

ارزیابی اثرات ویژگی‌های ریخت‌شناسی، هیدرولوژیکی و کاربری اراضی بر آب برداشتی از رودخانه با استفاده از روش‌های داده‌کاوی

چکیده

بخش کشاورزی به عنوان یکی از مهم‌ترین بخش‌های مصرف آب در پایداری سیستم‌های منابع آب کشور تأثیرگذار است. این مطالعه، با هدف تخمین برداشت آب از رودخانه برای مصارف کشاورزی در محدوده مطالعاتی نوبران، واقع در حوضه آبریز دریاچه نمک، انجام شده است. تخمین میزان برداشت آب از رودخانه با استفاده از متغیرهای وابسته به فاکتورهای ریخت‌شناسی، هیدرولوژیکی، کاربری اراضی و ترکیبی از متغیرهای آن‌ها که با نمونه‌برداری میدانی جمع‌آوری شده است، انجام گرفت. همچنین، برای تخمین متغیر برداشت آب از رودخانه‌ها، روش‌های داده‌کاوی شامل سامانه استنتاجی فازی-عصبی تطبیقی (ANFIS)، روش گروهی مدل‌سازی داده‌ها (GMDH)، شبکه تابع پایه شعاعی (RBF) و مدل درخت تصمیم رگرسیونی (Rtree)، به کار گرفته شد. در این مطالعه، مدل $GMDH_{۲۴}$ با سناریوی ترکیبی شامل متغیرهای عرض رودخانه، عمق رودخانه، حداکثر جریان، متوسط جریان، مساحت کشت شده زراعی و باغی به عنوان بهترین مدل برای برآورد متغیر برداشت آب از رودخانه معرفی گردید. مقدار RMSE برای سناریوی ترکیبی مدل $GMDH_{۲۴}$ به منظور تخمین برداشت آب در محدوده مطالعاتی نوبران ۰/۰۴۶ به دست آمد. نتایج حاکی از این است که عملکرد مدل $GMDH_{۲۴}$ در برآورد برداشت آب رودخانه‌ها برای مقادیر حداکثر بسیار قابل قبول و امیدوارکننده می‌باشد. بنابراین، مدل‌سازی و شناسایی متغیرهای مختلف تأثیرگذار بر میزان بهینه برداشت آب از رودخانه‌ها جهت تأمین مصارف کشاورزی باعث دستیابی به اهداف مدیریت یکپارچه منابع آب (IWRM) می‌شود.

واژه‌های کلیدی: مدل‌سازی، منابع آب، ریخت‌شناسی، هیدرولوژی، کاربری اراضی

مقدمه

یکی از وظایف مهم در بخش مدیریت منابع آب، ایجاد راهکارهایی به منظور بهره‌برداری مناسب و بهینه از منابع آب است. فعالیت‌های مربوط به توسعه منابع آب تغییراتی را در محیط‌زیست ایجاد می‌کند. اثرات زیست‌محیطی سیستم‌های توسعه منابع آب، علاوه بر مفید بودن در مواردی نیز می‌توانند مضر هم باشند. امروزه، در حوضه رودخانه‌ها تغییرات کاربری اراضی به طور چشمگیر مشاهده می‌شود، به طوریکه سهم تأثیر آن در تغییرات رواناب بسیار بیشتر از تغییرات آب و هوایی است. رودخانه‌ها مهم‌ترین منابع

آب سطحی می‌باشند که با توجه به نقش مهم آنها باید به دقت مورد بررسی و محافظت قرار گیرند. متأسفانه برداشت‌های بی‌رویه از منابع آب سطحی، طی سال‌های اخیر موجب کاهش وضعیت کیفی و کمی بسیاری از رودخانه‌های کشور شده است. پیش‌بینی میزان برداشت از رودخانه‌ها کمک شایانی به مدیران و بهره‌برداران می‌کند تا بتوانند نسبت به مدیریت صحیح برداشت آب اقدام کنند. مدل‌سازی یکی از راه‌هایی است که به کمک آن می‌توان رفتار یا عملکرد طرح‌های پیشنهادی یا سیاست‌های مدیریتی را پیش‌بینی کرد (۱۱، ۱۲، ۱۵، ۱۹ و ۲۳). در سال‌های اخیر، روش‌های مدل‌سازی داده محور مانند پرسپترون چند لایه (Multi-Layer Perceptron (MLP)، شبکه تابع پایه شعاعی (Radial Basis Function (RBF)، شبکه عصبی مصنوعی (Artificial Neural Networks (ANN)، سیستم استنتاج فازی-عصبی تطبیقی (Adaptive-Neural-based Fuzzy Inference Systems (ANFIS)، روش گروهی مدل‌سازی داده‌ها (Group Method of Data Handling (GMDH)، ماشین بردار پشتیبان (Support Vector machines (SVM)، مدل درخت تصمیم رگرسیونی (Regression Trees (Rtree)، رویکرد درخت‌های مدل (Model Trees (Mtree)، رگرسیون خطی چندگانه (Multi-Layer Regression (MLR)، و شبکه عصبی مبتنی بر رگرسیون عمومی (General Regression Neural Network (GRNN)، کاربردهای فراوانی در مطالعات هیدرولوژی و مهندسی منابع آب یافته‌اند که در ادامه به مواردی از آن‌ها اشاره می‌گردد.

عبداله پور و ستاری (۲) جریان روزانه رودخانه اهرچای واقع در استان آذربایجان شرقی را با استفاده از مدل‌های ANN و ANFIS پیش‌بینی کردند. ارزیابی نتایج پیش‌بینی‌ها نشان داد که مدل ANFIS توانایی بهتری در تخمین جریان رودخانه دارد. عباسیان و شهرکی (۱) مدل‌های GMDH و RBF را برای پیش‌بینی تقاضای آب شرب شهر زاهدان به کار بردند. نتایج نشان داد که مدل شبکه عصبی GMDH عملکرد بهتری را نسبت به مدل RBF ارائه داده است. یزدانخمی و همکاران (۳) به منظور پیش‌بینی تبخیر ماهانه در ایستگاه سینوپتیک، از سه روش ANN، ANFIS و Rtree استفاده کردند. نتایج نشان داد که ANN کارایی بهتری در پیش‌بینی میزان تبخیر دارد. کالدول و همکاران (۹) بیان کردند که رودخانه‌ها برای اکوسیستم آبی و پایداری جامعه ضروری هستند، اما توسط برداشت آب، تغییرات کاربری اراضی و تغییرات آب و هوایی تحت تأثیر قرار می‌گیرند. قربانی و همکاران (۱۶) کاربرد مدل‌های مختلف MLP، RBF و SVM را برای پیش‌بینی سری زمانی جریان رودخانه زرينه‌رود، بررسی کردند. نتایج مدل‌ها نشان داد که مدل‌های MLP و RBF جریان رودخانه را بهتر از مدل SVM پیش‌بینی کردند. احمد و شاه (۵) در پژوهشی از دو مدل RBF و

MLP برای تجزیه و تحلیل جریان و تخمین میزان جریان حداکثر رودخانه Surma در بنگلادش که دارای اقلیم استوایی (گرم و مرطوب) است، استفاده کردند. نتایج آن‌ها نشان داد که مدل شبکه RBF نسبت به مدل شبکه MLP عملکرد بهتری داشت. طالبی و همکاران (۲۵) به بررسی بار رسوب معلق با استفاده از مدل‌های Rtree، Mtree و ANN در حوضه آبریز حیدرآباد ایران پرداختند. آن‌ها نتایج حاصل از این مدل‌ها را با نتایج منحنی سنج رسوب مقایسه کردند. نتایج ایشان نشان داد که مدل‌های Rtree و Mtree دقت بالاتری نسبت به دو روش دیگر دارند. ژانگ و همکاران (۲۸) به منظور پیش‌بینی سطح آب زیرزمینی، مدل‌های GSM، RBF و ANFIS را در چین به کار گرفتند. نتایج نشان داد که دقت هر سه مدل در حد قابل قبول است. درحالی‌که، مدل ANFIS نتایج بهتری را ارائه داده است. ژانگ و همکاران (۲۷) از مدل‌های Rtree، MLR و مدل‌سازی هیدرولوژیکی برای پیش‌بینی رواناب در حوضه‌های آبریز استرالیا استفاده کردند. نتایج نشان داد که مدل Rtree عملکرد بهتری نسبت به سایر روش‌ها دارد. عاقل‌پور و ورشایان (۴) دقت دو مدل استوکاستیکی ARMA و ARIMA و سه مدل هوشمند شامل MLP، GMDH و GRNN در پیش‌بینی جریان روزانه رودخانه زیلکی در شمال ایران را بررسی کردند. مقایسه بین مدل‌ها نشان داد که دقت مدل‌های هوش مصنوعی بالاتر از مدل‌های استوکاستیکی است. همچنین، در میان مدل‌های هوشمند روش GMDH عملکرد بهتری دارد. محمدی و همکاران (۲۰) ترکیبی جدید از مدل ANFIS با الگوریتم جهش قورباغه به هم ریخته (SFLA) را برای پیش‌بینی دقیق جریان در رودخانه‌های Vu Gia و Thu Bon در ویتنام که دارای اقلیم معتدل و خیلی مرطوب می‌باشند، پیشنهاد کردند. نتایج نشان داد که مدل پیشنهادی ANFIS-SFLA به طور قابل توجهی دقت پیش‌بینی را بهبود بخشید. این محققین اظهار داشتند که مدل پیشنهادی می‌تواند در رودخانه‌های مختلف سراسر جهان تعمیم یافته و استفاده گردد. دالکیلیس و هشیمی (۱۳) جریان روزانه رودخانه Büyük Menderes در ترکیه را که دارای اقلیمی معتدل و نیمه‌مرطوب است، با استفاده از مدل‌های ANN، شبکه عصبی موجک (WNN) و ANFIS پیش‌بینی کردند. نتایج نشان داد که مدل WNN در مقایسه با سایر مدل‌ها، عملکرد بهتری دارد. بنکداری و همکاران (۶) دو روش خطی (GMDH) و غیرخطی (GS-GMDH) را به منظور پیش‌بینی جریان روزانه رودخانه Bow در آلبرتا-کانادا مقایسه کردند. نتایج حاصل از این پژوهش نشان داد که مدل GS-GMDH عملکرد بهتری در پیش‌بینی جریان روزانه، دارد. عمادی و همکاران (۱۴) با استفاده از روش‌های منفرد و هیبریدی-موجک شبکه عصبی مصنوعی (WANNs, ANNs)، سیستم استنتاج عصبی-فازی تطبیقی (WANFIS, ANFIS) و برنامه‌ریزی بیان ژن (WGE, GEP) و با به کارگیری خصوصیات مورفولوژیکی، هیدرولوژیکی

(کمی-کیفی) و کاربری اراضی، به برآورد میزان برداشت آب در زیرحوضه‌های هشتگرد و زرند-ساوه پرداختند. نتایج مطالعات ایشان حاکی از این است که عملکرد مدل‌های WGEF و ANN برای برآورد میزان برداشت آب از رودخانه‌های دو زیرحوضه مورد مطالعه، به ترتیب بهترین و ضعیف‌ترین می‌باشد. ایشان دلیل برتری مدل‌های هیبریدی-موجک نسبت به مدل‌های منفرد را توانایی نوپزدایی داده‌ها توسط تئوری موجک معرفی نمودند.


مروری بر پژوهش‌های انجام شده نشان می‌دهد که تاکنون مطالعات در حد کافی و مورد نیاز به منظور تخمین برداشت آب از رودخانه جهت تأمین مصارف کشاورزی صورت نگرفته است. لذا، این مطالعه با هدف مدیریت مشکلات کمبود منابع آب در حوضه آبریز دریاچه نمک، محدوده مطالعاتی نوبران، انجام شده است. به منظور تخمین مقدار برداشت آب از رودخانه برای مصارف کشاورزی در حوضه آبریز مذکور فاکتورهای مهم ساختار ریخت‌شناسی (Morphologic) رودخانه، مشخصات هیدرولوژیکی (Hydrologic)، کاربری اراضی (Land-use) و نهایتاً ترکیبی (Hybrid) از سه فاکتور مذکور در نظر گرفته شده است. بدین منظور، جهت مدل‌سازی مقدار آب برداشتی رودخانه از مدل‌های سامانه استنتاجی فازی-عصبی تطبیقی (ANFIS)، روش گروهی مدل‌سازی داده‌ها (GMDH)، شبکه تابع پایه شعاعی (RBF) و مدل درخت تصمیم رگرسیونی (Rtree) استفاده شده است. هدف از پژوهش حاضر، یافتن بهترین و مناسب‌ترین ترکیب متغیرهای ورودی روش‌های داده‌کاوی و انتخاب مدل برتر به منظور تخمین برداشت آب از رودخانه جهت تأمین مصارف کشاورزی در حوضه آبریز مذکور می‌باشد.

مواد و روش‌ها

منطقه مورد مطالعه و داده‌ها

دریاچه نمک یکی از مهم‌ترین حوضه‌های آبریز ایران است که در طبقه آب و هوایی خشک قرار گرفته است. این حوضه بین مختصات جغرافیایی $48^{\circ}8'$ تا $52^{\circ}29'$ طول شرقی و $33^{\circ}00'$ تا $36^{\circ}10'$ عرض شمالی واقع شده است که متشکل از چندین زیرحوضه با شرایط آب و هوایی مختلف می‌باشد. شکل ۱ موقعیت جغرافیایی محدوده مورد مطالعاتی نوبران را نشان می‌دهد. داده‌های به کار گرفته شده در این مطالعه (۳۸۹ نمونه‌برداری)، به روش میدانی توسط مدیریت منابع آب کشور جمع‌آوری شده است. متغیرهای وابسته به فاکتورهای ریخت‌شناسی، هیدرولوژیکی و کاربری اراضی و ترکیب سه سناریو مذکور جهت مدل‌سازی میزان آب برداشتی از رودخانه‌های محدوده مطالعاتی نوبران، به کار گرفته شد. فاکتور ریخت‌شناسی شامل متغیرهای عرض و عمق

رودخانه، فاکتور هیدرولوژیک شامل متغیرهای جریان حداقل، حداکثر و میانگین در رودخانه و فاکتور کاربری اراضی شامل متغیرهای سطح کشت محصولات باغی و زراعی، می‌باشد. در میان فاکتورهای مختلف، متغیرهای مرتبط با فاکتور ریخت‌شناسی رودخانه دارای کم‌ترین میزان ضریب تغییرات می‌باشند. جدول ۱ مشخصات آماری متغیرهای به کار رفته در پژوهش را نشان می‌دهد.



شکل ۱- موقعیت جغرافیایی حوضه آبریز مورد مطالعه

جدول ۱- مشخصات آماری متغیرهای به کار رفته در پژوهش

فاکتورها متغیرها	برداشت آب از رودخانه	کاربری اراضی		هیدرولوژیکی		ریخت‌شناسی	
		سطح کشت باغی	سطح کشت زراعی	جریان میانگین	جریان حداکثر	عمق رودخانه	عرض رودخانه
واحد	مترمکعب	هکتار		مترمکعب بر ثانیه		متر	
حداقل	۳۷۸۰/۰۰	۰/۰۵	۰/۱۰	۱/۰۰	۲/۵۰	۰/۰۵	۰/۱۰
حداکثر	۹۲۸۸۰۰/۰۰	۱۲۰/۰۰	۷۵۰/۰۰	۵۰/۰۰	۱۰۰/۰۰	۰/۸۰	۱/۵۰
میانگین	۱۵۳۳۹۹/۱۸	۴/۹۱	۱۰/۲۵	۱۰/۶۹	۲۱/۱۳	۰/۴۵	۰/۶۸
انحراف معیار	۱۵۳۱۲۴/۲۶	۸/۹۴	۴۳/۶۰	۸/۷۰	۱۷/۱۵	۰/۱۰	۰/۱۷
ضریب تغییرات	۱/۰۰	۱/۸۲	۴/۲۵	۰/۸۱	۰/۸۱	۰/۲۳	۰/۲۵

سامانه استنتاجی فازی-عصبی تطبیقی (ANFIS)

سامانه استنتاجی فازی-عصبی تطبیقی از الگوریتم‌های یادگیری شبکه عصبی و منطق فازی به منظور طراحی نگاشت غیرخطی بین فضای ورودی و خروجی استفاده می‌کند. بخش فازی رابطه بین متغیرهای ورودی و خروجی را برقرار می‌نماید و مشخصه‌های مربوط به توابع عضویت بخش فازی نیز به وسیله شبکه عصبی تعیین می‌شود. این نظریه، ابزاری توانمند و انعطاف‌پذیر برای مدل‌سازی عدم قطعیت‌ها و عدم صراحت‌های موجود در دنیای واقعی و بیان عبارات‌های زبانی برگرفته از تجربه و دانش بشر در قالب روابط ریاضی به شمار می‌آید. پیچیدگی و عدم قطعیت در سیستم‌های موجود در طبیعت، کمبود اطلاعات، و همچنین مبهم و غیر صریح بودن داده‌ها موجب شد تا استفاده از سیستم استنتاج فازی-عصبی تطبیقی در مدل‌سازی فرآیندهایی همچون هیدرولوژی، هیدروژئولوژی، مدیریت مخازن و برآورد بار رسوب معلق و ... کارایی بالایی داشته باشد (۱۸ و ۲۱). این سیستم بر اساس تغییر در میزان مقادیر و دامنه توابع تعلق در تکرارهای مختلف جهت رسیدن به شبکه مناسب بر اساس حداقل خطای موجود عمل می‌کند. زمانی عمل شبیه‌سازی به درستی انجام شده است که تمامی پارامترهای مؤثر در ساختار مدل طوری تعیین شوند که مقدار خطای مدل به حداقل مقدار خود برسد و همچنین مقادیر کارایی، بیشترین مقدار را داشته باشند (۲۲). ویژگی متمایزکننده ANFIS، فراهم کردن الگوریتم یادگیری پیوندی روش شیب پس انتشار و روش حداقل مربعات، به منظور اصلاح پارامترها می‌باشد.

روش گروهی مدل‌سازی داده‌ها (GMDH)

ایواخنکو اولین بار الگوریتم GMDH را به عنوان روشی جهت شناسایی روابط غیرخطی بین متغیرهای ورودی و خروجی پیشنهاد داد (۱۷). این الگوریتم یک رویکرد خودسازمانی بوده که توانایی به کارگیری در مدل‌سازی سیستم‌های پیچیده را دارد. شبکه

عصبی GMDH دارای ساختار شبکه‌ای چند لایه و پیشخور و مجموعه‌ای از نرون‌ها است. اتصال بین متغیرهای ورودی و خروجی را می‌توان با استفاده از سری چند جمله‌ای پیچیده به نام سری Volterra به صورت معادله (۱) بیان کرد (۲۴):

$$\bar{y} = a_0 + \sum_{i=1}^n a_i X_i + \sum_{i=1}^n \sum_{j=1}^n a_{ij} X_i X_j + \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n a_{ijk} X_i X_j X_k + \dots \quad (1)$$

که، X نشان‌دهنده متغیر ورودی، $\bar{y}$ متغیر خروجی، n تعداد ورودی‌ها و a ضریب است. سری Volterra، که یک شکل کلی معادله ریاضی است و می‌تواند با استفاده از چند جمله‌ای درجه دوم مانند معادله (۲) تقریب زده شود. در الگوریتم GMDH برای تولید نرون‌های لایه اول تمام متغیرهای ورودی با هم ترکیب شده و تمام ترکیبات دوتایی متغیرهای ورودی در نظر گرفته می‌شوند. به عنوان مثال اگر تعداد متغیرهای ورودی برابر n باشد، تعداد نرون‌های لایه اول برابر با $L_1 = \binom{2}{n}$ محاسبه می‌گردد که در این رابطه n تعداد متغیرهای ورودی می‌باشد.

$$\bar{y} = G(x_i, x_j) = a_1 x_1^2 + a_2 x_2^2 + a_3 x_1 + a_4 x_2 + a_5 x_1 x_2 + a_6 \quad (2)$$

پارامترهای مجهول در معادله (۲) ضرایب چند جمله‌ای است که با استفاده از روش‌های رگرسیون به گونه‌ای محاسبه می‌شود که اختلاف بین خروجی واقعی y و مقادیر محاسبه شده $\bar{y}$ برای هر جفت متغیرهای ورودی به حداقل برسد.

شبکه تابع پایه شعاعی (RBF)

شبکه‌های تابع پایه شعاعی شبکه‌های پیشرویی هستند که اولین بار توسط برومهید و لاو (۸) معرفی شدند. اساس این شبکه‌ها، توابع اندازه‌گیری فاصله از مرکز می‌باشد. شبکه‌ای با تابع شعاعی، تقریب سازهای بسیار قدرتمندی هستند به طوری که با داشتن تعداد نرون‌های کافی در لایه مخفی، قادر به تقریب‌سازی هر تابع پیوسته و با هر درجه دقت است. این شبکه‌ها بیشترین الهام را از تکنیک‌های آماری طبقه‌بندی الگوها گرفته‌اند که اساساً به عنوان گونه‌ای از شبکه‌های عصبی، حیاتی نو یافته‌اند و مزیت عمده آنها طبقه‌بندی الگوهایی است که دارای فضای غیرخطی هستند. RBF در ساده‌ترین حالت خود از سه لایه تشکیل شده است: لایه اول به عنوان لایه ورودی، مجموعه‌ای از گره‌های اصلی (واحدهای حسی) است. لایه دوم یک لایه پنهان است که در آن هر گره دارای مرکز و شعاع خاص خود و لایه سوم هم لایه خروجی است که پاسخ شبکه به تابع فعال‌سازی مورد استفاده در لایه ورودی را فراهم می‌کند (۱۰). روش محاسبه خروجی شبکه در معادله (۳) نشان داده شده است.

$$y = \sum_{i=1}^m W_i f_i(x) + b = \exp\left[\frac{-\|x - m_i\|^2}{d^2}\right] + b \quad (3)$$





که در آن، W_i نشان‌دهنده وزن یال، b بایاس، f تابع فعال‌سازی گوسی با مرکز m و پراکندگی d و $\| \cdot \|$ نشان‌دهنده نماد اقلیدسی است. توجیه ریاضیاتی انتخاب این توابع تبدیل بدین گونه بیان شده که مسئله رده‌بندی الگوی پیچیده‌ای که در یک فضای بعد بالای غیر خطی شکل گرفته است، محتمل‌تر است که به صورت خطی در فضای بعد پایین قابل تفکیک باشد.

مدل درخت تصمیم رگرسیونی (Rtree)

مدل درختی توسعه ایده و مفهوم درختان رگرسیونی است که دارای ساختار درختی وارونه است، این ساختار شامل یک گره ریشه در بالاترین قسمت درخت است که به گره‌های دیگر و برگ‌ها به صورت منشعب نمایش داده می‌شود و در قالب قوانین اگر-آنگاه قابل بیان است. اساس مدل درختی روش تقسیم و غلبه صفات برای نمونه‌هایی است که به یک گره می‌رسند. در ابتدا مدل درختی با تقسیم کردن فضای مسأله به صورت برگشتی یک درخت رگرسیونی می‌سازد. در این الگوریتم برای ایجاد شاخه در یک گره تقسیم، از پارامتر انحراف معیار مقادیر متغیر هدف به عنوان یک معیار اندازه‌گیری خطا در آن گره استفاده می‌شود و آزمونی برای انجام عملیات تقسیم در گره مذکور انجام شده، سپس صفتی که موجب کاهش بیش‌تر انحراف معیار گردد، به عنوان صفتی که روی آن شاخه زده شود، انتخاب می‌شود. کاهش انحراف معیار استاندارد با استفاده از رابطه (۴) محاسبه می‌شود (۷). این مدل قادر به استخراج دانش به شکل روابط ریاضی از مجموعه داده‌ها است.

$$SDR = sd(T) - \sum_i \frac{T_i}{T} \times sd(T_i) \quad (4)$$

در این رابطه، T ، T_i و sd به ترتیب معرف نمونه‌های به گره رسیده، مجموعه‌های حاصل از تقسیم گره براساس صفت انتخابی و انحراف معیار داده‌ها می‌باشند. در این روش، برخلاف دیگر روش‌های هوش مصنوعی از قبیل شبکه عصبی مصنوعی، برای آموزش به مدل نیازی به فرایند وقت‌گیر آزمون و خطا نیست. ساختار مدل‌های به کار گرفته شده در این مطالعه در شکل ۲ نشان داده شده است.



شکل ۲- ساختار مدل‌های به کار گرفته شده

در این مطالعه، به منظور تعیین ورودی‌های مدل، چهار فاکتور ریخت‌شناسی (عمق و عرض رودخانه)، هیدرولوژیکی (جریان حداقل، جریان حداکثر و جریان میانگین)، کاربری اراضی (سطح زیر کشت محصولات زراعی و باغی) و ترکیب سه سناریو مذکور در نظر گرفته شد. متغیرهای مذکور در غالب چهار سناریو به عنوان متغیرهای ورودی به مدل معرفی شدند. قبل از انجام مدل‌سازی، در مرحله اول همگنی داده‌های منتخب بررسی گردید. همچنین، معیار انتخاب پارامترهای به کار گرفته شده در پژوهش، معنی‌دار بودن میزان همبستگی آنها با متغیر خروجی یعنی برداشت آب از رودخانه جهت تأمین مصارف کشاورزی در سطح معنی‌داری ۰/۰۵ بوده است. در نهایت، به منظور تخمین میزان برداشت آب از رودخانه مدل‌های ANFIS، GMDH، RBF و Rtree به کار گرفته شد.

معیارهای ارزیابی دقت مدل‌ها

به منظور ارزیابی مدل‌ها، از شاخص‌های آماری ضریب همبستگی ((Correlation Coefficient (R)، ریشه میانگین مربعات خطا ((Root Mean Square Error (RMSE)، میانگین خطای مطلق ((Mean Absolute Error (MAE) و ضریب کارایی نش-ساتکلیف ((Nash-Sutcliffe Model Efficiency Coefficient (NSE) مطابق روابط (۵) تا (۸) استفاده شده است.

$$R = \left[\frac{\sum_{i=1}^N (RWA_{io} - \overline{RWA_o})(RWA_{ie} - \overline{RWA_e})}{\sqrt{\sum_{i=1}^N (RWA_{io} - \overline{RWA_o})^2 \sum_{i=1}^N (RWA_{ie} - \overline{RWA_e})^2}} \right] \quad (5)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (RWA_{io} - RWA_{ie})^2} \quad (6)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |RWA_{io} - RWA_{ie}| \quad (7)$$

$$NSE = 1 - \frac{(RWA_{ie} - \overline{RWA_{io}})^2}{(\overline{RWA_{io}} - \overline{RWA_o})^2} \quad (8)$$

در این روابط، RWA_{io} و RWA_{ie} مقادیر برداشت آب از رودخانه مشاهداتی و تخمینی و n تعداد کل داده‌ها است. $\overline{RWA_o}$ و $\overline{RWA_e}$ میانگین مقادیر برداشت آب از رودخانه مشاهداتی و تخمینی است. بهترین مدل با توجه به این معیارها، مدلی خواهد بود که مقدارهای چهار معیار برای آن به ترتیب نزدیک به یک، صفر، صفر و یک، باشد. در این مطالعه، به ترتیب ۷۰ درصد و ۳۰ درصد داده‌ها (۲۷۲ و ۱۱۷ نمونه‌برداری) برای آموزش و آزمون مدل‌ها به کار گرفته شده است.

نتایج و بحث

مشخصات مدل‌های بهینه به دست آمده جهت تخمین میزان برداشت آب از رودخانه در جدول ۲ آورده شده است. همانطور که در این جدول مشاهده می‌شود در روش سامانه استنتاجی فازی-عصبی تطبیقی تعداد بهینه خوشه، برای تمامی مدل‌های ANFIS_{۱۱} تا ANFIS_{۴۱} یکسان (برابر با ۵)، به دست آمد. در مدل‌های GMDH_{۲۱} تا GMDH_{۲۴} تعداد نرون‌های بهینه به ترتیب ۳۰، ۲۸، ۳۰ و ۳۳ و همچنین حداکثر تعداد لایه به ترتیب ۵، ۵، ۶ و ۸ به دست آمد. همچنین، حداکثر تعداد نرون در مدل‌های RBF_{۳۱} تا RBF_{۳۴} به ترتیب ۳۰، ۳۳، ۳۰ و ۲۹ محاسبه شد. در نهایت، تعداد شاخه‌ها در مدل Rtree_{۴۱} الی Rtree_{۴۴} به ترتیب ۱۴، ۱۶، ۱۴ و ۲۰ به دست آمد. نتایج حاصل از تمامی مدل‌های به کار گرفته شده بر اساس شاخص‌های آماری در جدول ۳ آورده شده است. هر کدام از این مدل‌ها با اندیس j مشخص شده‌اند که i (۱ تا ۴) به ترتیب نشان‌دهنده مدل‌های ANFIS، GMDH، RBF و Rtree و j (۱ تا ۴) نشان‌دهنده سناریوهای ورودی می‌باشد. به طور کلی، نتایج نشان می‌دهد که به ازای سناریو یکسان، مدل‌های GMDH بهترین و مدل‌های Rtree ضعیف‌ترین نتایج را ارائه داده‌اند.

جدول ۲- مشخصات مدل‌های بهینه

مدل‌ها	مقادیر	مشخصات	مدل‌ها	مقادیر	مشخصات
ANFIS _{۱۱}	۵، ۲، ۱۰۰۰، ۰/۰۰۰۰۱	تعداد توابع عضویت، ضریب ماتریس	RBF _{۳۱}	۳۰، ۰/۵	پراکندگی، حداکثر
ANFIS _{۱۲}	۵، ۲، ۱۰۰۰، ۰/۰۰۰۰۱	پارتیشن، حداکثر تعداد تکرار، حداقل	RBF _{۳۲}	۳۳، ۰/۴۵	تعداد نرون‌ها
ANFIS _{۱۳}	۱۰۰۰، ۰/۰۵، ۰/۸۵، ۱/۱	توسعه، حداکثر تعداد اپوک، اندازه گام	RBF _{۳۳}	۲۹، ۰/۴۱	
ANFIS _{۱۴}		اولیه، نرخ کاهش گام، نرخ افزایش گام	RBF _{۳۴}	۳۰، ۰/۴۸	
GMDH _{۲۱}	۳۰، ۵، ۰/۹		Rtree _{۴۱}	۱۴، ۸	
GMDH _{۲۲}	۲۸، ۵، ۰/۸۸	حداکثر تعداد نرون‌ها در هر لایه،	Rtree _{۴۲}	۱۶، ۶	برگ، شاخه‌ها
GMDH _{۲۳}	۳۰، ۶، ۰/۸۵	حداکثر تعداد لایه‌ها، فشار انتخابی	Rtree _{۴۳}	۱۴، ۸	
GMDH _{۲۴}	۳۳، ۸، ۰/۸۹		Rtree _{۴۴}	۲۰، ۱۲	

در تمامی مدل‌ها بهترین سناریو، سناریوی چهارم (ترکیب سناریوهای ۱ تا ۳) است. همچنین سناریو ۱ ضعیف‌ترین نتایج را در تخمین برداشت آب از رودخانه، دارد. بنابراین، می‌توان گفت در میان ۱۶ مدل پژوهش، مدل GMDH_{۲۴} به عنوان بهترین مدل و مدل Rtree_{۴۱} به عنوان ضعیف‌ترین مدل معرفی شده‌اند. بیشترین مقدار ضریب همبستگی و ضریب کارایی نش-ساتکلیف در مدل GMDH_{۲۴} به ترتیب ۰/۹۷۰ و ۰/۹۱۲ بوده است. همچنین، کمترین مقدار ریشه میانگین مربعات خطا و میانگین خطای مطلق نیز مربوط به مدل مذکور بوده و برابر با ۰/۰۴۶ و ۰/۰۳۶ به دست آمده است. حداقل مقدار ضریب همبستگی و ضریب کارایی نش

مربوط به مدل Rtree_{۴۱} بوده و به ترتیب ۰/۷۲ و ۰/۵۱ بدست آمد، درحالیکه مقدار ریشه میانگین مربعات خطا و میانگین خطای مطلق در این مدل ۰/۱۰۹ و ۰/۰۸۱ محاسبه شده است.


جدول ۳- نتایج مدل‌های بهینه

مدل‌ها	ضریب همبستگی	ریشه میانگین مربعات خطا	میانگین خطای مطلق	ضریب کارایی	مدل‌ها	ضریب همبستگی	ریشه میانگین مربعات خطا	میانگین خطای مطلق	ضریب کارایی
ANFIS _{۱۱}	۰/۷۴۴	۰/۱۰۸	۰/۰۷۸	۰/۵۱۳	RBF _{۳۱}	۰/۷۶۶	۰/۱۰۵	۰/۰۷۴	۰/۵۴۸
ANFIS _{۱۲}	۰/۹۰۴	۰/۰۶۷	۰/۰۴۴	۰/۸۱۶	RBF _{۳۲}	۰/۹۲۹	۰/۰۶۳	۰/۰۴۰	۰/۸۳۷
ANFIS _{۱۳}	۰/۷۵۷	۰/۱۰۵	۰/۰۷۳	۰/۵۴۶	RBF _{۳۳}	۰/۷۶۶	۰/۱۰۳	۰/۰۷۳	۰/۵۵۶
ANFIS _{۱۴}	۰/۹۳۴	۰/۰۵۶	۰/۰۴۱	۰/۸۷۰	RBF _{۳۴}	۰/۹۵۵	۰/۰۴۸	۰/۰۳۸	۰/۹۰۳
GMDH _{۲۱}	۰/۷۷۵	۰/۱۰۲	۰/۰۷۳	۰/۵۷۲	Rtree _{۴۱}	۰/۷۲۰	۰/۱۰۹	۰/۰۸۱	۰/۵۱۰
GMDH _{۲۲}	۰/۹۴۲	۰/۰۵۷	۰/۰۳۹	۰/۸۶۲	Rtree _{۴۲}	۰/۸۸۴	۰/۰۷۴	۰/۰۴۶	۰/۷۷۶
GMDH _{۲۳}	۰/۸۰۴	۰/۰۹۳	۰/۰۶۹	۰/۶۴۱	Rtree _{۴۳}	۰/۷۴۰	۰/۱۰۵	۰/۰۷۹	۰/۵۴۱
GMDH_{۲۴}	۰/۹۷۰	۰/۰۴۶	۰/۰۳۶	۰/۹۱۲	Rtree_{۴۴}	۰/۹۲۶	۰/۰۵۹	۰/۰۴۴	۰/۸۵۲


درصد بهبود عملکرد مدل GMDH_{۲۴} نسبت به مدل‌های GMDH_{۲۱}، GMDH_{۲۲} و GMDH_{۲۳}، بر اساس شاخص ضریب همبستگی

به ترتیب ۲۰، ۲/۹ و ۱۷ درصد می‌باشد. شکل‌های ۳ تا ۶ مقادیر مشاهداتی و تخمینی برداشت آب از رودخانه را با استفاده از چهار


مدل ANFIS، GMDH، RBF و Rtree و بر اساس سناریوهای ۱ تا ۴ برای دوره آزمون نشان می‌دهد.




شکل ۳- مقادیر مشاهداتی و تخمینی برداشت آب از رودخانه با استفاده از مدل‌های ANFIS_{۱۱}، GMDH_{۲۱}، RBF_{۳۱}، Rtree_{۴۱}



شکل ۴- مقادیر مشاهداتی و تخمینی برداشت آب از رودخانه با استفاده از مدل‌های $ANFIS_{12}$, $GMDH_{12}$, RBF_{12} , $Rtree_{12}$




شکل ۵- مقادیر مشاهداتی و تخمینی برداشت آب از رودخانه با استفاده از مدل‌های $ANFIS_{13}$, $GMDH_{13}$, RBF_{13} , $Rtree_{13}$




شکل ۶- مقادیر مشاهداتی و تخمینی برداشت آب از رودخانه با استفاده از مدل‌های $ANFIS_{14}$, $GMDH_{24}$, RBF_{34} , $Rtree_{44}$

شکل ۷ مقایسه نتایج حاصل از مدل‌های $ANFIS$, $GMDH$, RBF و $Rtree$ را بر اساس شاخص‌های آماری نشان می‌دهد. مدل $GMDH$ با توجه به اینکه در ترکیب خود از تابع کولموگروف گابور و شبکه عصبی استفاده می‌کند، سبب می‌شود که دقت نتایج ارائه شده با توجه به در نظر گرفتن روابط بین اعضا، بیش از سه مدل دیگر باشد. این مدل در صورتی که پارامتری باعث کاهش دقت شود آن را در مدل‌سازی دخالت نداده و با ایجاد ترکیب‌های متنوع، بهینه‌ترین حالت را ارائه می‌دهد. پس از مدل $GMDH$ ، نتایج مدل RBF با توجه به تابع رگرسیون موجود در آن از دقت بالاتری برخوردار می‌باشد. این رگرسیون تأثیر کمتری نسبت به تابع کولموگروف دارد. مدل $ANFIS$ در رتبه سوم عملکرد مدل‌ها قرار دارد. نتایج این مدل نشان داد که سیستم‌های فازی روش ایده‌آل برای پیش‌بینی در این تحقیق نیست. علت این موضوع عدم تأثیر مناسب شبکه عصبی در یادگیری قوانین فازی است. در نهایت، مدل $Rtree$ در رتبه چهارم قرار دارد که در آن از نرون برای یادگیری و آموزش استفاده نشده است و دقت پایین‌تری نسبت به سایر مدل‌های مورد استفاده در این پژوهش دارد.




شکل ۷- مقایسه نتایج مدل‌های تخمینی

دیاگرام تیلور ابزاری مناسب برای ارزیابی روش‌های به کار گرفته شده، می‌باشد و در سال‌های اخیر در مطالعات مربوط به آب و هواشناسی کاربرد فراوانی داشته است. نمودار تیلور برای ارزیابی عملکرد روش‌ها جهت تخمین متغیر آب برداشتی از رودخانه با متغیر مشاهداتی بر اساس شاخص‌های آماری R ، $RMSE$ و انحراف معیار به کار می‌رود (۲۶). مقایسه عملکرد مدل‌های $ANFIS$ ، $Rtree$ و RBF ، $GMDH$ برای تخمین برداشت آب از رودخانه منطقه مورد مطالعه در شکل ۸ نشان داده شده است. هیستوگرام، باند اطمینان و پیش‌بینی ۹۵٪ جهت تخمین میزان برداشت آب رودخانه در مدل ($GMDH_{۲۴}$) و سناریو برتر (چهارم) در شکل ۹ آورده شده است. نقاط تخمینی بر اساس مدل بهینه در محدوده باند پیش‌بینی قرار دارد که عملکرد مناسب مدل را تأیید می‌کند. نمودارهای ویولن چگالی متغیرها را نشان می‌دهد. هرچه نقاط داده در یک محدوده خاص بیشتر باشد، ویولن برای آن دامنه بزرگتر است. دیاگرام ویولن مربوط به مدل برتر ($GMDH$) برای سناریوهای مختلف در شکل ۱۰ نشان داده شده است.




شکل ۸- مقایسه نتایج روش‌های به کار گرفته شده جهت تخمین میزان برداشت آب از رودخانه با استفاده از دیاگرام تیلور



شکل ۹- هیستوگرام، باند اطمینان و پیش‌بینی ۹۵٪ جهت تخمین میزان برداشت آب از رودخانه در مدل (GMDH₂₄) و سناریو

برتر



شکل ۱۰- دیاگرام ویولن مربوط به مدل برتر (GMDH) برای سناریوهای مختلف

در جدول ۴ مقادیر مشاهداتی نرمال شده، تخمینی نرمال شده و قدرمطلق خطای تخمین برای مدل برتر (GMDH) و سناریو چهارم در دو بازه ۲۰ درصد حداقل و حداکثر، ارائه شده است. نتایج نشان می‌دهد که میانگین قدرمطلق خطای تخمین به ترتیب برای بازه‌های ۲۰ درصد حداقل و حداکثر ۰/۰۲ و ۰/۰۶ به دست آمده است.

جدول ۴- مقادیر مشاهداتی، تخمینی نرمال شده و قدرمطلق خطای تخمین برای مدل برتر (GMDH) و سناریو چهارم

۲۰ درصد حداقل			۲۰ درصد حداکثر		
مشاهداتی	تخمینی	قدرمطلق خطای تخمین	مشاهداتی	تخمینی	قدرمطلق خطای تخمین
نرمال	نرمال	تخمین	نرمال	نرمال	تخمین
۰/۰۰	۰/۰۴	۰/۰۴	۰/۲۰	۰/۱۳	۰/۰۶
۰/۰۰	۰/۰۰	۰/۰۰	۰/۲۰	۰/۱۵	۰/۰۵
۰/۰۰	۰/۰۲	۰/۰۲	۰/۲۷	۰/۲۳	۰/۰۴
۰/۰۰	۰/۰۲	۰/۰۲	۰/۲۷	۰/۲۶	۰/۰۱
۰/۰۰	۰/۰۲	۰/۰۲	۰/۲۷	۰/۲۶	۰/۰۱
۰/۰۱	۰/۰۴	۰/۰۳	۰/۳۰	۰/۲۳	۰/۰۶
۰/۰۱	۰/۰۴	۰/۰۳	۰/۳۰	۰/۲۳	۰/۰۶
۰/۰۲	۰/۰۶	۰/۰۴	۰/۳۰	۰/۲۴	۰/۰۵
۰/۰۲	۰/۰۳	۰/۰۱	۰/۳۲	۰/۳۲	۰/۰۱
۰/۰۲	۰/۰۳	۰/۰۱	۰/۳۶	۰/۳۱	۰/۰۴
۰/۰۲	۰/۰۳	۰/۰۱	۰/۳۶	۰/۳۶	۰/۰۰
۰/۰۳	۰/۰۴	۰/۰۱	۰/۳۸	۰/۲۹	۰/۰۹
۰/۰۳	۰/۰۲	۰/۰۱	۰/۴۰	۰/۳۱	۰/۰۹
۰/۰۴	۰/۰۳	۰/۰۱	۰/۴۵	۰/۳۹	۰/۰۶
۰/۰۴	۰/۰۷	۰/۰۳	۰/۶۶	۰/۵۳	۰/۱۳
۰/۰۴	۰/۰۷	۰/۰۳	۱/۰۰	۰/۸۲	۰/۱۸

همانطور که ذکر شد، سناریو چهارم که ترکیبی از سناریوهای اول تا سوم می‌باشد، به عنوان بهترین ورودی (رتبه اول) معرفی شد. علت این امر را می‌توان به این موضوع نسبت داد که سناریوی چهارم تأثیر تمامی متغیرهای ورودی را در تخمین میزان برداشت آب از رودخانه به طور همزمان در برمی‌گیرد. بعد از این سناریو، سناریوی هیدرولوژیکی (رتبه دوم) نتایج بهتری نسبت به سناریوی ریخت‌شناسی و کاربری اراضی داشت. زیرا همانگونه که مشخص است رابطه کاملاً مستقیمی بین جریان رودخانه و برداشت آب از آن وجود دارد به گونه‌ای که پس از کسر نیازهای زیست‌محیطی رودخانه و جریان پایه هر چقدر میزان آبدهی رودخانه افزایش یابد، میزان برداشت آب کشاورزی از آن نیز در صورت عدم نظارت کافی افزایش خواهد داشت. سناریو کاربری اراضی در رتبه سوم

بهترین ورودی‌ها قرار دارد. با توجه به اینکه کاربری اراضی در بخش کشاورزی به چهار کلاس مرتعی، آبی، دیم و جنگلی تقسیم می‌شود، با هرگونه تغییر کاربری از مرتعی و جنگلی به سمت دیم و آبی میزان مصرف و برداشت آب از رودخانه نیز افزایش خواهد یافت. در بخش زراعی و باغی نیز نوع سطح زیر کشت محصولات و روش آبیاری بر میزان مصرف آب تأثیر مستقیم دارد به عنوان مثال راندمان آبیاری در روش غرقابی حدود ۲۰ تا ۳۰ درصد و در روش آبیاری بارانی ۷۰ تا ۷۵ درصد و در روش موضعی به محدوده ۸۵ تا ۹۰ درصد می‌رسد. در نهایت، نتایج نشان داد که سناریو ریخت‌شناسی در رتبه چهارم قرار دارد. با توجه به اینکه اکثر رودخانه‌ها تمایل به پایداری و تثبیت دارند، لذا، تغییرات ریخت‌شناسی رودخانه (حریم و بستر) در این راستا صورت می‌گیرد. اکثر برداشت‌های آب‌های سطحی از نهرها و رودخانه‌های فصلی صورت می‌گیرد و این رودخانه‌ها اکثراً در رده رودخانه‌های پیر دسته‌بندی می‌شوند که تقریباً در حالت تثبیت قرار داشته و تغییرات ریخت‌شناسی بالایی مانند رسوبگذاری و آورد حاصل از فرسایش بالادست را ندارند. بنابراین، برداشت پایدار و مطمئن از این رودخانه‌ها جهت مصارف کشاورزی صورت می‌گیرد و این مورد تأثیر چندانی بر برداشت آب از رودخانه ندارد. نتایج این مطالعه، با نتایج مطالعات بسیاری از محققین از جمله احمد و شاه (۵) و عمادی و همکاران (۱۴) در زمینه تأثیر عوامل مختلف از جمله خصوصیات هیدرولوژیکی و مورفولوژیکی رودخانه و کاربری اراضی بر میزان برداشت آب از رودخانه، همخوانی دارد.

نتیجه‌گیری

آگاهی از میزان برداشت آب از رودخانه نقش مهمی در مدیریت منابع آب دارد. بر این اساس، با توجه به این که پیش‌بینی دقیق به منظور برنامه‌ریزی صحیح برای استفاده از منابع در آینده می‌تواند کمک قابل ملاحظه‌ای را به مدیران ارائه کند. لذا، در این پژوهش مدل‌های ANFIS، GMDH، RBF و Rtree برای تخمین میزان برداشت از رودخانه در منطقه نوبران به کار گرفته شدند. نتایج حاصل از این مدل‌ها نشان داد که بر اساس شاخص‌های ارزیابی به ازای مجموعه ورودی یکسان، مدل GMDH بالاترین و مدل Rtree ضعیف‌ترین عملکرد را در پیش‌بینی میزان برداشت از رودخانه در میان مدل‌های هوشمند، دارند. همچنین، نتایج حاکی از این بود که سناریو ۴ (ترکیب مجموعه‌های ریخت‌شناسی، هیدرولوژی و کاربری اراضی) به عنوان بهترین مجموعه ورودی نتایجی با دقت بالاتر نسبت به سایر سناریوها ارائه می‌دهد. از آنجایی که میزان برداشت آب از رودخانه‌ها به عنوان یک سیستم پیچیده می‌تواند تحت تأثیر متغیرهای متعددی باشد، لذا پیشنهاد می‌گردد در تحقیقات آتی محققین به بررسی اثرات متغیرهای مختلف از جمله تراکم

جمعیت، شرایط اکوهیدرولوژیکی، میزان نیاز آبی محصولات، فصول کشت و ترکیب حقابه‌ها بر میزان برداشت آب از روخانه پرداخته و مدل‌های ترکیبی داده محور را نیز جهت مدل‌سازی در این زمینه به کار بگیرند.

تقدیر و تشکر

این مقاله مستخرج از طرح پژوهشی دانشگاهی می‌باشد. نویسندگان این مقاله از دانشگاه علوم کشاورزی و منابع طبیعی ساری (SANRU) به دلیل حمایت مالی، کمال تشکر را دارند (کد طرح: ۱۰-۱۴۰۰-۰۲).

منابع

1. Abbasian, M and A. Sardar Shahraki. 2020. Modeling and comparing GMDH and RBF Artificial Neural Networks in forecasting short-term demand for drinking water in Zahedan. *Journal of Irrigation and Water Engineering* 10 (3): 248-261.
2. Abdollahpour, M and M. Sattari. 2015. Forecasting daily river flow of Ahar Chay River using Artificial Neural Networks (ANN) and comparison with Adaptive Neuro Fuzzy Inference System (ANFIS). *Journal of Water and Soil Conservation* 22 (1): 287-298.
3. Afkhami, H., A. Habibi Pour and M. R. Ekhtesasi. 2018. Performance assessment of data mining techniques for forecast for one year evaporation (A Case study: Yazd Synoptic Station). *Journal of Range and Watershed Management* 71 (3): 563-578. (In Persian).
4. Aghelpour, P and V. Varshavian. 2020. Evaluation of stochastic and artificial intelligence models in modeling and predicting of river daily flow time series. *Stochastic Environmental Research and Risk Assessment* 34 (1): 33-50.
5. Ahmed, A. M and S. M. A. Shah. 2017. Application of artificial neural networks to predict peak flow of Surma River in Sylhet Zone of Bangladesh. *International Journal of Water* 11 (4): 363-375.
6. Bonakdari, H., A. D. Binns and B. Gharabaghi. 2020. A Comparative Study of Linear Stochastic with Nonlinear Daily River Discharge Forecast Models. *Water Resources Management* 34 (11): 3689-3708.
7. Breiman, L., J. Friedman., C. J. Stone and R. A. Olshen. 1984. Classification and regression trees. *CRC press* pp. 277-287.
8. Broomhead, D. s and D. Lowe. 1988. Multivariable functional interpolation and adaptive networks. *Complex Systems* 2 (3): 321-355.
9. Caldwell, P. V., G. Sun., S. G. McNulty., E. C. Cohen and J. M. Myers. 2012. Impacts of impervious cover, water withdrawals, and climate change on river flows in the conterminous US. *Hydrology and Earth System Sciences* 16: 2839-2857.
10. Chen, L-H., C-T. Chen and Y-G. Pan. 2010. Groundwater level prediction using SOM-RBFN multisite model. *Journal of Hydrologic Engineering* 15 (8): 624-625.
11. Coe, M. T., M. H. Costa and B. S. Soares-Filho. 2009. The influence of historical and potential future deforestation on the stream flow of the Amazon River-Land surface processes and atmospheric feedbacks. *Journal of hydrology* 369 (1-2): 165-174.
12. Costa, M. H., A. Botta and J. A. Cardille. 2003. Effects of large-scale changes in land cover on the discharge of the Tocantins River, Southeastern Amazonia. *Journal of Hydrology* 283 (1-4): 206-217.
13. Dalkılıç, H. Y and S. A. Hashimi. 2020. Prediction of daily streamflow using artificial neural networks (ANNs), wavelet neural networks (WNNs), and adaptive neuro-fuzzy inference system (ANFIS) models. *Water Supply* 20 (4): 1396-1408.
14. Emadi, A., R. Sobhani., H. Ahmadi., A. Boroomandnia., S. Zamanzad-Ghavidel and H. M. Azamathulla. 2022. Multivariate modeling of agricultural river water abstraction via novel integrated-wavelet methods in various climatic conditions. *Environment, Development and Sustainability* 24 (4): 4845-4871.
15. Fuller, I. C and R. G. Death. 2018. The science of connected ecosystems: What is the role of catchment-scale connectivity for healthy river ecology?. *Land Degradation & Development* 29 (5): 1413-1426.
16. Ghorbani, M. A., H. A. Zadeh., M. Isazadeh and O. Terzi, O. 2016. A comparative study of artificial neural network (MLP, RBF) and support vector machine models for river flow prediction. *Environmental Earth Sciences* 75 (6): 476.

17. Ivakhnenko, AG. 1971. Polynomial theory of complex systems. *IEEE Transactions on Systems, Man, and Cybernetics* 1: 364–378.
18. Kişi, Ö. 2009. Evolutionary fuzzy models for river suspended sediment concentration estimation. *Journal of Hydrology* 372 (1-4): 68-79.
19. Loucks, D. P and E. van Beek. 2017. Water Resource Systems Modeling: Its Role in Planning and Management. *In Water Resource Systems Planning and Management* (pp. 51-72). Springer, Cham.
20. Mohammadi, B., N. T. T. Linh., Q. B. Pham, A. N. Ahmed., J. Vojteková., Y. Guan., S. I. Abba and A. El-Shafie. 2020. Adaptive neuro-fuzzy inference system coupled with shuffled frog leaping algorithm for predicting river streamflow time series. *Hydrological Sciences Journal* 65 (10): 1738-1751.
21. Nayak, P. C., K. P. Sudheer., D. M. Rangan and K. S. Ramasastri. 2004. A neuro-fuzzy computing technique for modeling hydrological time series. *Journal of Hydrology* 291 (1-2): 52-66.
22. Nourani, V and M. Komasi. 2013. A geomorphology-based ANFIS model for multi-station modeling of rainfall-runoff process. *Journal of Hydrology* 490: 41-55.
23. Piao, S., P. Friedlingstein., P. Ciais., N. de Noblet-Ducoudré., D. Labat and Zaehle, S. 2007. Changes in climate and land use have a larger direct impact than rising CO₂ on global river runoff trends. *Proceedings of the National academy of Sciences* 104 (39): 15242-15247.
24. Sharzei, G.A., M. Ahrari and H. Fakhrai. 2008. Prediction of water demand in Tehran using structural models, time series and GMDH neural network, *Economic research* 43: 151-175.
25. Talebi, A., J. Mahjoobi., M. T. Dastorani and V. Moosavi. 2017. Estimation of suspended sediment load using regression trees and model trees approaches (case study: Heyderabad drainage basin in Iran). *ISH journal of Hydraulic Engineering* 23 (2): 212-219.
26. Taylor, K.E. 2001. Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research: Atmospheres* 106 (D7): 7183-7192.
27. Zhang, Y., F. H. S. Chiew., M. Li and D. Post. 2018. Predicting Runoff Signatures Using Regression and Hydrological Modeling Approaches. *Water Resources Research* 54: 7859–7878.
28. Zhang, N., C. Xiao., B. Liu and X. Liang. 2017. Groundwater depth predictions by GSM, RBF, and ANFIS models: a comparative assessment. *Arabian Journal of Geosciences* 10 (8): 1-12.

Evaluation of the effects of morphological, hydrological, and land-use characteristics on river water abstraction using data mining methods

Abstract

The agricultural sector, as one of the most important sectors of water consumption, is of great importance for the sustainability of the country's water resources systems. The objective of this study was to estimate the River Water Abstraction (RWA) for agricultural purposes in the study area of Nobaran in the Namak Lake basin. RWA was estimated using variables related to morphological, hydrological, and land use factors, as well as a combination of their variables collected through field sampling. Data mining methods such as Adaptive-Network-based Fuzzy Inference Systems (ANFIS), Group Method of Data Handling (GMDH), Radial Basis Function (RBF) and Regression Trees (Rtree) were also used to estimate the RWA variables. In the current study, the GMDH₂₄ model with a combined scenario including the variables of river width, river depth, minimum flow, maximum flow, average flow, crop and garden cultivated area was adopted as the best model for estimating the RWA variable. The RMSE value for the combined scenario of the GMDH₂₄ model was found to be 0.046 for estimating RWA in the Nobaran study area. The results showed that the performance of the GMDH₂₄ model for estimating RWA for maximum values is very acceptable and promising. Therefore, modeling and identifying various variables that affect the optimal RWA rate for agricultural purposes fulfills the objectives of Integrated Water Resources Management (IWRM).

Keywords: Modeling, Water resources, Morphology, Hydrology, Land-use