



بررسی کارایی روش‌های مختلف هوش مصنوعی و روش آماری در برآورد میزان رواناب (مطالعه موردی: حوزه شهید نوری کاخک گناباد)

محمد‌هدی زرعی^۱، محمدتقی دستورانی^۲، منصور مصدقی^۳ و مسعود عشقی‌زاده^۴

^۱ دانشکده منابع طبیعی و محیط‌زیست، دانشگاه فردوسی مشهد

^۲- استاد دانشکده منابع طبیعی و محیط‌زیست، دانشگاه فردوسی مشهد، (نویسنده مسؤول): dastorani@um.ac.ir

^۳- استادیار گروه کشاورزی و منابع طبیعی، مجتمع آموزش عالی گناباد

^۴ تاریخ دریافت: ۹۵/۶/۱۰ تاریخ پذیرش: ۹۴/۶/۱۴

چکیده

سال‌هاست که از مدل‌های بارش-رواناب در زمینه هیدرولوژی و برآورد رواناب استفاده می‌شود. اما علی‌رغم وجود مدل‌های فراوان، ظهور مرتباً مدل‌های جدید نشان‌دهنده آن است که هنوز مدلی که بتواند بدون هیچ‌گونه نقص و ایرادی، کارایی و دقت بالا را در برآوردها ارائه کند ایجاد نشده است. بدین منظور جهت دستیابی به بهترین نتایج؛ تعیین کارایی و شناسایی بهترین مدل‌ها، پس از انجام مدل‌سازی‌ها، ضرورت می‌یابد. در این راستا، در پژوهش حاضر، ابتدا اقدام به مدل‌سازی و برآورد میزان رواناب با استفاده از روش‌های مختلف هوش مصنوعی و نیز روش‌های آماری رگرسیون چندگانه شد. سپس جهت بررسی کارایی روش‌های اجراء شده و نهایتاً انتخاب بهترین مدل، از معیارهای کارایی و ارزیابی شامل؛ ضریب همبستگی (R)، ضریب نش-ساتکلیف (NSE)، ریشه میانگین مربعات خطأ (RMSE) و میانگین قدر مطلق خطأ (MAE) استفاده گردید. اطلاعات مورداً استفاده در این تحقیق، از داده‌های ۹ واقعه بارندگی در بازه زمانی ۱۵۰-۱۱۰-۲۰۰ حوزه کاخک گناباد تهیه شد. مدل‌های هوش مصنوعی موربدبررسی در این مطالعه نیز عبارت بودند از: شبکه عصبی مصنوعی پس انتشار پیش‌خور نرمال، پیش‌خور Cascade، پیش‌خور خودبازگشته Elman، شبکه فازی-عصبی (ANFIS) و مدل درخت تصمیم‌رگرسیونی (Regression Tree) که در محیط نرم‌افزار متلب اجرا شدند. همچنین از روش رگرسیون چندگانه گام‌به‌گام به عنوان روش آماری، در محیط نرم‌افزار مینی‌تب استفاده گردید. نتایج حاصل از این پژوهش نشان داد، انواع روش‌های آماری و هوش مصنوعی در نظر گرفته شده به طور نسبتاً مشابهی دارای کارایی قابل قبول بوده و با دقت مناسب و خطای نسبتاً کم، قادر به برآورد میزان رواناب هستند. در این بین، مدل‌های عصبی پیش‌خور نرمال و پیش‌خور Cascade با تعداد ۵ پارامتر ورودی میزان کارایی بهتری را نسبت به سایر مدل‌ها نشان دادند. چنانکه معیارهای کارایی R، RMSE، NSE در این مدل‌ها، به ترتیب مقادیر مشابه؛ ۰/۸۸، ۰/۷۶، ۰/۲ و ۱/۵ بدست آمد. در مجموع یافته‌ها حاکی از برآورد بهتر مدل‌های هوش مصنوعی نسبت به روش آماری رگرسیونی است.

واژه‌های کلیدی: مدل‌سازی، شبکه‌های عصبی، درخت تصمیم، ANFIS، پس انتشار، پیش‌خور، پیش‌خور

معیارهای ارزیابی، مناسب‌ترین و کاراترین مدل را با توجه به ویژگی‌های خاص منطقه خشک و نیمه‌خشک ایران معرفی نمود. از جمله روش‌هایی که در سال‌های اخیر توجه پژوهش‌گران را به خود جلب کرده، روش‌های هوش مصنوعی (AI) است که در کنار روش‌های آماری که قبلاً استفاده می‌گردید، تغییراتی شگرف را در علم هیدرولوژی ایجاد کردند. در بررسی‌ها و تحقیقات متعدد، از انواع مختلفی از روش‌های هوش مصنوعی و روش‌های آماری (رگرسیونی) بهره گرفته شده (۲۴) که هریک نتایج مختلفی در برداشته است. در ادامه به صورت خلاصه به تعدادی از مطالعات انجام گرفته در این زمینه پرداخته می‌شود. در تحقیق انجام‌شده توسعه فتح الهی و همکاران (۱۳)، از مدل شبکه عصبی مصنوعی ARX^۱ برای پیش‌بینی جریان ماهانه حوزه رودخانه آجی چای (تلخه رود) در استان آذربایجان شرقی استفاده کردند. در این حوزه که دارای میانگین بارش سالیانه ۳۵۵ میلی‌متر و مقدار حداقل دیب ۴۰/۶ متر مکعب در ثانیه است، نتایج تحقیق حاصله نشان داد که عملکرد مدل شبکه عصبی مذکور، در پیش‌بینی رواناب ماهانه مناسب می‌باشد. در تحقیقی دیگر بوسفی و همکاران (۲۵)، با استفاده از شبکه عصبی مصنوعی و درخت تصمیم‌گیری، رسوبات بار معلق حوزه‌های آبخیز استان

مقدمه

کمبود منابع آبی و عدم مدیریت صحیح مصرف آب در مناطق خشک و نیمه‌خشک، لزوم توجه به رواناب و منابع آبی حاصل از نزولات را پیش‌ازپیش مشخص می‌کند. همچنین با توجه به موقعیت ایران که در کمرنگ خشک جغرافیایی جهان و در زمرة مناطق کم باران جهان واقع شده است، اهمیت استفاده از رواناب‌ها دوچندان می‌گردد. در این راستا وجود مدل‌هایی که بتوانند امکانی را برای تخمین و استفاده هرچه بهتر از منابع آبی و رواناب‌ها فراهم کنند بسیار مؤثر خواهد بود. به طور کلی با انجام مدل‌سازی، اولاً سعی می‌شود مهم‌ترین عوامل و پارامترهای تأثیرگذار در ایجاد رواناب‌ها شناسایی و اولویت‌بندی شوده ثانیاً با استفاده از نتایج حاصله از مدل، برنامه‌ریزی‌های آتی برای مدیریت رواناب‌ها صورت گیرد. در دهه‌های اخیر انواع مختلفی از مدل‌ها برای برآورد و پیش‌بینی رواناب‌ها ارائه شده‌اند اما با توجه به اینکه اکثر این مدل‌ها در خارج از ایران ایجاد شده‌اند و نتایج حاصل از مدل‌ها بسته به مناطق گوناگون و شرایط اقلیمی متفاوت است، مدل‌سازی مجدد و کالیبراسیون آن‌ها در مناطق داخل کشور حائز اهمیت می‌باشد. در این میان می‌توان با بررسی میزان کارایی روش‌ها و مدل‌های مختلف و با در نظر گیری

عملکرد را در پیش‌بینی داده‌های تست سه حوزه مذکور داشته است. چونگو همکاران (۲۱) با استفاده از مدل‌های شبکه عصبی مصنوعی دبی جریان ورودی رودخانه سویانگانگ در کره را پیش‌بینی کردند. بدین منظور مدل‌ها بر اساس الگوریتم‌های پس انتشار و Cascade-Correlation توسعه داده شد. نتایج نشان داد مدل Cascade-Correlation نسبت به سایر مدل‌ها قابلیت پیش‌بینی بهتری دارد. در تحقیقی توسط تالی و همکاران (۳۲)، پیش‌بینی رواناب با استفاده از مدل فازی عصبی تاکاگی-سوگو با یادگیری آنالاین محلی در سه حوزه آزمایشی، شهری و روتایی در سنگاپور ایجاد شد. نتایج نشان داد که عملکرد مدل یادگیری محلی ANFIS بهتر از مدل‌های فیزیکی همچون مدل موجی حرکتی (KWM)، مدل مدیریت آب رگیار (SWMM) و مدل HBV است. دورم و همکاران (۹)، با استفاده از شبکه عصبی مصنوعی و سیستم‌های فازی عصبی به مدل‌سازی بارش-رواناب در حوزه آبخیز Susurluk پرداختند. نتایج نشان داد این دو مدل دارای عملکرد تقریباً مشابه هستند. نورانی و همکاران (۲۵) از دو مدل هیبریدی هوش مصنوعی شامل نوعی شبکه عصبی و سیستم استنتاج تطبیقی فازی-عصبی برای مدل‌سازی فرآیند بارش رواناب در دو حوزه در منطقه آذربایجان ایران استفاده کردند و نتیجه گرفتند که هرچند هر دو مدل قادر به انجام این مدل‌سازی هستند ولی نتایج مدل دوم از دقت بالاتری برخوردا است. همچنین نورانی و همکاران (۲۶) سیستم استنتاج تطبیقی فازی عصبی در مدل‌سازی بارش-رواناب روزانه و ماهانه حوزه لیقوان چای تبریز استفاده کردند. سپس نتایج را با نتایج به دست آمده با استفاده از رگرسیون خطی و میانگین متحرک یکپارچه پس‌رونده (ARIMA) مقایسه کردند. درنهایت ایشان نتیجه گرفتند، منطق فازی یک ابزار مفید برای مدل‌سازی این سیستم‌ها می‌باشد. در تحقیقی دیگر کارآموز و عراقی نژاد (۲۲)، با استفاده از سیستم استنتاج فازی و شبکه‌های عصبی مصنوعی به پیش‌بینی بلندمدت رواناب رودخانه زاینده‌رود پرداختند. نتایج نشان داد که استفاده ترکیبی از دو مدل ذکر شده برای پیش‌بینی جریان دارای دقت قابل قبولی است. اسدی و همکاران (۲)، با ارائه یک مدل ترکیبی جدید از شبکه‌های عصبی برای مدل‌سازی بارش-رواناب در حوزه آق‌چای ایران استفاده کردند. در مدل ترکیبی ایشان، از روش‌های پردازش داده، روش الگوریتم تیتیک و الگوریتم لونبرگ مارکوارت برای آموزش ورودی شبکه عصبی بهره گرفته شد. درنهایت نتایج نشان داد که رواناب پیش‌بینی شده با استفاده از مدل ترکیبی فوق دارای دقت بیشتری نسبت به شبکه‌های عصبی مصنوعی و سیستم استنتاج تطبیقی عصبی فازی است. همچنین شبکه‌های عصبی به طور گسترده‌ای برای مدل نودون بسیاری از فرآیندهای هیدرولوژیکی غیرخطی دیگر به کار می‌روند. مانند، جریان سطحی، مدیریت آب‌های زیرزمینی، شبیه‌سازی کیفیت آب و همچنین پیش‌بینی بارش (۱۸).

با توجه به تحقیقات انجام‌شده، هدف از پژوهش حاضر بررسی کارایی مدل‌های مختلف هوش مصنوعی و روش‌های

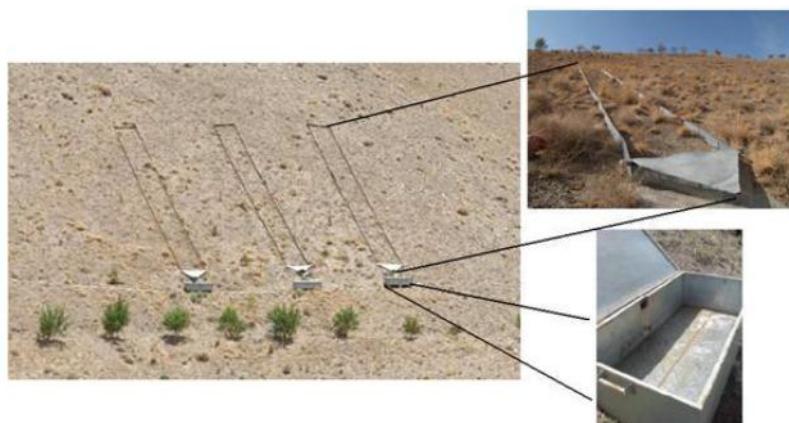
لرستان را شبیه‌سازی نمودند. نتایج نشان داد که الگوریتم لونبرگ مارکوارت مناسب‌ترینتابع آموزش و شبکه پیش‌خور پس انتشار خطأ در شبیه‌سازی پدیده موردنظر از دقت بالاتری نسبت به مدل درخت تصمیم برخوردار است. در تحقیقی چن و همکاران (۵) از مدل درختان تصمیم به همراه شبکه‌های عصبی مصنوعی جهت تحلیل وقوع سیلاب در حوزه‌ای در تایوان استفاده کردند و نتایج حاصله را موفقیت‌آمیز توصیف نمودند. عشقی و همکاران (۱۱) در تحقیقی کارایی مدل‌های مختلف هوش مصنوعی شامل شبکه عصبی مصنوعی، درخت تصمیم و ماشین بردار پشتیبان را در برآورد رسوبات معلم در حوزه آبخیز بابا امان خراسان شمالی مورد ارزیابی قرار دادند. نتایج نشان داد که ماشین بردار پشتیبان در مقایسه با روش‌های دیگر استفاده شده در این تحقیق کارایی بهتری را ارائه داده است. شایق (۳۰) از مدل درخت تصمیم رگرسیونی جهت ارزیابی پژوهه‌های باروری ابرها در استان فارس استفاده کرد. نتایج نشان داد که مدل درخت تصمیم با داده‌های خام و آموزش تصادفی، بهتر آموزش دیده و پیش‌بینی‌های دقیق‌تری را از حجم بارش مناطق هدف ارائه می‌دهد. همچنین وهابی و مهدیان (۳۴) در حوزه طالقان از یک باران‌ساز در پلاتی به ابعاد $1/2 \times 0/89$ متر، به منظور مطالعه اثر شبیب، پوشش گیاهی، بافت خاک و رطوبت اولیه خاک بر رواناب استفاده نمودند. آن‌ها گزارش کردند که پوشش گیاهی و رطوبت اولیه خاک در هر دو بارش به ترتیب بیشترین تأثیر منفی و مثبت را بر رواناب نشان داد. در تحقیق دیگر باتاچاریا و همکاران (۴) از دو روش یادگیری ماشینی شامل شبکه عصبی مصنوعی و مدل‌های درخت تصمیم، جهت مدل‌سازی انتقال بار کل و بار کف رودخانه استفاده کردند و نتایج را با نتایج تحقیقات دیگر مقایسه کردند. طبق نتایجی که گرفتند مدل‌های یادگیری ماشینی دقت بیشتری نسبت به دیگر روش‌ها دارد و از بین مدل‌های مذکور، مدل درخت تصمیم کمترین خطأ را نشان داد. هانگ و همکاران (۱۸) با استفاده از داده‌های رواناب ۷۵ ایستگاه اطراف بانکوک تایلند، مدل شبکه عصبی‌ای را برای پیش‌بینی زمان واقعی رواناب توسعه دادند. بدین‌منظور ایشان از شش مدل برای شناسایی مناسب‌ترین مدل استفاده کردند. تجزیه و تحلیل حساسیت نشان داد که مهم‌ترین ارماتر ورودی در کنار خود بارش، دمای قرائت شده از دماستج (که بیشتر معکس‌کننده میزان رطوبت هوا است)^۱ در پیش‌بینی بارش است. درنهایت با مقایسه مدل‌ها نتیجه گرفتند شبکه عصبی مصنوعی بخصوص شبکه پیش‌خور^۲ عملکرد خوبی دارد و می‌تواند در پیش‌بینی زمان واقعی رواناب و مدیریت سیلاب در حوزه مذکور استفاده شود. گوس وامی و اوکونور (۱۴) از مدل شبکه عصبی برای پیش‌بینی و شبیه‌سازی جریان رودخانه در سه حوزه واقع در فرانسه استفاده کردند. شبکه عصبی به کار گرفته شده از نوع شبکه پیش‌خور چندایله بود. ایشان برای بررسی عملکرد شبکه عصبی، نتایج حاصل از آن را با پنج مدل سیستم نظری و یک مدل مفهومی مقایسه کردند که در نهایت نتایج تحقیق نشان داد مدل شبکه عصبی بهترین

این حوزه که از زیر حوزه‌های حوزه آبخیز شهید نوری کاخک است، دارای طول جغرافیایی "۳۷/۱ ۳۵ ۳۵ ۵۸" تا "۳۶ ۵۸" در عرض جغرافیایی "۴۶/۱ ۴۶ ۳۴ ۵" می‌باشد. حوزه زوجی کاخک شامل دو زیر حوزه شاهد و نمونه است که دارای شرایط تقریباً مشابه هستند. مساحت هریک از این زیر حوزه‌ها به ترتیب عبارت از شکل ۱ موقعیت حوزه مورد مطالعه را در کشور نشان می‌دهد. در شکل ۲ نیز نمایی از پلات‌های استفاده شده در تحقیق دیده می‌شود (۱۲).

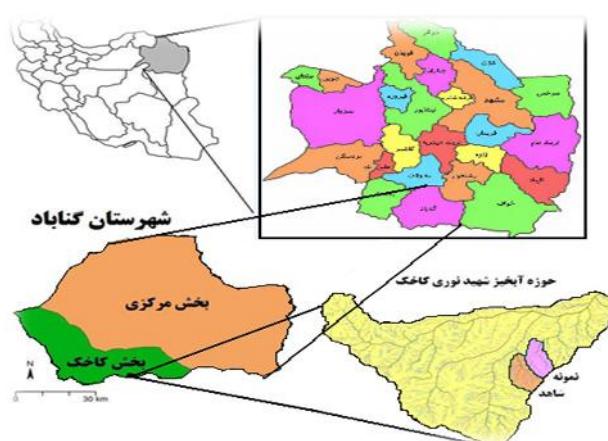
آماری رگرسیونی در پیش‌بینی و برآورد میزان رواناب حوزه‌های مناطق خشک همچون حوزه معرف کاخک گناباد است.

مواد و روش‌ها منطقه مورد مطالعه

حوزه زوجی کاخک در استان خراسان رضوی، در شهرستان گناباد و در بخش کاخک به فاصله ۳۰ کیلومتری از شهر گناباد و ۷ کیلومتری جنوب غربی شهر کاخک واقع شده است.



شکل ۱ - موقعیت جغرافیایی حوزه کاخک (نمونه و شاهد)
Figure 1. Geographical location of Kakhk watershed (Sample and observation catchments)



شکل ۲ - نمونه‌ای از پلات‌های فرسایشی در حوزه کاخک گناباد
Figure 2. Samples of erosion plots in Kakhk watershed of Gonabad

اصلی رویکرد درخت تصمیم، نشان دادن راه حل هاست (۳۳). از جمله الگوریتم مهم درخت تصمیم، الگوریتم‌های CART و ID3 است که با هم‌زمان با بهبود کیفیت تصمیم، اندازه درخت را حداقل می‌کنند (۲۰). در این تحقیق از الگوریتم CART بهمنظور ایجاد درخت تصمیم رگرسیونی استفاده گردید.

پارامترهای مورداستفاده در شبیه‌سازی

با توجه به تعدد پارامترهای مؤثر بر میزان رواناب در حوزه موردمطالعه، جهت انجام مراحل تحقیق، سعی گردید از مؤثرترین پارامترها که میزان همبستگی بیشتری با مقادیر رواناب مشاهده‌ای دارند استفاده گردد. در این رابطه، علاوه بر اطلاعات اقلیمی که از ایستگاه کلیماتولوژی واقع در حوزه کاخک بهدست آمد، سایر پارامترها از طریق پلاتهای جای گذاری شده در دو حوزه حاصل گردید. به طور کلی اطلاعات مورداستفاده در تحقیق، شامل: داده‌های شدت متوسط بارندگی (برحسب میلی‌متر بر ساعت)، مقدار بارندگی (میلی‌متر)، تداوم بارش (ساعت)، تبخیر از تشک (میلی‌متر)، رطوبت پیشین خاک (از طریق سنسور اندازه‌گیری رطوبت در عمق ۵۰ سانتی‌متری خاک)، درصد تاج پوشش گیاهی، درصد تندي شبیه، درصد سنگ و سنگ‌ربیزه و درصد لاشبرگ می‌باشد. همچنین مقادیر رواناب حاصل از بارش نیز از مخازن گردیده بودند، تهیه شد (شکل ۲). یکسان بودن مشخصات پلاتها از نقطه نظر طول و عرض (۱۸×۲۲/۱ متر)، امکان استفاده از اطلاعات حاصله و مقایسه شرایط آن‌ها را با یکدیگر فراهم نمود (شکل ۲). در این مطالعه، مشاهدات (نمونه‌ها) برای هر پارامتر (متغیر) در بازه سال‌های ۲۰۱۵-۲۰۱۱ مورد استفاده قرار گرفته است که با احتساب تعداد ۹ پلات در هر زیر حوزه و اطلاعات رگبارهای حادث شده (۹ رگبار)، بالغ بر ۸۱ داده در هر حوزه (۱۶۲ داده در حوزه زوجی) شد.

اجرای مدل

با توجه به اختلاف در ماهیت و شیوه اجرای هر یک از مدل‌های در نظر گرفته شده، در این تحقیق، برای مدل‌سازی انواع مدل‌های هوش مصنوعی، از نرم‌افزار متلب و برای اجرای روش‌های آماری رگرسیونی از نرم‌افزار مینی‌تب استفاده گردید. در هر دو حالت، کلیه داده‌ها به دو دسته: آموزشی^۷ و آزمایشی^۸ و به ترتیب ۸۰ درصد و ۲۰ درصد از کل داده‌ها تقسیم شده و به مدل معرفی گردیدند. روند انتخاب داده‌های آموزش و آزمون به صورت سیستماتیک و توسط کاربر انجام شد که البته داده‌های آزمون در مرحله آموزش مورداستفاده قرار نگرفتند. در مرحله مدل‌سازی مدل‌های هوش مصنوعی در متلب، ابتدا سعی گردید اولویت‌بندی و تعیین اهمیت هریک از پارامترهای رودی در رواناب خروجی، با توجه به حالات مختلف و تعداد پارامترهای متفاوت (۵، ۷ و ۹ پارامتر) انجام گیرد که در گام نخست، مدل‌ها با استفاده از پنج پارامتر اولیه رودی شامل؛ مقدار بارش، متوسط شدت بارندگی، تداوم بارش، میزان تبخیر و رطوبت خاک ایجاد

معرفی روش‌های مورد استفاده

از جمله روش‌هایی که در سال‌های اخیر توجه پژوهش‌گران را به خود جلب نموده، روش‌های هوش مصنوعی است که شبکه‌های عصبی مصنوعی (ANN) از معروف‌ترین آن‌ها به شمار می‌رود. این شبکه‌ها با استخراج روابط بین ورودی‌ها و خروجی‌ها، امکان شبیه‌سازی شرایط مختلف را فراهم کرده و خروجی مناسب را می‌دهند. در پژوهش حاضر، جهت بررسی کارایی روش‌های مختلف هوش مصنوعی در تخمین میزان رواناب و اولویت‌بندی عوامل مؤثر بر آن، سعی گردید، از انواع روش‌های هوش مصنوعی شامل، شبکه عصبی مصنوعی (ANN)، پس انتشار خطأ، پیش‌خور نرمال، پیش‌خور Cascade، پس‌خور خودبازگشته‌ی المَنَّ، سیستم فازی-عصبی (ANFIS) و مدل درخت تصمیم^۹ استفاده شود. سپس با اجرای روش‌های آماری، ارزیابی و مقایسه‌های بین روش‌های در نظر گرفته شده صورت گیرد. روش آماری رگرسیونی اجراسده، روش رگرسیون چندگانه بهترین زیرمجموعه^{۱۰} بود.

در ادامه به طور مختصر روش‌ها و الگوریتم‌های مورداستفاده شرح داده می‌شود.

شبکه‌های عصبی پیش‌خور و پس‌خور

به طور کلی شبکه‌های عصبی مصنوعی بر مبنای جهت ورود اطلاع و پردازش به دو گروه تقسیم می‌شوند که عبارتند از: شبکه‌های پیش‌خور که جهت حرکت اطلاعات از نرون‌های ورودی به خروجی است و برگشتی وجود ندارد و شبکه‌های پس‌خور که برگشت از خروجی به ورودی ممکن است. از معروف‌ترین شبکه‌های عصبی پس‌خور می‌توان به شبکه‌های المَنَّ اشاره کرد. الگوریتم‌های مختلفی جهت آموزش و انتقال شبکه عصبی وجود دارند، در این تحقیق به منظور شناسایی بهترین و کارترین مدل، از الگوریتم‌های لونبرگ مارکوارت و گرادیان نزولی^{۱۱} در آموزش شبکه عصبی استفاده گردید. این دو الگوریتم در محیط نرم‌افزار متلب به ترتیب با نام trainlm و traingdx شناخته می‌شوند. همچنین از توابع نوع سیگموئید (tansig) در لایه میانی و تابع خطی (purelin) در لایه خروجی، به عنوان تابع انتقال شبکه عصبی استفاده شد.

سیستم استنتاج فازی عصبی تطبیقی (ANFIS)^{۱۲}

این مدل، که مدل توسعه‌یافته فازی است از ترکیب سیستم‌های فازی با شبکه‌های عصبی ایجاد می‌گردد. چنان‌که در این مدل، از الگوریتم‌های یادگیری شبکه عصبی مصنوعی‌برای آموزش مدل استفاده می‌شود. این روش در مدل‌سازی راینده‌هایی همچون هیدرولوژی، هیدرولوژی، مدیریت مخازن و برآورد بار رسوب معلم بسیار قدرتمند است. مهم‌ترین دلیل ترکیب سیستم‌های فازی با شبکه‌های عصبی، قابلیت یادگیری آن‌ها است (۱۹).

درخت تصمیم

درخت تصمیم از انواع روش‌های داده‌کاوی و ابزاری قوی برای دسته‌بندی و پیش‌بینی وقایع می‌باشد. در این روش، برخلاف شبکه عصبی مصنوعی، ضرورتی وجود ندارد که داده‌ها لزوماً به صورت عددی باشند (۲۳). در مجموع، مزیت

گیاهی و درصد شیب پلاتها و در گام آخر، مقادیر پارامترهای (RMSE)، میانگین قدر مطلق خطا (MAE)، میزان رواناب شبیه‌سازی شده (برآورده) با میزان رواناب مشاهده شده واقعی، مقایسه و میزان کارایی مدل‌ها بررسی شد.

نتایج و بحث

الف) اجرای شبکه‌های عصبی پیش‌خور، پس انتشار Cascade و پس خور المَن

در این حالت مدل‌های عصبی تحت شرایط مختلف؛ تعداد پارامترهای ورودی ۵، ۷ و ۹ عدد، انواع توابع آموزشی، تعداد متفاوت لایه‌های پنهان و نرون‌های لایه میانی اجرا شدند. کیفیت نتایج مدل‌ها در قیاس با میزان رواناب مشاهده شده واقعی، تحت ضرایب R، RMSE و NSE در جداول ۱، ۲ و ۳ نشان داده شده است.

(ب) اجرای مدل فازی- عصبی (ANFIS)

با اجرای مدل عصبی فازی با تابع آموزش سوگنو و انتخاب تعداد پارامترهای ورودی ۵، ۷ و ۹، همبستگی خوبی بین میزان رواناب واقعی با مقادیر متناظر برآورده مدل ANFIS مشاهده شد. چنانکه ضرایب همبستگی (R) به دست‌آمده برای مدل‌های با ۵، ۷ و ۹ ورودی به ترتیب برابر با ۰/۸۵، ۰/۸۵ و ۰/۷۳ است که البته ضریب نش-ساتکلیف در مدلی که با تعداد ۵ پارامتر ورودی اجرا شده نسبت به سایر مدل‌ها بالاتر بوده و برابر ۰/۷۵ است. کیفیت نتایج داده‌های برآورده حاصل از مدل ANFIS در جدول ۴ ارائه شده است.

شدند و سپس در گام بعدی، پارامترهای درصد تاج پوشش درصد سنگ و سنگریزه و درصد لاشبرگ برای ارزیابی نتایج، وارد مدل‌ها گردیدند.

همچنین، با توجه به حساسیت مدل‌های هوش مصنوعی نسبت به عوامل دیگر مانند؛ مقدار مناسب داده‌های آموزش، تعداد لایه‌های شبکه، تعداد نورون‌ها در لایه‌های میانی، نوع قاعده‌های آموزشی و توابع انتقال و ...، سعی گردید کیفیت نتایج مدل‌ها، بسته به تغییر در هریک از عوامل فوق، موردنبررسی قرار گیرد. درنهایت با استفاده از داده‌های آزمون، اقدام به شبیه‌سازی مدل‌های هوش مصنوعی، گردید. در بخش دیگر این پژوهش، با استفاده از مدل‌های آماری رگرسیون چندگانه بهمنظور برآورد رواناب در نرم‌افزار مینی‌تب استفاده گردید که در مرحله نخست، ابتدا اقدام به تعیین توزیع نرمال بودن داده‌ها و حذف داده‌های پرت موجود شده و سپس با رسم ماتریکس پلات، عدم وجود هم خطی و تورم در داده‌ها نمایان شد. در مرحله بعد، جهت اولویت‌بندی و مشاهده مؤثرترین پارامترهای ورودی بر رواناب، از روش رگرسیون چندگانه گام به گام (Step Wize) استفاده گردید که مؤثرترین پارامترها در معادله رگرسیون گام به گام معرفی شدند. درنهایت با استفاده از معادله رگرسیون چندگانه به دست‌آمده، شبیه‌سازی میزان رواناب با استفاده از داده‌های آزمون انجام گردید.

معیارهای ارزیابی مدل

پس از برآورد داده‌های رواناب توسط مدل، با استفاده از معیارهای کارایی و ارزیابی شامل؛ ضریب نش-ساتکلیف (NSE)، ضریب همبستگی (R)، جذر میانگین مربعات خطا

جدول ۱- کیفیت نتایج مدل با استفاده از شبکه عصبی پیش خور نرمال Feed forward ANN

Table 1. Quality of the results produced by the model using normal feed forward ANN

تعداد پارامترهای ورودی	تابع آموزش	تابع انتقال (اول و دوم)	تعداد لایه‌های پنهان	تعداد نرون‌های لایه میانی	R	Nash, Sutcliffe	RMSE	MAE
۵	trainlm	Tansig-purelin	۱	۵	.۰/۸۸	.۰/۲۸	۲/۲	۱/۶
۵	traingdx	Tansig-purelin	۱	۱۰	.۰/۸۸	.۰/۷۶	۲	۱/۵
۵	traingdx	Tansig-purelin	۱	۲۰	.۰/۸۵	.۰/۷۰	۲/۲	۱/۶
۵	trainlm	Tansig-purelin	۲	۱۰	.۰/۸۸	.۰/۷۵	۲	۱/۶
۷	trainlm	Tansig-purelin	۱	۱۰	.۰/۷۸	.۰/۶۱	۲/۶	۱/۹۳
۷	trainlm	Tansig-purelin	۲	۱۰	.۰/۷۹	.۰/۶۰	۲/۶	۱/۸۸
۹	trainlm	Tansig-purelin	۱	۱۰	.۰/۵۸	.۰/۰۳	۴	۳/۲۵

جدول ۲- کیفیت نتایج مدل با استفاده از شبکه عصبی پس انتشار Cascade

Table 2. Quality of the results produced by the model using Cascade back propagation ANN

تعداد پارامترهای ورودی	تابع آموزش	تابع انتقال (اول و دوم)	تعداد لایه‌های پنهان	تعداد نرون‌های لایه میانی	R	Nash, Sutcliffe	RMSE	MAE
۵	trainlm	Tansig-purelin	۱	۱۰	.۰/۸۷	.۷۵۰	۲/۰۵	۱/۵
۷	trainlm	Tansig-purelin	۱	۱۰	.۰/۸۷	.۰/۳۳	۳/۳۵	۲/۳۵
۷	trainlm	Tansig-purelin	۲	۱۰	.۰/۸۱	.۰/۶۶	۲/۳۸	۱/۶۹
۹	trainlm	Tansig-purelin	۱	۱۰	.۰/۵۷	.۰/۴۲	۳/۱۱	۲/۲

جدول ۳- کیفیت نتایج مدل با استفاده از شبکه عصبی پس انتشار Elman

Table 3. Quality of the results produced by the model using Elman back propagation ANN

تعداد پارامترهای ورودی	تابع آموزش	تابع انتقال (اول و دوم)	تعداد لایه‌های پنهان	تعداد نرون‌های لایه میانی	R	Nash, Sutcliffe	RMSE	MAE
۵	trainlm	Tansig-purelin	۱	۱۰	.۰/۸۶	.۰/۶۶	۲/۳۸	۱/۶۶
۷	trainlm	Tansig-purelin	۱	۱۰	.۰/۸۵	.۰/۷۲	۲/۱۵	۱/۷۱
۹	trainlm	Tansig-purelin	۱	۱۰	.۰/۷۳	.۰/۴۴	۳/۰۷	۲/۲۵

جدول ۴- کیفیت نتایج مدل با استفاده از شبکه فازی- عصبی (ANFIS)

Table 4. Quality of the results produced by the model using Adaptive Neuro-Fuzzy Inference System (ANFIS)

تعداد پارامترهای ورودی	تابع آموزش	R	Nash, Sutcliffe	RMSE	MAE
۵	sugeno	.۰/۸۶	.۰/۷۵	۲/۲۸	۱/۶۶
۷	sugeno	.۰/۸۵	.۰/۲۶	۲/۱۵	۱/۷۱
۹	sugeno	.۰/۷۳	.۰/۵۱	۳/۰۷	۲/۲۵

نتایج زمانی حاصل گردید که تعداد پارامترهای ورودی ۷ عدد باشد. چنانکه میزان همیستگی و ضریب نش بدهست آمده بین داده‌های مدل درخت تصمیم و داده‌های مشاهده شده، برابر، همان‌طور که در جدول ۵ نمایش داده شده است، بهترین

ج) اجرای مدل درخت تصمیم (Decision Tree)

پس از رسم درخت داده‌های مؤثر در رواناب و انجام هرس در آن، اقدام به پیش‌بینی دادها از داده‌های تست گردید. همان‌طور که در جدول ۵ نمایش داده شده است، بهترین

جدول ۵- کیفیت نتایج مدل با استفاده از مدل درخت تصمیم رگرسیونی Regression Tree

Table 5. Quality of the results produced by the model using Regression Tree

تعداد پارامترهای ورودی	الگوریتم مورداستفاده	R	Nash, Sutcliffe	RMSE	MAE
۵	CART	.۰/۷۵	.۰/۷۵	۵/۰۱	۳/۲۵
۷	CART	.۰/۸۰	.۰/۵۲	۳/۳	۲/۴
۹	CART	.۰/۷۵	.۰/۵۴	۲/۷۸	۱/۷

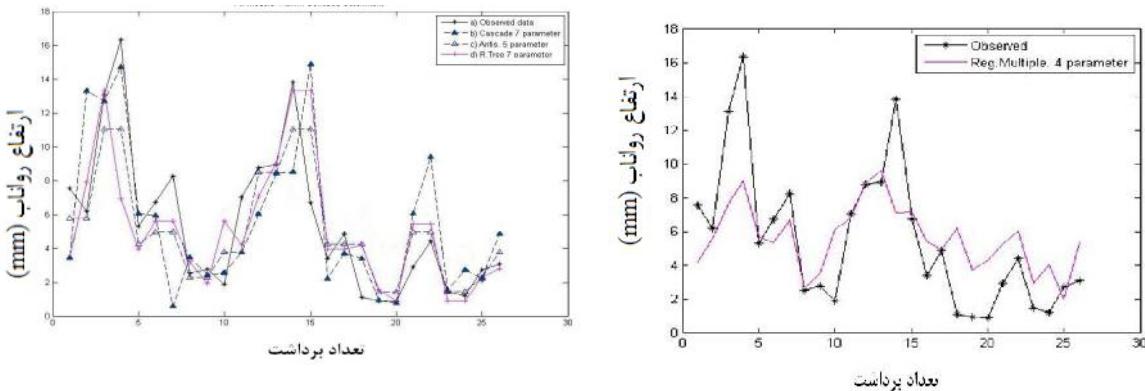
گردید، که از بین ۹ پارامتر در نظر گرفته شده، پارامترهای مقدار بارش، تداوم بارش، پوشش گیاهی، درصد تندری شیب به عنوان پارامترهای نهایی در معادله رگرسیون گام به گام باقی مانندند. درنهایت با استفاده از معادله حاصل از رگرسیون چندگانه، شبیه‌سازی داده‌های آزمون (همان داده‌های مورد تست در مدل‌های هوش مصنوعی) انجام شد. جدول ۶

اجرای مدل‌های آماری رگرسیون خطی چندگانه (Multiple Regression)

برای این منظور که از روش رگرسیون بهترین زیرمجموعه در نرم‌افزار مینی‌تب استفاده شد پس از تعیین توزیع نرمال بودن داده‌ها و حذف داده‌های پرت، اقدام به رسم ماتریکس پلات و بررسی عدم وجود همخطی در بین داده‌ها

مشاهدهای می‌باشد. همچنین در شکل ۳، نمودار ارتباط مقادیر برآورده تعدادی از مدل‌ها با یکدیگر و با رواناب مشاهده شده واقعی به نمایش گذاشته شده است.

نشان‌دهنده معادله رگرسیونی به دست‌آمده از داده‌های آموزشی به همراه مقادیر پارامترهای خطای R، MAE و RMSE مربوط به مقایسه برآورد مدل رگرسیونی چندمتغیره و مقادیر



شکل ۳- نمودار مقایسه‌ای داده‌های برآورده مدل رگرسیون چندگانه با میزان رواناب مشاهده شده (شکل سمت راست) و نیز انواع ساختار شبکه عصبی پیش‌خور Cascade، شبکه فازی-عصبی ANFIS و مدل درخت تصمیم (شکل سمت چپ) با میزان رواناب مشاهده‌ای.

Figure 3. Comparison of the predictions produced by Stepwise Multiple Regression model and the measured data (right) and also the results produced by different Cascade feed forward ANN structures, ANFIS and the decision Tree models against measured values of run off (left).

جدول ۶- کیفیت نتایج حاصل از مدل رگرسیون چندگانه گام به گام

تعداد پارامترهای ورودی	روش‌های مورداستفاده	R	Nash, Sutcliffe	RMSE	MAE
۴	Best subset -Step Wise	.۷۲	.۴۶	۲/۰۲	۲/۲۳
$Y=0.52+0.0805x_1-0.154x_3-0.038x_6+0.0897x_7$					معادله رگرسیون به دست‌آمده:

تعداد پارامترهای ورودی ۵ و ۷ عدد، به دست آمد که این مهم نشان‌دهنده تأثیرگذاری بیشتر ۵ پارامتر در نظر گرفته شده یعنی مقدار بارش، متوسط شدت بارندگی، تداوم بارش، میزان تبخیر و درصد رطوبت خاک در میزان رواناب حاصله در مدل‌های اجرا شده است. همچنین با انتخاب الگوی بهترین زیرمجموعه در مدل رگرسیونی نیز، با اندکی تفاوت نسبت به مدل‌های هوش مصنوعی، تعداد ۴ پارامتر مقدار بارش، تداوم بارش، پوشش گیاهی و درصد تنیدی شیب، به عنوان مدل نهایی معرفی شد که بیانگر وزن و تأثیر برخی پارامترهای اقلیمی شامل مقدار و تداوم بارش در میزان رواناب است. بنابراین می‌توان نتیجه گرفت، کارایی هریک از مدل‌های برآورده، بسته به نوع و تعداد پارامتر معینی تغییر می‌کند و به موازات افزایش تعداد پارامترهای ورودی غیر مؤثر، ضریب کارایی کاهش می‌یابد. گواه این مطلب، نتایج و برآورد ضعیف مدل‌ها با افزایش تعداد پارامترهای غیر مؤثر (از ۵ به ۹ پارامتر) است.

۳- نتایج به دست آمده حاکی از برآورد بهتر مدل‌های هوش مصنوعی نسبت به روش آماری رگرسیونی است. بطوریکه در بهترین حالت مقدار ضریب همبستگی مدل رگرسیون آماری $0/72$ به دست آمد که نسبت به مقادیر متناظر مدل‌های هوش مصنوعی کمتر است. این یافته‌ها با نتایج تحقیقات حمزه چی (۱۷) در پیش‌بینی سری‌های زمانی فصلی با شبکه عصبی

با توجه به بررسی‌های انجام شده در تحقیق، نتایج زیر حاصل می‌گردد:

۱- همان‌طور که از نتایج مشخص است؛ عملکرد روشهای هوش مصنوعی مورد بررسی در برآورد رواناب، با توجه به معیارهای کارایی در نظر گرفته شده قابل قبول می‌باشد که این نتایج، کاربرد گسترده‌ی این روشهای را در زمینه‌های هیدرولوژی و آب توجیه می‌کند. این یافته‌ها با نتایج و گزارش‌های اکبری و همکاران (۱) و دستورانی و همکاران (۶) در بررسی کارایی مدل درخت تصمیم، حبیبی پور و همکاران (۱۵) در استفاده از درخت تصمیم رگرسیونی و شبکه عصبی مصنوعی، دستورانی و همکاران (۸)، در بررسی کارایی شبکه عصبی مصنوعی و سیستم استنتاج عصبی- فازی تطبیقی، قادری و همکاران (۲۵) در برآورد رواناب دائم‌های و آبراهه‌های فرعی که کارایی مدل‌های مورداستفاده را بیان کردن هم‌خوانی دارد.

۲- بهترین نتایج به دست آمده در بین مدل‌ها، از مدل شبکه عصبی پیش‌خور و پس انتشار Cascade و از تعداد ۵ پارامتر ورودی، به همراه یک لایه پنهان و ۱۰ نرون لایه میانی و با مقادیر مشابه R، NSE و RMSE به ترتیب: $0/88$ ، $0/76$ و $1/5$ حاصل گردید. البته این نتایج در سایر مدل‌های هوش مصنوعی در نظر گرفته شده (شامل پسا انتشار المَن و سیستم فازی عصبی ANFIS و درخت تصمیم) نیز با

۴- همچنین نتایج نشان داد شبکه عصبی مصنوعی کارایی بهتری نسبت به درخت تصمیم دارد. این موضوع می‌تواند به دلیل کمبود داده‌های ورودی (آموزشی) برای درخت تصمیم باشد. چنانکه در مدل درخت تصمیم، درخت ایجاد شده نتوانسته شاخ و برگ قابل توجه‌ای نیز ایجاد نماید و هرس در آن منتج به برآورده بیشتری نسبت به مدل‌های عصبی مصنوعی گردد. با این وجود برآورده آن قابل قبول و مناسب ارزیابی می‌شود. شبکه عصبی یک مدل پیش‌بینی است و لذا در مسائل پیش‌بینی انتظار می‌رود توانایی بیشتری نسبت به مدل درخت تصمیم که عمدتاً یک مدل بهینه سازی است داشته باشد. البته مزیت مدل درخت تصمیم در مقایسه با شبکه عصبی این است که جزء مدل‌های جعبه سیاه نبوده و قواعد استفاده شده به خوبی مشخص است. این نتایج با مطالعات یوسفی و همکاران (۳۵)، اختصاصی و همکاران (۱۰) که عملکرد شبکه عصبی مصنوعی را نسبت به درخت تصمیم بالاتر دانسته، مطابقت دارد و با نتایج سنتیل کومار و همکاران (۲۸)، که دقت نتایج درخت تصمیم را نسبت به مدل شبکه عصبی و منطق فازی بالاتر دانسته، مطابقت ندارد.

۷- در این مطالعه مشخص شد مدل فازی و شبکه عصبی دارای عملکرد تقریباً مشابهی است که با یافته‌های دستورانی و همکاران (۸)، سلژی و همکاران (۳۱)، دورم و همکاران (۹) مرتبط است.

۹- همان‌طور که در نمودارهای حاصل از شبکه‌های عصبی مشخص شد، شبکه‌های عصبی نقاط اوج را به درستی برآورده و پیش‌بینی نمی‌کنند که از نقاط ضعف این نوع مدل‌ها بشمار می‌آید. این نتایج با یافته‌های دستورانی و همکاران (۷) در حوزه آبخیز جامیشان همخوانی دارد. همچنین این نتایج در نتایج مدل‌ها از ترکیب مدل‌های مفهومی و شبکه‌های عصبی بهمنظور پیش‌بینی دقیق‌تر رواناب بهره گرفته شود و یا با در نظر گیری سایر پارامترهایی که در شرایط فعلی لحاظ نشده‌اند مانند ارتفاع، اندازه و مساحت پلات (شارپلی و کلینمن، ۲۹)، بافت و نفوذپذیری خاک و ... تا حد ممکن نتایج مدل‌ها را بهبود بخشید. همچنین می‌توان مدل‌های هوش مصنوعی پیش‌بینی را نیز به مطالعه اضافه کرد تا شناسایی بیشترین مدل‌ها به صورت جامع تری صورت گیرد.

تشکر و قدردانی

لازم است از اداره منابع طبیعی و آبخیزداری شهرستان گناباد که در ارائه اطلاعات آماری حوزه کاخک گناباد حمایت نمودند و نیز سرکار خاتم مهندس زینب عرب اسدی که در اجرای روش‌های هوش مصنوعی در نرم‌افزار برنامه‌نویسی MATLAB راهنمایی کردند تقدیر و تشکر گردد.

مصنوعی، باتاچاریا و همکاران (۴) در مدل‌سازی بار رودخانه توسط شبکه عصبی مصنوعی و درخت تصمیم، حجه بخش (۱۶) در برآورد بار بستر توسط درخت تصمیم، شایق (۳۰) در ارزیابی پروژه باروری ابرها با درخت تصمیم، بابا نژاد (۳) در برآورد رسوب رودخانه توسط سیستم‌های تطبیقی فازی، که خطای برآورده مدل‌های مذکور را کم و دقت آن‌ها را بیشتر از روش‌های آماری گزارش کرده‌اند همخوانی دارد. تصور می‌شود علت این امر، در امکان استفاده از توابع متعدد متناسب با روند درونی حاکم بر داده‌ها از نظر پراکنش آن‌ها حول میانگین، دامنه تغییرات داده‌ها، چولگی داده‌ها و ... در مدل‌های هوش مصنوعی است که روش‌های آماری از این نظر (امکان استفاده از توابع متعدد بسته به وضعیت داده‌ها) دارای محدودیت می‌باشند. علاوه بر آن همانطور که تاماری و همکاران (۳۳) نیز نشان دادند، در صورتیکه نایابی داده‌ها بالا باشد، مدل‌های شبکه عصبی نیز نخواهد توانست نسبت به مدل‌های رگرسیونی خطی نتایج چندان بیشتر ارائه نمایند اما در صورت استفاده از داده‌های با دقت بالا (که خطای داده برداری کم باشد) مدل‌های هوش مصنوعی از جمله شبکه‌های عصبی به سبب توانایی ساختاری مناسب جهت پیدا کردن رابطه چه خطی و چه غیر خطی بین داده‌های ورودی و خروجی می‌توانند فرآیند حاکم بر داده‌ها را یاد گرفته و در پیش‌بینی خروجی‌ها بر اساس ورودی‌های داده شده کارایی بیشتری از خود نشان می‌دهند. با توجه به اینکه داده‌های استفاده شده در تحقیق حاضر نیز از هر لحظه دقت و صحت لازم را دارا بوده بنابراین مدل‌های هوش مصنوعی کارایی مناسبی را در مقایسه با مدل‌های رگرسیونی از خود به نمایش گذاشتند.

نمودار رگرسیونی نیز قابل مشاهده است، چنانکه مدل رگرسیونی برآورد متوضی را ارائه می‌دهد.

۱۰- با توجه به استفاده از الگوریتم‌های مختلف گرادیان نزولی و لونبرگ مارکوارت در شبکه‌های عصبی (پیش‌خور و پس‌خور)، مشخص گردید تغییر تابع آموزش تاثیر چندانی در کیفیت نتایج نهایی ندارد.

همان‌طور که از نتایج مشخص گردید، انواع روش‌های آماری و هوش مصنوعی به کاربرده شده در این مطالعه، به طور نسبتاً مشابهی قادر به برآورد میزان رواناب با خطای نسبتاً کم هستند. این نتایج، نشان‌دهنده اولاً اهمیت و تأثیرگذاری پارامترهای ورودی در نظر گرفته شده در میزان رواناب است و ثانیاً عملکرد و کارایی قابل قبول مدل‌های مذکور در برآورد خروجی، یعنی رواناب را نشان می‌دهد. بنابراین می‌توان از این مدل‌ها در برآورد رواناب به ویژه در مناطق خشک و نیمه‌خشک که شرایط نسبتاً مشابه با منطقه تحقیق دارند استفاده نمود. توصیه می‌شود، در تحقیقات بعدی برای بهبود

منابع

1. Akbari, Z., A. Talebi, M.T. Dastorani, J. Mahjubi and B. Akbari. 2013. The impact of sediment flows classification on accurately suspended sediment estimation using decision tree models. The first national conference on achieving sustainable development in agriculture, natural resources and environment sectors, Tehran (In Persian).
2. Asadi, S., J. Shahrabii, P. Abbaszadeh and S. Tabanmehr. 2013. A new hybrid artificial neural networks for rainfall-runoff process modeling. Neurocomputing, 121: 470-480.
3. Babanejad, T. 2012. The use of genetic algorithms in adaptive fuzzy-neural system to estimate the sediment in the river, Ninth International River Engineering Seminar, Shahid Chamran University of Ahvaz, Iran, February 2012, (In Persian).
4. Bhattacharya, B., R.K. Price and D.P. Solomatine. 2007. Machine learning approach to modeling sediment transport. Journal of Hydraulic Engineering, 133(4): 440-450.
5. Chen, J.C., S.K. Ning, H.W. Chen and C.S. Shu. 2008. Flooding probability of urban area estimated by decision tree and artificial neural networks, Journal of Hydroinformatics, 10(1): 57-67.
6. Dastorani, M.T., A. Habibpour, M.R. Ekhtesasi, A. Talebi and J. Mahjubi, 2013. Evaluation of the Decision Tree Model in Precipitation Prediction (Case study: Yazd Synoptic Station), Iran Water Resources Research, 3: 14-27 (In Persian).
7. Dastorani M.T., Kh. Azimi Fashi, A. Talebi and M.R. Ekhtesasi, 2012. Estimation of Suspended Sediment Using Artificial Neural Network (Case Study: Jamishan Watershed in Kermanshah). Journal of watershed management research, 6: 61-74 (In Persian).
8. Dastorani M.T., H. Sharifi Darani, A. Talebi and A.R. Moghaddamnia, 2011. "Evaluation of the application of artificial neural networks and adaptive neuro-fuzzy inference systems for rainfall-runoff modeling in Zayandeh_rood dam basin, Journal of Water and Wastewater, 4: 114-125 (In Persian).
9. Dorum, A., A. Yarar, M. Faik Sevimli and M. Onuçyıldız. 2010. "Modelling the rainfall-runoff data of susurluk basin." Expert Systems with Applications 37(9): 6587-6593.
10. Ekhtessasi, M., M. Yusefi and M. Tavakkoli. 2015. Comparing the Best Input Combining Artificial Neural Networks and Decision Tree Method to Identify Factors that Influence the Phenomenon of Dust Storm (Case Study Yazd Province), Journal of Watershed Science and Engineering. 9(28): 33-40 (In Persian).
11. Eshghi, P., J. Farzadmehr, M.T. Dastorani and Z. Arab Asadi. 2016. The effectiveness of intelligent models in estimating the river suspended sediments (Case study: Babaaman basin, Northern Khorasan), Journal of watershed management research, 14: 88-95 (In Persian).
12. Eshghizadeh, M. 2011, The Review of the pair watersheds of Kakhk, Gonabad, Department of Natural Resources and Watershed Management of Gonabad (In Persian)
13. Fathollahi, S., D. Mirshahi and B. Abbaspoor, 2015. Prediction of runoff resulted from rainfall in Ajichai river basin, using neural networks. The first International Congress on Irrigation and Drainage, Ferdowsi University of Mashhad. Iran (In Persian).
14. Goswami, M. and K.M. O'Connor, 2005. Application of Artificial Neural Networks for river flow simulation in three French catchments.4th Inter-Celtic Colloquium on Hydrology and Management of Water Resource. National University of Ireland, Galway, Ireland.
15. Habibipour, A., M.T. Dastorani, M.R. Ekhtesasi, H. Afkhami. 2011. Evaluation of the Effects of Data range Modification on Efficiency of Regression Decision Tree and Artificial Neural Networks for Drought Prediction, Journal of watershed management research, 3: 63-79 (In Persian).
16. Hajjabakhsh, C. 2012. Estimation of bed load sediment using regression decision trees, and comparing with experimental methods, M.Sc. Thesis, Department of Civil Engineering, Yazd University, Iran, 103 pp (In Persian).
17. Hamzaçebi, C. 2008. Improving artificial neural network's performance in seasonal time series forecasting. Information Sciences, 178(23): 4550-4559.
18. Hung, N.Q., M.S. Babel, S. Weesakul and N.K. Tripathi. 2008. An articial neural network model for rainfall forecasting in Bangkok, Thailand. Hydrology and Earth System Sciences Discussions, 5(1): 183-218.
19. Jang, J.S.R. 1993. ANFIS: Adaptive-network-based fuzzy inference system. J. of IEEE. Trans. Syst. Man, Cyber, 23(3): 665-685.
20. Janikow, Z. and M. Faifer. 2000. Bottom- up Fuzzy Partitioning in Fuzzy Decision Trees. Fuzzy Information Processing Society, NAFIPS. 19th International Conference of the North American.
21. Jeong, C.S., W.J. Koh and J.H. Heo. 2000. A study on real-time forecasting of reservoir inflow based on artificial neural network. Proceedings of Watershed Management and Operations Management 2000 conference, American Society of Civil Fngineers, USA
22. Karamouz, M. and S. Araghinejad. 2011. Advanced Hydrology. Amirkabir University of Technology Press. Tehran. Iran. (In Persian).
23. Kia, M. 2010. Neural networks in MATLAB, Third Edition, published by Kian-Rayaneh-Sabz, 229 pp (In Persian).
24. Meshkani, A. and A. Nazemi. 2009. Introduction to Data Mining, Ferdowsi University of Mashhad Press, Mashhad (In Persian).
25. Nourani, V., Ö. Kisi and M. Komasi. 2011. "Two hybrid Artificial Intelligence approaches for modeling rainfall-runoff process." Journal of Hydrology 402(1-2): 41-59.
26. Nourani, V., M.A. Kynejad and L. Malekani. 2010. "The use of Adaptive Neural - fuzzy systems in Modeling of rainfall - runoff." Journal of Civil and Environmental Engineering, University of Tabriz 39(4): 75-81 (In Persian).

27. Qaderi, M. 2012. Development of hydrological model for simulation of rainfall-runoff from hill slopes and small catchments (Case study: Sanganeh station, Khorasan Razavi), M.Sc. Thesis, Faculty of Natural Resources, Yazd University, Iran (In Persian).
28. Senthil Kumar, A., C. Ojha, M. Goyal, R. Singh and P. Swamee. 2012. "Modeling of Suspended Sediment Concentration at Kasol in India Using ANN, Fuzzy Logic and Decision Tree Algorithms". *Journal of Hydrologic Engineering*, 17(3): 393-404.
29. Sharpley, A. and P. Kleinman. 2003. Effect of rainfall simulator and plot scale on overland flow and phosphorus transport. *Journal of Environmental Quality*, 32: 2172-2179.
30. Shayegh, M. 2012. Cloud seeding project evaluation using decision trees regression model (case study: in central Iran, Fars province), MSc thesis, Water and Power Industry University, Tehran. Iran. (In Persian).
31. Solgi, A., F. Radmanesh, A. Pourhaghi and M. Bagherian. 2014. Evaluation of Artificial Intelligence Systems Performance in Precipitation Forecasting. *TI Journals Agriculture Science Developments*. 3 (7): 256-264.
32. Talei, A., L.H.C. Chua, C. Quek and P.E. Jansson. 2013."Runoff forecasting using a Takagi-Sugeno neuro-fuzzy model with online learning." *Journal of Hydrology*, 488(0): 17-32.
33. Tamari, S., J.H.M. Wosten and J.C. Ruz-suarez. 1996. Testing an artificial neural network -for predicting soil hydraulic conductivity. *Journal of Soil Science Society of America*, 60: 1732-1741.
34. Vahabi, J. and M.H. Mahdian. 2008. Rainfall simulation for the study of the effects of efficient factors on runoff rate. *Current Science*, 95: 1439-1445.
35. Yousefi, M. and F. Barzegar, 2013. Suspended sediment comparative study using a decision tree model and sediment curve (Case Study: Lorestan) *Journal of Watershed management Research (Pajooresh and Sazandegi)*, in press (In Persian).

Evaluation of the Efficiency of Different Artificial Intelligence and Statistical Methods in Estimating the Amount of Runoff (Case Study: Shahid Noori Watershed of Kakhk, Gonabad)

**Mohammad Mahdi Zarei¹, Mohammad Taghi Dastorani², Mansour Mesdaghi³ and
Masoud Eshghizadeh⁴**

1 and 3- M.Sc. Graduate in Watershed Management and Visiting Professor, Faculty of Natural Resources and Environment, Ferdowsi University of Mashhad

2- Professor, Faculty of Natural Resources and Environment, Ferdowsi University of Mashhad, Iran
(Corresponding author: dastorani@um.ac.ir)

4- Assistant Professor, Department of Agriculture and Natural Resources, University of Gonabad
Received: December 26, 2015 Accepted: September 4, 2016

Abstract

Rainfall-runoff models are used in the field of hydrology and runoff estimation for many years, but despite existing numerous models, the regular release of new models shows that there is still not a model that can provide sophisticated estimations with high accuracy and performance. In order to achieve the best results, modeling and identification of factors affecting the output of the model is necessary. In this regard, in present study, it has been tried to identify the factors and estimating the amount of runoff using a variety of methods of artificial intelligence and multiple regression. Then, to evaluate the efficiency of the implemented models and choose the best model, some performance criteria including the correlation coefficient (R), Nash-Sutcliffe coefficient (NSE), the root mean square error (RMSE) and the mean absolute error (MAE) were used. The data used in this study were 9 rainfall events data measured in time period of 2011- 2015 taken from the Khakh watershed of Gonabad. Artificial intelligence models used in this study were: normal feedforward neural networks, feedforward Cascade neural networks, feedbackward Elman neural networks, Adaptive Neuro Fuzzy Inference System (ANFIS) and regression decision tree model (Regerssion Tree) that were implemented in MATLAB software environment and also step multiple regression as statistical methods which was implemented in Minitab software. The results of this study showed that the used statistical and artificial intelligence methods are considered acceptable with almost similar performance and with relatively appropriate accuracy and low error they are able to estimate the amount of runoff. In the meantime, Cascade and normal feedforward neural models with 5 input parameters, presented better performance comparing to the other models, as the performance criteria of R, RMSE, NSE and MAE in these models were the similar values of 0.88 , 0.76, 2 and 1.5, respectively. Overall, the findings indicate better estimations of the artificial intelligence models comparing to the regression model.

Keywords: Modeling, Neural Networks, Decision trees, ANFIS, Backpropagation, Feedforward, Feedbackward