قرار دارند و در تعیین دبی خروجی از آن مشارکت دارند. مشخصات ایستگاه‌های مورد استفاده در جدول ۱ نشان داده شده است.

جدول ۱- مشخصات ایستگاه‌های مورد استفاده در این مطالعه

نام ایستگاه	طول جغرافیایی	عرض جغرافیایی	میانگین
پلدختر	۳۷°۵۲'	۴۸°۰۴'	۵۰/۹۲
موتورخانه	۳۷°۵۲'	۴۷°۵۴'	۴/۷۰
میانه (هیدرومتری)	۳۷°۵۳'	۴۷°۰۳'	۵/۱۹
میانه (سینوپتیک)	۳۷°۵۷'	۴۷°۰۴'	۲۲/۵۱
استور	۳۷°۵۰'	۴۷°۰۵'	۸۱/۱۹



شکل ۱. موقعیت جغرافیایی ایستگاه‌های هیدرومتری و سینوپتیک واقع در منطقه مورد مطالعه

داده‌های به کار برده شده در این تحقیق شامل ۱۹ سال اطلاعات ماهانه مربوط به داده‌های دبی^۴ ایستگاه هیدرومتری و یک ایستگاه سینوپتیک می‌باشد. از تابع زیر جهت مقیاس کردن ورودی‌ها و خروجی‌ها قبل از ورود به مدل‌های هوش مصنوعی استفاده گردید.

$$Z = \frac{2 * (X_i - X_{\min})}{(X_{\max} - X_{\min})} - 1 \quad (1)$$

در معادله بالا Z مقادیر استاندارد شده بین -1 و $+1$ و X_{\max} و X_{\min} به ترتیب کمترین و بیشترین مقدار ورودی و خروجی می‌باشد.

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی متفاوت از سیستم‌های معمولی از جمله مدل‌های آماری و یا تحلیلی می‌باشند. یک شبکه عصبی مصنوعی متشکل از تعداد دلخواه از عناصر بسیار ساده می‌باشد که گره نامیده می‌شود. هر گره یک عنصر بسیار ساده پردازشگر است که به ورودی‌های با وزن‌های مختلف که از گره‌های دیگر دریافت می‌کند، پاسخ می‌دهد. تا کنون شبکه‌های عصبی مختلف با الگوریتم‌های مختلف در مطالعات هیدرولوژی مورد استفاده قرار گرفته است. در این مطالعه شبکه‌های پرسپترون چندلایه پیش‌خور با روش آموزش پس انتشار خطأ^۱ مورد استفاده قرار گرفته است. انتخاب این نوع از شبکه‌های عصبی مصنوعی به این دلیل بوده است که در تحقیقات قبل، عملکرد بهتر این نوع شبکه‌ها نسبت به انواع دیگر شبکه‌های عصبی در زمینه هیدرولوژی و منابع آب به ثبات رسیده است (Alp Cigizoglu, ۲۰۰۸).

M5 مدل

مدل درختی بسط یافته مفهوم رگرسیون درختی است که مقادیر ثابتی را در برگ‌ها دارد (ویتن و فرانک، ۲۰۰۵) که قابل مقایسه با توابع خطی تکه‌ای می‌باشد. مدل درختی M5 یک مدل تصمیم‌گیری دوتایی با توابع

¹ Back Propagation

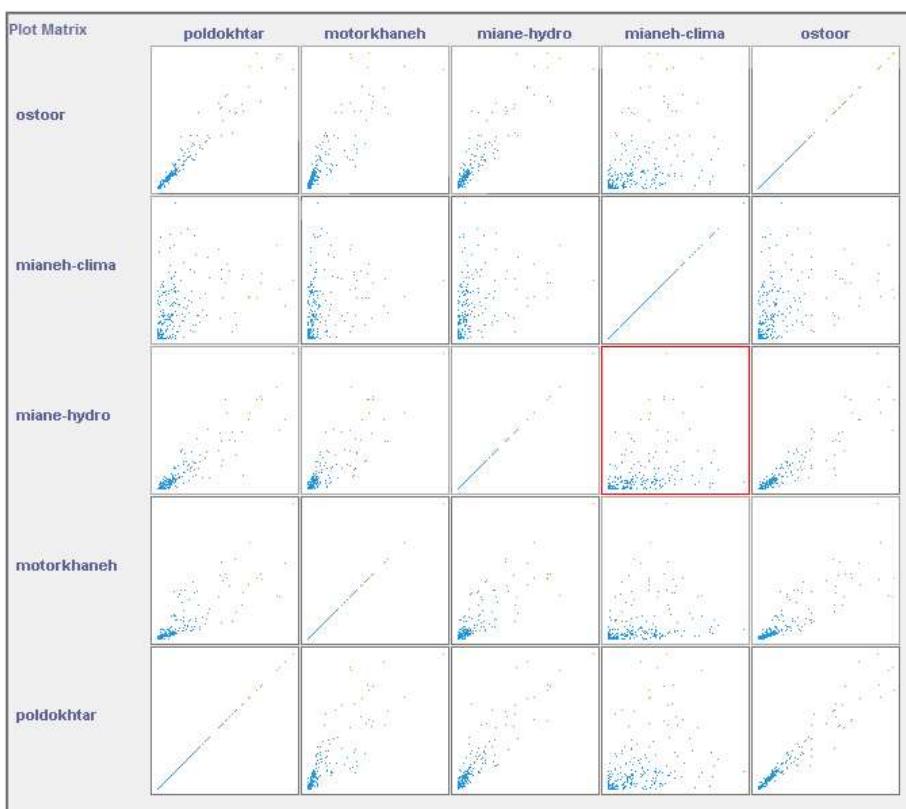
رگرسیونی خطی در گره‌های انتهایی است که قابلیت پیش‌بینی متغیرهای پیوسته را دارد می‌باشد. مدل‌های درختی بر اساس روش حل و تقسیم ایجاد می‌شوند. ایجاد یک مدل درختی متشکل از دو مرحله است. در مرحله اول با استفاده از یک معیار تقسیم، نمودار درختی ایجاد می‌شود. معیار تقسیم در الگوریتم درختی مدل M5 بر اساس تخفیف میزان انحراف معیار که به عنوان شاخصی از خطای هر گره می‌رسد و محاسبه کاهش قابل انتظار خطای آن گره در نتیجه آزمون متغیر مورد نظر در آن گره می‌باشد. معادله کاهش میزان انحراف معیار به شکل زیر می‌باشد:

$$SDR = \frac{sd(T)}{\sum |T_i|} sd(T_i) \quad (2)$$

در معادله بالا T نشان‌دهنده نمونه‌هایی است که هر گره می‌رسد. T_i نشان‌دهنده مجموعه‌هایی هستند که از تقسیم کردن گره بر اساس صفت انتخابی به دست آمدند. Sd بیانگر انحراف معیار می‌باشد. پس از بررسی تمام انشعاب‌های موجود مدل M5 انشعاب‌هایی را انتخاب می‌کند که بیشترین کاهش میزان خطای را داشته‌اند. این روند تقسیم کردن ممکن است باعث ایجاد ساختار درختی بزرگی شود که منجر به بیش برآش می‌گردد. جهت رفع این مشکل هرس کردن درخت باید انجام شود که اینکار با جایگزینی زیردرخت با یک برگ صورت می‌گیرد. بنابراین مرحله دوم در طراحی یک مدل درختی شامل هرس کردن درخت برگ و جایگزینی زیردرخت‌ها با توابع رگرسیونی خطی است. این روش ایجاد مدل درختی فضای نمونه را به چندین بخش (زیرمجموعه) تقسیم می‌کند و در هر یک از آن‌ها یک مدل رگرسیونی درختی ایجاد می‌شود. جزئیات بیشتر این روش در کوئینلن (1992) شرح داده شده است.

نتایج و بحث

جدول ۱ نشان‌دهنده مشخصات ایستگاه‌های مورد استفاده در این تحقیق و نیز مشخصات سری‌های زمانی هیدرولوژیک و اقلیمی مربوط به هر یک از ایستگاه‌ها می‌باشد. در این مطالعه از روش شبکه عصبی مصنوعی و مدل نمودار درختی M5 جهت شبیه‌سازی جریان ماهانه رودخانه در محل ایستگاه استور استفاده گردید. با توجه به استفاده از داده‌های بارش و دبی مربوط به عنوان متغیرهای ورودی جهت شبیه‌سازی متغیر خروجی (دبی) لذا جهت یکسان‌سازی ابعاد داده‌های ورودی داده‌ها بین ۱- و +۱ استاندارد شدند. داده‌های مورد استفاده به دو بخش تقسیم شد. هشتاد درصد از داده‌ها (شامل ۱۸۲ داده مشاهده‌ای) جهت آموزش مدل‌ها و ۲۰ صدر داده‌ها (۴۶ داده مشاهده‌ای) جهت صحبت‌سنگی مدل‌ها مورد استفاده قرار گرفت. دو معیار ارزیابی معیار همبستگی (R2) و میانگین مجازور مربعات خطای (RMSE) جهت ارزیابی مدل‌ها مورد استفاده قرار گرفت. با توجه به اینکه پارامترهای ورودی مقیاس متفاوتی دارند لذا قبل از ورود به مدل در یک بازه عددی خاصی استاندارد گردیدند. این مقیاس‌سازی ورودی‌ها جهت افزایش کارایی تابع تاثرات سیگموئید در شبکه عصبی مصنوعی نیز موثر می‌باشد. قبل از بکارگیری مدل‌های شبکه عصبی مصنوعی و مدل نمودار درختی M5 ابتدا پلات ماتریکس متغیرهای ورودی و خروجی ترسیم گردید تا تغییرات سری زمانی متغیر خروجی در مقابل متغیرهای ورودی مشخص گردد.



شکل ۲-پلات ماتریکس همبستگی بین متغیرهای ورودی و متغیر خروجی

ماتریکس پلات سری زمانی دبی ماهانه جریان در محل ایستگاه استور در مقابل سری‌های زمانی جریان ماهانه رودخانه در ایستگاه‌های بالادست و نیز بارندگی ماهانه ایستگاه سینوپتیک بالادست حوزه در شکل ۲ نشان داده شده است. با توجه به شکل سری زمانی متغیر پاسخ (جریان رودخانه در محل ایستگاه استور) همبستگی بیشتری با سری‌های زمانی جریان رودخانه در ایستگاه‌های بالادست نسبت به سری زمانی بارندگی ماهانه در ایستگاه سینوپتیک بالادست نشان می‌دهد. به طوریکه بیشترین همبستگی سری زمانی جریان ماهانه در ایستگاه ایستگاه پلدختر و سپس به ترتیب ایستگاه هیدرومتری میانه و موتورخانه می‌باشد. کمترین میزان همبستگی نیز مربوط به ایستگاه سینوپتیک میانه می‌باشد. با توجه به شکل یک نیز مشخص می‌شود ایستگاه پلدختر نزدیکترین ایستگاه به ایستگاه استور می‌باشد.

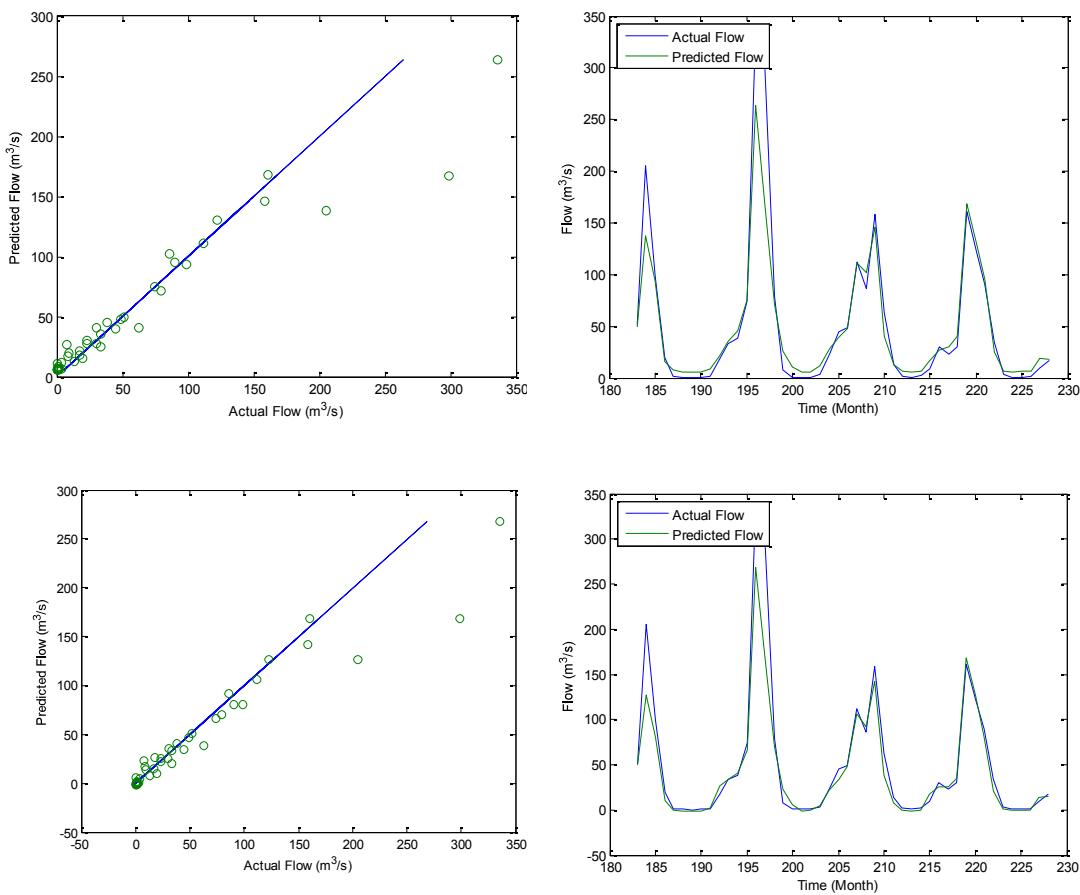
با توجه به نتایج ارائه شده در شکل ۲ مشخص می‌شود همبستگی دبی-دبی بیشتر از میزان همبستگی بارش-دبی می‌باشد. به طوریکه همبستگی بین سری زمانی بارش با سری زمانی دبی کمترین میزان را داشته است. جهت شبیه‌سازی جریان ماهانه رودخانه در ایستگاه استور از شبکه عصبی مصنوعی و نمودار درختی M5 استفاده گردید. معماری شبکه عصبی مصنوعی با انتخاب تعداد لایه‌های مخفی و تعداد نرون‌های مخفی آغاز شد. عموماً یک لایه مخفی می‌تواند جهت شبیه‌سازی هر نوعتابع خطی پیچیده با دقت مورد نظر به کار گرفته شود. در مورد تعداد نرون‌ها در لایه مخفی تعدادی از مطالعات $2m+1$ نرون (لیپمن، ۱۹۸۷) بعضی از آنها $2m$ (وانگ، ۱۹۹۱) و تعدادی نیز m (تانگ و فیش ویگ، ۱۹۹۳) نرون در لایه مخفی را مناسب دانسته‌اند. بر اساس تعداد ورودی‌های

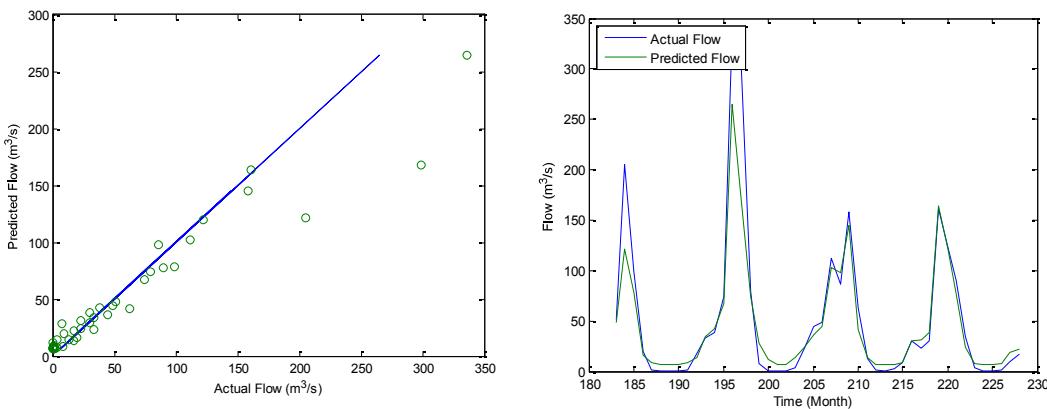
مدل تعداد نرون‌های لایه مخفی تعیین می‌گردد. با در نظر گرفتن تعداد چهار متغیر ورودی در این مطالعه سه سناریو در معماری شبکه عصبی مصنوعی در این مطالعه مورد لحاظ قرار گرفت. در سناریوی اول نه نرون در لایه مخفی، در سناریو دوم هشت نرون و در سناریوی سوم چهار نرون در لایه مخفی مورد استفاده قرار گرفت و در هر بار اجرای مدل، مقادیر خطای مدل مورد محاسبه قرار گرفت. نتایج خطای مدل شبکه عصبی مصنوعی در سناریوهای مختلف در جدول ۲ ارائه شده است جهت تعیین شبکه عصبی مصنوعی از الگوریتم لونبرگ-مارگرات و ۳۰۰ دور آموزش استفاده گردید.

جدول ۲- تعیین بهترین ساختار شبکه عصبی مصنوعی با استفاده از فرآیند آزمون و خطا

تعداد نرون مخفی	آموزش		صحت سنجی	
	RMSE	R ²	RMSE	R ²
۹	۱۸/۳۷	۰/۹۷	۲۳/۶۲	۰/۸۶
۸	۲۱/۸۱	۰/۹۶	۲۵/۶۴	۰/۹۳
۴	۲۱/۰۲	۰/۹۷	۲۵/۴۰	۰/۹۳

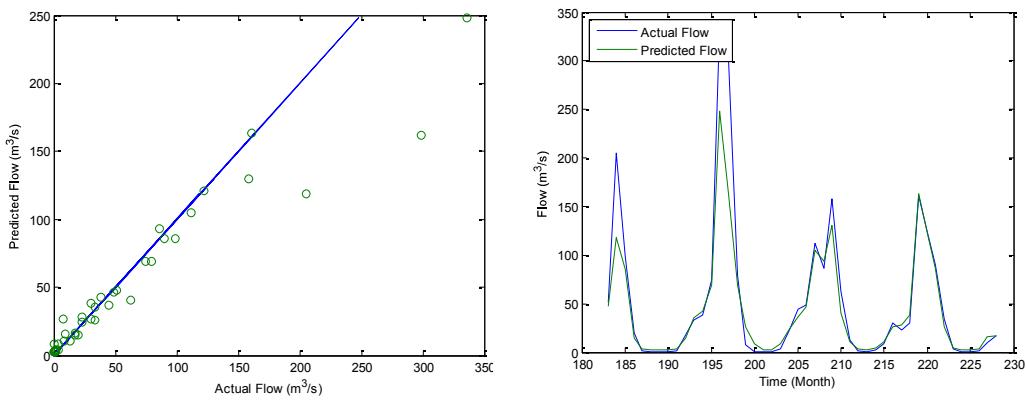
منبع: یافته‌های پژوهش





شکل ۳- نتایج شبیه‌سازی مدل شبکه عصبی با چهار، هشت و نه نرون در لایه مخفی منبع: یافته‌های پژوهش

نتایج آموزش و صحت سنجی مدل‌های شبکه عصبی مصنوعی با ۴، ۸ و ۹ نرون در لایه مخفی در جدول ۲ آورده شده است. با توجه به نتایج جدول مشخص می‌شود با افزایش تعداد نرون در لایه مخفی خطای مدل بالا می‌رود. به طوریکه کمترین خطای مدل وقتی حاصل می‌شود که تعداد نرون در لایه مخفی برابر با تعداد ورودی‌های مدل انتخاب می‌شود. بیشترین خطای مدل نیز وقتی حاصل می‌شود که تعداد نرون در لایه مخفی برابر با ۹ نرون انتخاب شود. بنابراین ساختار شبکه عصبی با یک لایه مخفی با چهار نرون انتخاب گردید و جهت شبیه‌سازی جریان ماهانه رودخانه با استفاده از داده‌های دبی و بارش ایستگاه‌های بالادست مورد استفاده قرار گرفت و نتایج آن با نتایج شبیه‌سازی مدل M5 مورد مقایسه قرار گرفت. نتایج شبیه‌سازی مدل شبکه عصبی مصنوعی با تعداد نرون‌های مختلف در شکل ۳ آورده شده است.



شکل ۴- نتایج شبیه‌سازی مدل M5 منبع: یافته‌های پژوهش

پس از انتخاب بهترین مدل شبکه عصبی مصنوعی، از شبکه مذکور جهت شبیه‌سازی داده‌های دبی ماهانه جریان رودخانه در ایستگاه استور استفاده گردید و نتایج آن با نتایج شبیه‌سازی مدل M5 مورد مقایسه قرار گرفت. نتایج شبیه‌سازی مدل درختی M5 در شکل ۴ آورده شده است. با توجه به شکل مشخص است مدل مذکور توانایی بالایی در شبیه‌سازی جریان رودخانه با استفاده از داده‌های جریان و بارش در بالادست داشته است. با توجه به نتایج شکل ۳ و ۴ (شکل سمت چپ) مشخص است که پراکندگی داده‌های مشاهده‌ای و پیش‌بینی شده در دنباله بالایی کاهش پیدا کرده است. بخش سمت راست شکل ۳ و ۴ نیز موید همین مطلب است به طوریکه تطابق داده‌های مشاهده‌ای و

پیش‌بینی شده برای دبی‌های اوج در هر دو روش کاهش یافته است. در توضیح این مطلب می‌توان گفت هر دو روش شبکه عصبی مصنوعی و مدل M5 در پیش‌بینی داده‌های دبی اوج (سیل) توانای کمی دارند که می‌تواند ناشی از نادیده گرفتن واقعیت‌های فیزیکی حوزه توسط این نوع از مدل‌ها باشد که یکی از نقاط ضعف این مدل‌ها همین موضوع می‌باشد.

جدول ۳- مقایسه نتایج شبیه‌سازی مدل شبکه عصبی مصنوعی و مدل M5

شبکه عصبی مصنوعی (نرون)	M5			R^2
	استور	RMSE	R^2	
	۲۸/۱۸	۰/۹۲	۲۵/۴۰	۰/۹۳

منبع: یافته‌های پژوهش

در ادامه به مقایسه نتایج مدل شبکه عصبی مصنوعی و مدل M5 پرداخته شد. نتایج شبیه‌سازی مدل M5 و شبکه عصبی مصنوعی با چهار نرون در جدول ۳ خلاصه شده است. خطای شبکه عصبی مصنوعی در شبیه‌سازی داده‌های تست ۲۵/۴۰ با ضریب همبستگی ۰/۹۳ و خطای مدل درختی M5 در شبیه‌سازی داده‌های فوق ۲۸/۱۸ با ضریب همبستگی ۰/۹۲ می‌باشد. با توجه به نتایج جدول مشخص می‌شود که شبکه عصبی مصنوعی دقت بیشتری نسبت به مدل M5 داشته است. اگرچه شبکه عصبی در شبیه‌سازی داده‌های جریان تا حدودی موقتاً از مدل درختی بوده است با این وجود مدل M5 از جهت در اختیار گذاشتن مدل‌های ساده‌تر و با ضرایب مشخص، می‌تواند قابل توجه مدیران قرار گیرد.

نتیجه‌گیری

پیش‌بینی جریان‌های رودخانه در مقیاس‌های زمانی مختلف از جمله روزانه، سالانه و ماهانه اهمیت زیادی در مدیریت و برنامه‌ریزی منابع آبی ایفا می‌کند. در این مطالعه روش‌های داده کاوی از جمله روش شبکه عصبی مصنوعی و مدل نمودار درختی M5 جهت شبیه‌سازی جریان ماهانه رودخانه در ایستگاه استور مورد استفاده قرار گرفتند. در ابتدا معماری شبکه عصبی مصنوعی با تعداد نرون‌های مختلف در سه سناریو مورد بررسی قرار گرفت و با انجام آزمون و خطا کارایی شبکه عصبی مصنوعی با تعداد نرون‌های مختلف در لایه مخفی مورد بررسی قرار گرفت. نتایج نشان داد با افزایش تعداد نرون‌های محاسباتی در لایه مخفی کارایی شبکه عصبی مصنوعی کاهش می‌یابد. به طوریکه بیشترین کارایی شبکه عصبی وقتی حاصل می‌شود که تعداد نرون محاسباتی برابر با تعداد متغیرهای ورودی به مدل انتخاب شود. با افزایش تعداد نرون محاسباتی در لایه مخفی کارایی شبکه عصبی مصنوعی کاهش یافت. در ادامه بهترین شبکه عصبی مصنوعی مخصوصی انتخاب شده جهت شبیه‌سازی داده‌های دبی ماهانه رودخانه در ایستگاه استور مورد استفاده قرار گرفت و نتایج آن با مدل نمودار درختی M5 مورد مقایسه قرار گرفت. نتایج نشان داد عملکرد شبکه عصبی مصنوعی نسبت به مدل M5 تا حدودی افزایش یافته است. با این وجود مدل M5 از جهت سهولت مدلسازی و با ضرایب مشخص در معادله امتیاز زیادی را در مدلسازی متغیرهای محیطی ایفا می‌کند. هر دو روش شبکه عصبی مصنوعی و مدل M5 در شبیه‌سازی داده‌های دبی اوج ناموفق بوده‌اند که دلیل آن ناتوانی آنها در درک فرآیندهای فیزیکی موجود در حوره آبخیز است. جریان رودخانه تحت تاثیر عوامل متعددی از جمله هیدرولوژی ذوب برف و نوسانات آب زیر زمینی می‌باشد که این عوامل توسط این مدل‌ها در نظر گرفته نمی‌شود و

ضعف اصلی این مدل‌ها نیز همین امر می‌باشد. با این وجود این مدل‌ها جهت برآورده جریان در نقاط خاص و بدون آمار هیدرومتری می‌توانند نقش مهمی داشته باشند.

منابع

- شریفی م. و صالحی سده ر. ۱۳۸۴. کاربرد شبکه‌های عصبی در پیش‌بینی جریان رودخانه در حوزه معرف کارده. کمیته تحقیقات شرکت سهامی آب منطقه‌ای خراسان. دفتر فنی و پژوهش‌های کاربردی شرکت مدیریت منابع آب ایران.
- Abrahart, R. J. , See, L. , Kneal, P. E. , 2001. Investigating the role of saliency analysis with neural network rainfall–runoff model. *Computers and Geosciences* 27,921-928.
- Alp, M. , C. g. . zog. lu, H. K. , 2004. Modelling of rainfall, runoff relationship by different artificial intelligence methods. *ITU Journal* 3 (1), 80. 88 (In Turkish).
- Bhattacharya, B. , and Solomatine, D. P. , Neural networks and M5 model trees in modeling water level–discharge relationship, *Neurocomputing*, 2005, vol. 63,pp. 381–396.
- Cigizoglu, H. K. , H. K. , 2002. Suspended sediment estimation and forecasting using artificial neural networks. *Turkish Journal of Engineering and Environmental Sciences* 26 (2002), 16. 26
- Cigizoglu, H. K. and Alp, M. , 2008. Generalized Regression Neural Network in Modeling River Sediment Yield. *Journal of Advances in Engineering Software*, 37: 63-67.
- Erkan Turan, M. , Ali Yurdusev, M. 2009. River flow estimation from upstream flow records by artificial intelligence methods. *Journal of hydrology*. 369, 71-77.
- Furundzic, D. , 1998. Application example of neural networks for time series analysis: rainfall–runoff modeling. *Signal Processing* 64, 383–396.
- Lippmann, R. P. , 1987. An introduction to computing with neural nets. *IEEE ASSP Mag.* , 4–22.
- Minns, A. W. , Hall, M. J. , 1996. Artificial neural networks as rainfall–runoff models. *Hydrological Sciences Journal* 41 (3), 399–417.
- Quinlan, J. R. , Learning with continuous classes. In: Proc. AI'92 (Fifth Australian Joint Conf. on Artificial Intelligence)(ed. by A. Adams & L. Sterling), 343{348. World Scientific, Singapore. 1992.
- Sajikumar, N. , Thandaveswara, B. S. , 1999. A non-linear rainfall–runoff model using an artificial neural network. *Journal of Hydrology* 216, 32–55.
- See, L. , Corne, S. , Dougherty, M. , Openshaw, S. , 1997. Some initial experiments with neural network models of flood forecasting on the River Ouse. In: Proceedings of the 2nd International Conference on GeoComputation.
- Shamseldin, A. Y. , 1997. Application of a neural network technique to rainfall–runoff modeling. *Journal of Hydrology* 199, 272–294.
- Solomatine, D. P. and Avila Torres, L. A. , Neural network approximation of a hydrodynamic model in optimizing reservoir operation, In: Proceedings of the second international conference on hydroinformatics, Zurich. pp. 201-206, 1996.
- Stravas, L. and Brilly, M. , Development of a low flow forecasting model using the M5 machine learning method, *Hydrological Sciences*, 2007, vol. 52, no. 3, pp. 466–477.
- Tang, Z. , Fishwick, P. A. , 1993. Feedforward neural nets as models for time series forecasting. *ORSA J. Comput.* 5 (4), 374–385.
- Wei Chih_Chang and Hsu Nien_Sheng, Optimal tree based release rules for real_time flood control operations on a multipurpose multireservoir system, *J. Hydrology*, 2009, vol. 365, pp. 213–224.
- Witten, I. H. and Frank, E. , Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations. Morgan Kaufmann: San Francisco. 2005.
- Wong, F. S. , 1991. Time series forecasting using backpropagation neural networks. *Neurocomputing* 2, 147–159.
- Toker, A. S. and Markus, M. 2000. Precipitation-Runoff Modeling using Artificial Neural Network and ConceptualModels, *Journal of Hydrologic Engineering*, 5(2):156-161.
- Xiong, L. , O'Connor, K. M. and Goswami, M. 1999. Application of the Artificial Neural Network (ANN) in Flood Forecasting on a Karstic Catchment, *Conceptual and Neural Network Models, Journal of Hydrology*, 321(1-4):344-363.