



شبیه‌سازی سطح آب زیرزمینی دشت سلسله استان لرستان با استفاده از الگوریتم‌های فراکاوشی نوین

حمیدرضا باباعلی*

استادیار گروه مهندسی عمران، دانشگاه آزاد اسلامی واحد خرم آباد

تأیید نهایی مقاله: ۱۴۰۰/۰۶/۰۱

وصول مقاله: ۱۴۰۰/۰۵/۰۳

چکیده

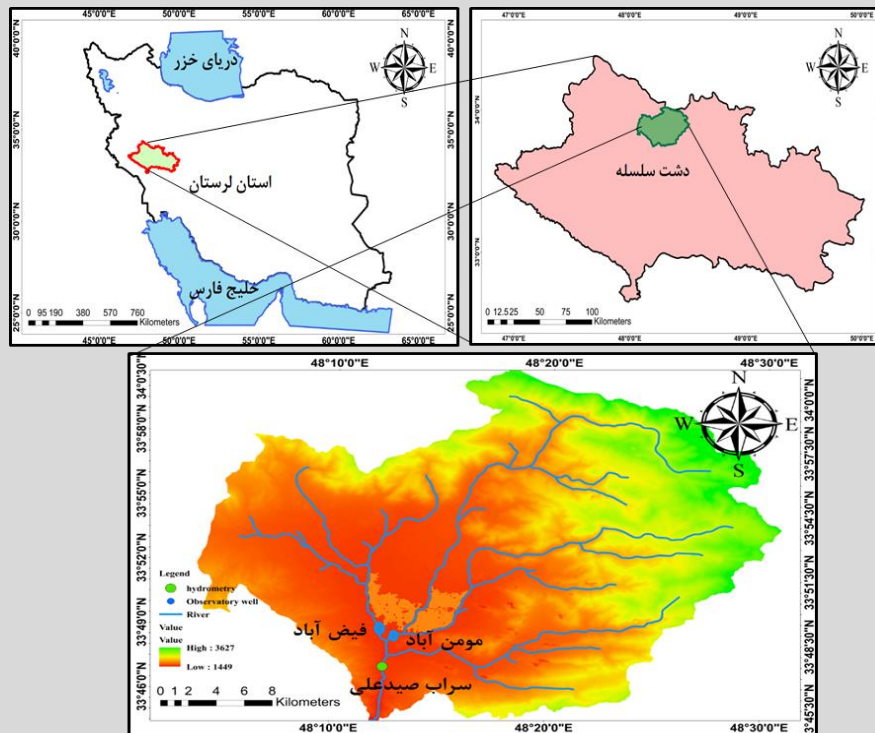
در سال‌های اخیر افت منابع آب زیرزمینی به‌عنوان مهم‌ترین چالش در مسائل مدیریت منابع آب مطرح است. اولین گام در جهت مدیریت آب زیرزمینی، شبیه‌سازی سطح آب زیرزمینی و شناسایی عوامل مؤثر بر سطح آب زیرزمینی است. از این رو در این پژوهش جهت شبیه‌سازی سطح آب زیرزمینی دشت سلسله واقع در استان لرستان از مدل ترکیبی رگرسیون بردار پشتیبان (SVR) با موجک و الگوریتم‌های فرا ابتکاری گرگ خاکستری (GWO) و خفاش (BA) در مقیاس زمانی ماهانه طی دوره‌ی آماری ۲۰۲۰-۲۰۱۰ استفاده شد. معیارهای ضریب همبستگی (R^2)، مجذور میانگین مربعات خطا (RMSE)، میانگین مطلق خطا (MAE)، ضریب بهره‌وری نش-ساتکلیف (NSE)، درصد بایاس (PBIAS) برای ارزیابی و مقایسه‌ی عملکرد مدل‌ها مورد استفاده قرار گرفت. نتایج نشان داد هر سه مدل هیبریدی، در الگوهای ترکیبی نتایج بهتری نسبت به سایر الگوهای تعیین‌شده دارند. همچنین، با توجه به معیارهای ارزیابی مشخص شد که از بین مدل‌های به‌کاررفته در شبیه‌سازی سطح آب زیرزمینی، مدل رگرسیون بردار پشتیبان-موجک با ضریب تعیین ($R^2=0/975-0/988$)، ریشه‌ی میانگین مربعات خطا ($RMSE=0/112-0/146$)، میانگین قدرمطلق خطا ($MAE=0/076-0/093m$) ضریب نش ساتکلیف ($NS=0/963-0/978$) و درصد بایاس ($PBIAS=0/001$) در مرحله‌ی صحت‌سنجی عملکرد بهتری نسبت به سایر مدل‌ها از خود نشان داده است.

کلمات کلیدی: افت سطح آب، رگرسیون بردار پشتیبان، دشت سلسله، استان لرستان

۱-مقدمه

با توجه به رشد روزافزون جمعیت و ضرورت استفاده بهینه از منابع آب، تأمین بیشترین مقدار ممکن آب‌های زیرزمینی برای رفع نیازهای همه‌ی انسان‌ها از اهمیت ویژه‌ای برخوردار است. بهره‌برداری بی‌رویه از منابع بسیاری از نقاط جهان و کشور ایران منفی شده است. به‌منظور آگاهی از وضعیت این منابع و مدیریت بهینه‌ی آن‌ها، لازم است پیش‌بینی دقیقی از نوسانات سطح آب زیرزمینی صورت گیرد. بیشتر سری‌های زمانی هیدرولوژیکی نظیر تغییرات سطح آب زیرزمینی همواره شامل فرایندهای نامانا و پیچیده هستند که با استفاده از مدل‌های خطی متداول و کلاسیک به‌خوبی قابل توصیف و مدلسازی نیستند. بنابراین به‌منظور مدل‌سازی این پدیده‌های هیدرولوژیکی لازم است از مدل‌های غیرخطی استفاده شود. امروزه سیستم‌های هوشمند به‌طور گسترده برای پیش‌بینی پدیده‌های غیرخطی مورد استفاده قرار می‌گیرد. با این وجود مشاهده شد که این مدل‌ها ظرفیت محدودی برای ضبط غیرثابت بودن و غیرخطی بودن در سری داده‌ها دارند که به‌نوبه‌ی خود می‌توان از طریق تکنیک‌های مدرن محاسبات نرم مانند رگرسیون بردار پشتیبان (SVR) بهتر به آن‌ها پرداخت. چنین تکنیک‌هایی از تحمل دنیای واقعی در برابر عدم قطعیت، عدم دقت و حقایق جزئی مرتبط با داده‌های طبیعی برای انجام مدل‌سازی یا پیش‌بینی مقادیر آینده استفاده می‌کنند (زارع و کو، ۲۰۱۸: ۴۴).

رگرسیون بردار پشتیبان یکی از مدل‌های مرسوم و قدرتمند برای مدل‌سازی فرایندهای هیدرولوژیکی و ژئوهیدرولوژیکی است که عموماً دارای ماهیتی پیچیده و غیرخطی است (کومار و همکاران، ۲۰۰۴: ۶۸). رگرسیون بردار پشتیبان دارای دو ضعف شاخص و برجسته می‌باشند. اول این که برای پیدا کردن بهترین جواب، نیازمند داده‌های زیاد و بلندمدت هستند. دوم زمانی که داده‌های تست خارج از محدوده باشند قدرت پیش‌بینی را دچار چالش بزرگ، ابهام و عدم قطعیت خواهند کرد (ملس و همکاران، ۲۰۱۱: ۸۷؛ کیسی و همکاران، ۲۰۱۴: ۵۲). برای برطرف کردن این ضعف، دو راهکار کلی وجود دارد: اول: الگوریتم‌های رگرسیون بردار پشتیبان با الگوریتم‌های منطق فازی تلفیق و ترکیب می‌شوند که اساس تشکیل سیستم استنتاج عصبی - فازی تطبیقی هستند. دوم: ترکیب رگرسیون بردار پشتیبان با الگوریتم‌های بهینه‌ساز فرا ابتکاری می‌باشد (ابتهاج و بونکداری، ۲۰۱۴: ۱۰۲؛ رجایی و همکاران، ۲۰۰۹: ۴۷). استفاده از مدل هیبریدی رگرسیون بردار پشتیبان با الگوریتم‌های فرا کاوشی در علوم و مهندسی آب صورت گرفته است که به‌اختصار به چند مورد در زمینه‌ی شبیه‌سازی سطح آب زیرزمینی اشاره می‌گردد:



شکل (۱): منطقه‌ی مورد مطالعه

Figure (1): The study area

جدول (۱): مشخصات جغرافیایی ایستگاه‌های مورد بررسی

Table (1): Geographical characteristics of the studied stations

ردیف	نوع ایستگاه	نام ایستگاه	عرض جغرافیایی	طول جغرافیایی
۱	چاه مشاهداتی	مومن آباد	۴۸° ۱۳' ۱۹"	۳۳° ۵۰' ۶"
۲	چاه مشاهداتی	فیض آباد	۴۸° ۱۱' ۵۱"	۳۳° ۵۰' ۲۱"
۳	هیدرومتری	سراب صید علی	۴۸° ۱۲' ۲۵"	۳۳° ۴۷' ۱۱"

سریکانت و همکاران^۱ (۲۰۰۹: ۲۴) عملکرد شبکه عصبی استاندارد FFN که با الگوریتم لونیگ-مارکورت (LM) آموزش داده شده، برای پیش‌بینی نوسانات سطح آب زیرزمینی در حوضه‌ی آبریز می‌شی وارم حیدرآباد هند مورد آزمایش قرار دادند. نتایج این تحقیق نشان داد که مدل مذکور بهترین انطباق و روند پیش‌بینی با داده‌های مشاهداتی دارد. استیل^۲ (۲۰۰۹: ۴۲) در مطالعه‌ای کاربرد شبکه‌های عصبی مصنوعی را در زمینه‌ی

ژئوهیدرولوژی مورد بررسی قرار داد. وی کاربرد انواع شبکه‌های عصبی را با استفاده از الگوریتم‌های متعدد مورد تحلیل قرار داده و بیان داشت که شبکه‌های پیشرو همراه با تأخیر زمانی مؤثرترین نوع شبکه در زمینه‌ی ژئوهیدرولوژی هستند. آداموسکی و چان^۱ (۲۰۱۱: ۱۰۲) از شبکه عصبی موجک جهت پیش‌بینی سطح آب زیرزمینی حوضه چاتوگای واقع در کانادا در سال ۲۰۰۲-۲۰۰۹ استفاده نمودند و نشان دادند شبکه عصبی موجک پتانسیل بالایی در پیش‌بینی تراز آب زیرزمینی دارد و می‌تواند این مدل در مدیریت آب‌های زیرزمینی مفید باشد. هاسنا و همکاران^۲ (۲۰۱۶: ۲۱۴) شبکه عصبی مصنوعی را جهت پیش‌بینی سطح آب زیرزمینی دشت چاندپور بنگلادش در طی سال ۱۹۸-۲۰۰۷ بکار بردند و نشان دادند شبکه عصبی مصنوعی خطای ناچیزی در پیش‌بینی سطح آب زیرزمینی دارد. کایا و همکاران^۳ (۲۰۱۸: ۲۱۴) در پژوهشی جهت بررسی میزان نوسانات سطح آب زیرزمینی منطقه‌ی ریحانی واقع در کشور ترکیه از شبکه عصبی مصنوعی و مدل M5 استفاده کردند و نشان داد دو مدل برای پیش‌بینی نوسانات آب زیرزمینی نتایج نزدیک به هم دارند. تندیا و همکاران^۴ (۲۰۱۹: ۲۴۲) به ارزیابی مدل شبکه عصبی هیبریدی در منطقه شیکاگو ژاپن پرداختند نتایج تحقیقات نشان داد مدل شبکه عصبی هیبریدی عملکرد قابل قبولی نسبت به مدل شبکه عصبی مصنوعی دارد. لی و همکاران^۵ (۲۰۱۹: ۲۳۹) به منظور تعیین عملکرد شبکه‌های عصبی مصنوعی به تحلیل میزان نوسانات سطح آب زیرزمینی پرداختند نتایج نشان داد مدل شبکه عصبی پیشرو عملکرد قابل قبولی در پیش‌بینی نوسانات سطح آب زیرزمینی دارد. بهمنی و همکاران (۲۰۲۱: ۳۶) کارایی دو مدل ترکیبی برنامه‌ریزی بیان ژن-موجک و درخت تصمیم-موجک جهت شبیه‌سازی سطح آب زیرزمینی دشت دلفان واقع در استان لرستان مورد بررسی قرار دادند نتایج نشان داد مدل ترکیبی برنامه‌ریزی بیان ژن-موجک از عملکرد بهتری نسبت به سایر مدل‌ها برخوردار است. از سوی دیگر میلان و همکاران^۶ (۲۰۲۱: ۸۷) در پژوهشی کارایی مدل‌های هیبریدی فازی-زدحام ذرات، فازی-گرگ خاکستری وفازی-شاهین را جهت پیش‌بینی سطح آب زیرزمینی با استفاده از پارامترهای بارش، تبخیر، دما مورد بررسی قرار دادند نتایج نشان داد مدل ترکیبی فازی-الگوریتم شاهین برای پیش‌بینی سطح آب زیرزمینی از دقت قابل توجهی برخوردار است. در مجموع با توجه به پژوهش‌های انجام‌شده و همچنین اهمیت دشت سلسله از لحاظ شرب و کشاورزی، که مهم‌ترین محدوده‌های استان لرستان واقع در کشور ایران از جهت تولید محصولات کشاورزی بوده و محصولات این دشت جهت رشد و نمو از آب‌های زیرزمینی تغذیه می‌کنند در سال‌های اخیر افت منابع آب زیرزمینی در این دشت سبب کاهش محصولات کشاورزی و و بحرانی شدن این دشت شده است. بنابراین اقدامات مدیریتی و ارائه راهکار به منظور مدیریت کمی دشت سلسله

1- Adamowski & Chan
 2- Ashmaul Husna
 3- Ziya Kaya

4- Thendiyath et al.
 5- Li et al.
 6- Milan et al.

امری لازم و ضروری می‌باشد. لذا هدف از این تحقیق شناسایی پارامترهای مؤثر و شبیه‌سازی سطح آب زیرزمینی دشت سلسله با استفاده از مدل تلفیقی رگرسیون بردار پشتیبان با الگوریتم‌های بهینه‌سازی همچون گرگ خاکستری، خفاش و موجک بر اساس پارامترهای بارندگی، دما و سطح آب‌های زیرزمینی که در شرکت آب منطقه‌ای لرستان موجود بود، استخراج و مورد بررسی قرار گرفت.

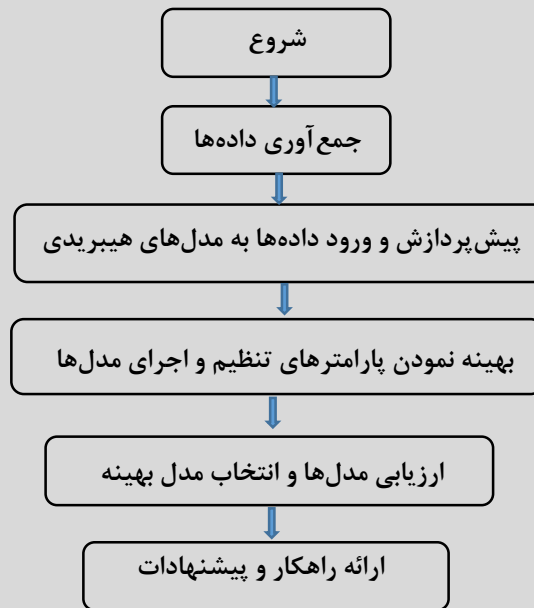
۲- مواد و روش‌ها

۲-۱- منطقه‌ی مورد مطالعه

استان لرستان واقع در کشور ایران یکی از استان‌های کوهستانی غرب ایران بوده که بیشتر مناطق این استان را کوه‌های زاگرس پوشانده است. آب‌وهوای استان لرستان متنوع و تنوع آب‌وهوا در آن از شمال شرق به جنوب غرب کاملاً مشهود است. از مهم‌ترین دشت‌های پرآب این استان سلسله می‌باشد. حوضه‌ی آبریز سلسله از زیرحوضه‌های رودخانه کشکان، که جزئی از حوضه‌ی آبریز کرخه از حوضه‌های آبریز اصلی کشور ایران می‌باشد، است. این دشت بین طول جغرافیایی $28^{\circ} 48'$ تا $31^{\circ} 48'$ شرقی و عرض جغرافیایی $33^{\circ} 43'$ تا $34^{\circ} 05'$ شمالی قرار داشته که ارتفاع متوسط دشت از سطح دریا حدود ۱۵۸۰ متر وسعت آن ۱۹۶ کیلومتر مربع می‌باشد. بارندگی متوسط سالانه دشت ۵۴ میلی‌متر و دمای متوسط سالانه $8/8$ درجه سانتی‌گراد است. سفره‌ی آبدار اصلی دشت سلسله را رسوبات آبرفتی تشکیل می‌دهد که در شکل ۱ نشان داده شده است. جدول ۱ موقعیت جغرافیایی چاه‌های مشاهداتی و ایستگاه مورد بررسی را نشان می‌دهد.

۲-۲- داده‌های مورد استفاده

در این پژوهش جهت شبیه‌سازی سطح آب زیرزمینی دشت سلسله واقع در استان لرستان از مدل‌های هیبریدی رگرسیون بردار پشتیبان_موجک، رگرسیون بردار پشتیبان_گرگ خاکستری و رگرسیون بردار پشتیبان_خفاش استفاده شد که در شکل ۲ فلوچارت مراحل شبیه‌سازی نشان داده شد. به منظور شبیه‌سازی سطح آب زیرزمینی از پارامترهای بارش (P)، دما (T) و سطح آب زیرزمینی (H) دو حلقه چاه مشاهداتی که مبنای بیان آب دشت سلسله بوده و دارای آمار همگن و فاقد داده مفقود می‌باشد، به صورت ماهانه از شرکت آب منطقه‌ای لرستان طی بازه‌ی زمانی ۲۰۲۰-۲۰۱۰ اخذ شد. که ۷۰٪ داده‌ها برای مدسازی و ساخت مدل (دوره‌ی آموزش) و ۳۰ درصد آن برای صحت‌سنجی و یا ارزیابی مدل (دوره‌ی تست) انتخاب شد (خسروی و همکاران، ۲۰۱۸: ۳۶).



شکل (۲): فلوچارت مراحل پژوهش

Figure (2): Flowchart of research stages

۳-۲- ماشین بردار پشتیبان

ماشین بردار پشتیبان بر مبنای تئوری بهینه‌سازی مقید می باشد که از اصل استقرای کمینه‌سازی خطای ساختاری استفاده نموده و سبب یک جواب بهینه کلی می‌گردد (واپنیک^۱، ۱۹۹۵: ۴۲). در این پژوهش از مدل رگرسیون بردار پشتیبان استفاده شد که به صورت زیر بیان می‌گردد. فرمول کلی رگرسیون بردار پشتیبان به صورت معادله ۱ می‌باشد در این معادله Y متغیر وابسته و x متغیر مستقل است که در نهایت به معادله ۲ منجر می‌شود.

$$y=f(x)+noise \quad (1)$$

$$F(x)=W^T \cdot \phi(x)+b \quad (2)$$

در معادله ۲، W^T ترانزاده بردار ضرایب و b ثابت مشخصه‌های تابع رگرسیونی و ϕ نیز تابع کرنل است. برای محاسبه W و b لازم است تابع خطا (معادله ۳) در مدل ϵ -SVM با در نظر گرفتن شرایط مندرج (قیود) در معادله ۴ و ۵ کمینه شود (هامل^۲، ۲۰۰۹: ۲۴).

$$\frac{1}{2}W^T \cdot W + C \sum_{i=1}^N \varepsilon_i + C \sum_{i=1}^N \varepsilon_i^* \quad (۳)$$

$$W^T \cdot \phi(X_i) + b - y_i \leq \varepsilon + \varepsilon_i^* \quad (۴)$$

$$y_i - W^T \cdot \phi(X_i) - b \leq \varepsilon + \varepsilon_i, \varepsilon_i, \varepsilon_i^* \geq 0, \quad i=1,2,\dots,N \quad (۵)$$

در معادلات بالا C عامل تعیین جریمه در هنگام رخ دادن خطای آموزش مدل است که عددی صحیح و مثبت می‌باشد. ϕ تابع کرنل، N تعداد نمونه‌ها و دو مشخصه ε_i^* و ε_i متغیرهای کمبود هستند. در نهایت تابع SVM رگرسیونی را می‌توان به صورت معادله‌ی ۶ نوشت:

$$f(x) = \sum_{i=1}^N \bar{\alpha}_i \phi(x_i)^T \cdot \phi(x) + b \quad (۶)$$

در معادله‌ی ۶، $\bar{\alpha}_i$ میانگین ضرایب لاگرانژ می‌باشد. با توجه به اینکه محاسبه‌ی تابع کرنل $\phi(x)$ در فضای مشخصه آن ممکن است بسیار پیچیده باشد بنابراین جهت تسهیل این پیچیدگی کرنل‌های متفاوتی معرفی شد (یون و همکاران^۱، ۲۰۱۱: ۱۲۱). مهم‌ترین توابع کرنل چندجمله‌ای^۲ و کرنل توابع پایه شعاعی^۳ (RBF) و کرنل خطی، به ترتیب طبق معادلات ۷-۹ بیان می‌شوند (باساک و همکاران^۳، ۲۰۰۷: ۲۲؛ واپنیک و چرونسکی^۴، ۱۹۹۱: ۳۲).

$$K(x, x_j) = (t + x_i \cdot x_j)^d \quad (۷)$$

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \quad (۸)$$

$$k(x, x_j) = x_i \cdot x_j \quad (۹)$$

۴-۲- تبدیل موجک

تبدیل موجک به‌عنوان مدلی همانند تبدیل فوریه‌ی زمان کوتاه جهت غلبه بر مشکلات مربوط به قدرت تفکیک‌پذیری فرکانس است. در این تبدیل سیگنال به پنجره‌هایی تقسیم‌شده و فرآیند بر روی هرکدام از این پنجره‌ها به‌صورت مجزا صورت می‌پذیرد (واپنیک، ۱۹۹۸: ۳۱). مهم‌ترین تفاوت سری فوریه زمان کوتاه با تبدیل موجک در قدرت تفکیک‌پذیری خلاصه می‌گردد به‌گونه‌ای که در تبدیل موجک در یک زمان عرض پنجره یا مقیاس فرکانس نیز متناسب با نوع فرکانس تغییر می‌نماید. به عبارت دیگر، در تبدیل موجک پارامتر مقیاس بجای فرکانس وارد می‌شود. بنابراین تبدیل موجک یک یعنی تبدیل زمان-مقیاس بوده به‌گونه‌ای که در

1- Yoon et al.

2- Polynomial

2- Radial Basis Functions (RBF)

3- Basak & Patranabis

4- Vapnik & Chervonenkis

مقیاس‌های بالا سیگنال منبسط شده و جزئیات سیگنال بررسی می‌گردد و در مقیاس‌های پایین سیگنال منقبض شده و کلیات سیگنال بررسی می‌شود (وانگ و همکاران، ۲۰۰۰: ۴۲). تبدیل موجک به دو صورت پیوسته و گسسته می‌باشد.

تبدیل موجک پیوسته (CWT)

تبدیل موجک پیوسته‌ی به صورت معادلات (۱۰) و (۱۱) بیان می‌گردد (واپنیک، ۱۹۹۸: ۳۱).

$$CWT_f^\psi(s, \tau) = \Psi_f^\psi(s, \tau) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} f(t) \psi^* \left(\frac{t-\tau}{s} \right) dt = \langle f(t), \psi_{s,\tau}(t) \rangle \quad (10)$$

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{|s|}} \psi \left(\frac{t-\tau}{s} \right) \quad (11)$$

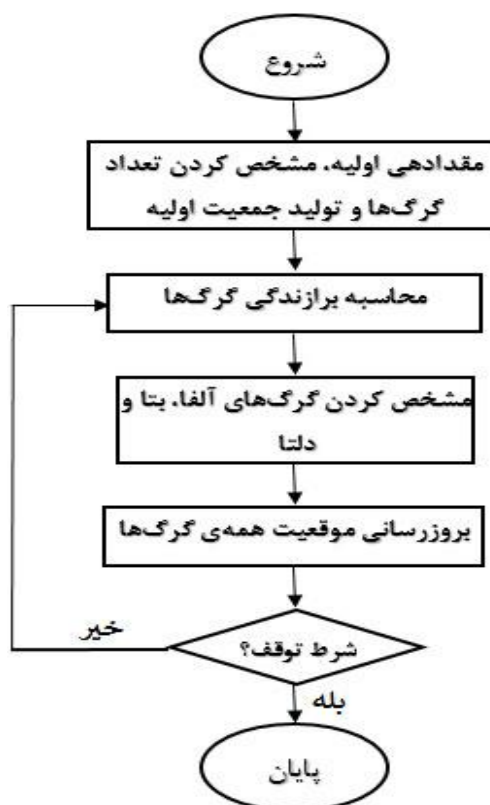
در این روابط s متغیر مقیاس و τ متغیر انتقال است. نشانه * بیان‌کننده‌ی مزدوج مختلط می‌باشد. ψ موجک مادر و $\frac{1}{\sqrt{|s|}} \psi \left(\frac{t-\tau}{s} \right)$ موجک‌های حاصل از انتقال و تغییر مقیاس موجک اصلی (مادر) می‌باشند (وانگ و همکاران، ۲۰۰۰).

۲-۵- الگوریتم گرگ خاکستری

الگوریتم گرگ خاکستری GWO یک الگوریتم فراکاووشی که از ساختار سلسله مراتبی و رفتار اجتماعی گرگ‌های خاکستری در هنگام شکار کردن بیان شده است (استا، ۱۹۷۹: ۲۱). این الگوریتم فرآیند ساده‌ای داشته و به دلیل آنکه مبتنی بر جمعیت بوده به سادگی به مسائل با ابعاد بزرگ تعمیم می‌یابد. گرگ‌های خاکستری در بالای هرم زنجیره غذایی به عنوان شکارچیان در راس قرار می‌گیرند. گرگ‌های خاکستری در یک گروه (دسته) که به‌طور متوسط ۵-۱۲ عضو دارد زندگی می‌کنند. همه‌ی عضوهای این گروه‌ها دارای سلسله مراتب اجتماعی بسیار دقیق بوده و وظایف خاصی بر عهده آنها می‌باشد. در هر گله برای شکار کردن ۴ درجه گرگ وجود داشته که به صورت زیر بیان می‌شود (استا، ۱۹۷۹: ۲۱).

- گرگ‌های رهبر می‌توانند مذکر یا مونث باشند و تسلط به گله دارند و به گروه alpha معروف هستند.
- گرگ‌هایی که به گروه alpha در تصمیم‌گیری کمک نموده و همچنین می‌توانند بجای آنها انتخاب شوند به گروه beta مشهور هستند.

- گرگ‌هایی پایین‌تر از گروه beta و شامل گرگ‌های پیر، شکارچی‌ها و گرگ‌های مراقبت‌کننده از نوزادان هستند به omega معروفند.
- گرگ‌هایی که پایین‌ترین مرتبه و کمترین حق را نسبت به بقیه‌ی اعضا دارند به omega معروف هستند. در شکل ۳ فلوچارت الگوریتم گرگ خاکستری نشان داده شده است.



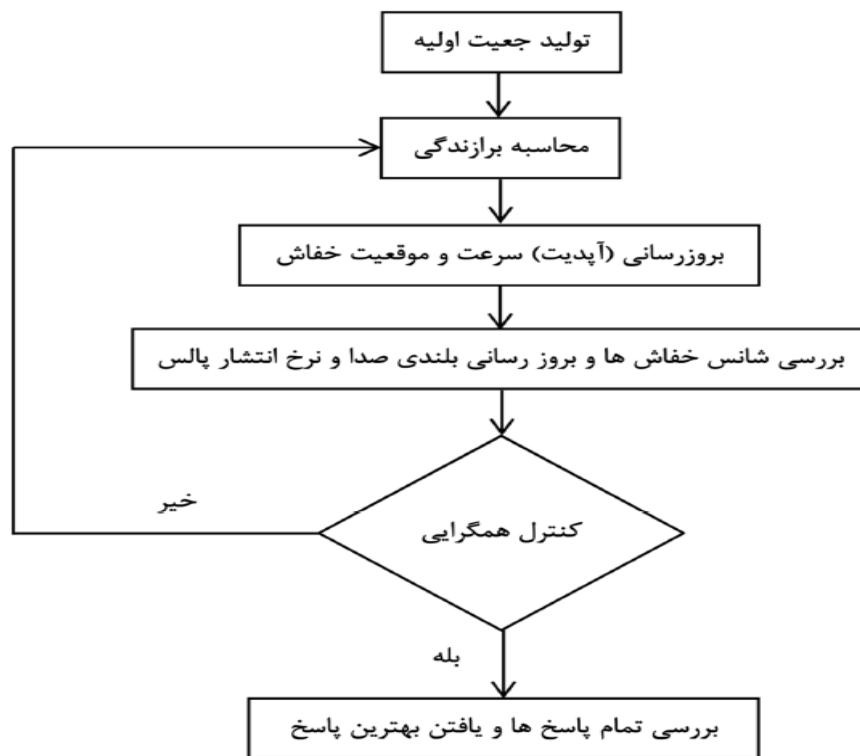
شکل (۳): فلوچارت الگوریتم گرگ خاکستری

Figure (3): Gray wolf algorithm flowchart

۲-۶- الگوریتم خفاش

هوش جمعی که بر مبنای رفتارهای گروهی استوار بوده یکی از قوی‌ترین تکنیک‌های بهینه‌سازی است (آمودا و همکاران^۱، ۲۰۱۳: ۳۳). الگوریتم خفاش از دسته الگوریتم‌های فراابتکاری بوده که از رفتار جمعی خفاش‌ها در محیط طبیعی الهام می‌گیرد. الگوریتم خفاش خاصیت انعکاس صدا توسط خفاش‌ها نشأت گرفته و منجر به

جواب بهینه می‌گردد به گونه‌ای که خفاش‌ها محل دقیق غذا به وسیله‌ی فرستادن امواج صوتی و دریافت بازتاب آن، جستجو می‌نمایند. هنگامی که امواج صوتی به سمت خفاش بازگشته با وجود تاریکی مطلق یک تصویر صوتی از موانع روبروی محیط اطراف خود ترسیم می‌نماید (آمودا و همکاران، ۲۰۱۳: ۳۳). در شکل ۴ فلوجارت الگوریتم خفاش نشان داده شده است.



شکل (۴): فلوجارت الگوریتم بهینه‌سازی خفاش

Figure (4): Flowchart of the Bat Optimization Algorithm

۷-۲- ارزیابی و عملکرد مدل‌ها

در این پژوهش به منظور تجزیه و تحلیل مدل‌ها، از شاخص‌های ضریب تبیین (R^2)، ریشه‌ی میانگین مربعات خطا- (RMSE)، میانگین قدر مطلق خطا (MAE)، ضریب نش ساتکلیف (NS) و درصد بایاس (PBIAS) مطابق معادلات ۱۶-۱۲ محاسبه شد. بهترین مقدار برای این پنج شاخص به ترتیب یک، صفر، صفر، یک و صفر است.

$$R^2 = \left[\frac{\sum_{i=1}^n (M_{oi} - \bar{M}_0)(M_{ei} - \bar{M}_e)}{\sqrt{\sum_{i=1}^n (M_{oi} - \bar{M}_0)^2 \cdot \sum_{i=1}^n (M_{ei} - \bar{M}_e)^2}} \right]^2, 0 \leq R^2 \leq 1 \quad (13)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (M_{ei} - M_{oi})^2}, 0 \leq RMSE \leq +\infty \quad (14)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |M_{ei} - M_{oi}|, 0 \leq MAE \leq +\infty \quad (15)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (M_{ei} - M_{oi})^2}{(\sum_{i=1}^n (M_{ei} - \bar{M}_e))^2}, -\infty < NSE < 1 \quad (16)$$

$$PBIAS = \frac{\sum_{i=1}^n (M_{oi} - M_{ei})}{\sum_{i=1}^n M_{ei}} \times 100, -100 \leq PBIAS \leq 100 \quad (17)$$

در این معادلات، M_{ei} و M_{oi} به ترتیب ارزش‌های مشاهده‌شده و محاسبه‌شده در زمان i ام، N تعداد مقادیر، \bar{M}_e و \bar{M}_0 نیز به ترتیب میانگین ارزش‌های مشاهده‌شده و محاسبه‌شده است.

۳- نتایج و بحث

به‌منظور آموزش ماهیت سازوکار حاکم بر پدیده نه‌تنها سبب پیچیدگی الگو افزایش حافظه درگیر خواهد شد، بلکه سبب کاهش دقت مدل نیز می‌شود. لذا در الگوسازی سطح آب‌های زیرزمینی نیز بایستی سعی نمود مؤثرترین داده‌های مشاهده‌شده را به‌عنوان داده‌های آموزشی انتخاب کرد (چن و همکاران، ۲۰۰۷: ۳۶). این امر به صورت ترکیب‌های مختلف مطابق جدول ۲ استفاده‌شده است که از این پس از آن‌ها به‌عنوان الگو نام‌برده خواهد شد.

جدول (۲): ترکیب‌های منتخب پارامترهای ورودی به مدل‌های هیبریدی مورد بررسی

Table (2): Selected combinations of input parameters to the hybrid models examined

پارامتر خروجی	پارامتر ورودی	ردیف
H(t)	P(t)	۱
H(t)	P(t), T(t)	۲
H(t)	P(t), T(t), H(t-1)	۳
H(t)	P(t), T(t), H(t-1), H(t-2)	۴

در این پژوهش به منظور برآورد نوسانات سطح آب زیرزمینی دشت سلسله لرستان مدل‌ها و الگوریتم‌های بهینه‌سازی فراکاشی با یک مجموعه داده مشاهداتی مورد ارزیابی قرار گرفتند و بیشترین کارایی برای مدل‌سازی و تحلیل بیشتر انتخاب شد. این مرحله دارای چهار الگو که به عنوان بهترین الگوهای ترکیبات ورودی انتخاب شدند که در جدول ۲ بیان گردید. همچنین برای هر مدل هیبریدی شامل رگرسیون بردار پشتیبان-موجک، رگرسیون بردار پشتیبان-گرگ خاکستری و رگرسیون بردار پشتیبان - خفاش از هر چهار ترکیب در مراحل آموزش و تست استفاده می‌شود (خسروی و همکاران، ۲۰۱۶: ۶۸). نتایج حاصل از بررسی الگوها نشان داد مدل‌های هیبریدی مورد بررسی در ساختار متشکل از کلیه داده‌های ورودی (ساختار شماره ۴) از عملکرد بهتری به دلیل افزایش حافظه مدل برخوردار است که این نتایج با پژوهش دهقانی و همکاران (۲۰۲۰: ۱۴۲)، جلالی و همکاران (۱۳۹۸: ۳۶) و دانشور و ثوقی و منافیان آذر (۱۳۹۷: ۴۷) همخوانی دارد که در جداول ۳ و ۴ نتایج ساختار ترکیبی شماره ۴ قابل مشاهده است. نتایج حاصل از عملکرد مدل‌ها با استفاده از شاخص ارزیابی نشان داد مدل ترکیبی رگرسیون بردار پشتیبان-موجک از خطای کمتری نسبت به سایر مدل‌های هیبریدی مورد بررسی برخوردار است که این امر برای هر دو چاه مشاهداتی مشهود است به گونه‌ای که طبق شاخص‌های ارزیابی مدل‌ها این مدل در چاه مومن‌آباد دارای مقادیر $R=0/988$ ، $RMSE=0/112$ ، $MAE=0/076$ ، $NS=0/978$ و $BIAS=0/001$ و همچنین چاه فیض‌آباد دارای مقادیر $R=0/975$ ، $RMSE=0/146$ ، $MAE=0/093$ و $BIAS=0/001$ و $NS=0/963$ می‌باشد همچنین مقدار درصد بایاس برای چاه‌های مورد مطالعه مقداری مثبت داشته است و این به معنای ناچیز بودن خطای مدل می‌باشد. که این نتایج با پژوهش بهمنی و همکاران (۲۰۲۱: ۲۲۴) همخوانی دارد در تبیین این نتایج می‌توان بیان نمود تبدیل موجکی با جدا نمودن سیگنال به فرکانس‌های بالا و پائین ویژگی‌های چند مقیاسی سیگنال را در اختیار داشته و دقت مدل را تا حد قابل توجهی بالا می‌برد. سیگنال‌های بالا گذر و پائین گذر حاصل از تجزیه موجک، برازش بسیار خوبی با معادلات مجموع سینوسی دارند که هر چه تعداد مراتب این معادلات بیشتر می‌شود، دقت کار افزایش می‌یابد بسامدهای مراحل پایین‌تر تجزیه، نویز بیشتری دارند، ولی با افزایش سطح تجزیه از میزان نویز کاسته شده و سیگنال نرم‌تر می‌شود.

جدول (۳): تحلیل نتایج مدل‌های هیبریدی مورد بررسی در چاه مشاهداتی مومن‌آباد

Table (3): Analysis of the results of the studied hybrid models in Momenabad observation well

صحت‌سنجی					آموزش					مدل
PBIAS	NS	MAE(m)	RMSE(m)	R ²	PBIAS	NS	MAE(m)	RMSE(m)	R ²	
0/001	0/978	0/076	0/112	0/988	0/002	0/942	0/128	0/265	0/962	WSVR
0/002	0/954	0/108	0/231	0/971	0/003	0/931	0/236	0/342	0/948	GWO-SVR
0/002	0/938	0/146	0/326	0/964	0/003	0/917	0/322	0/412	0/933	BA-SVR

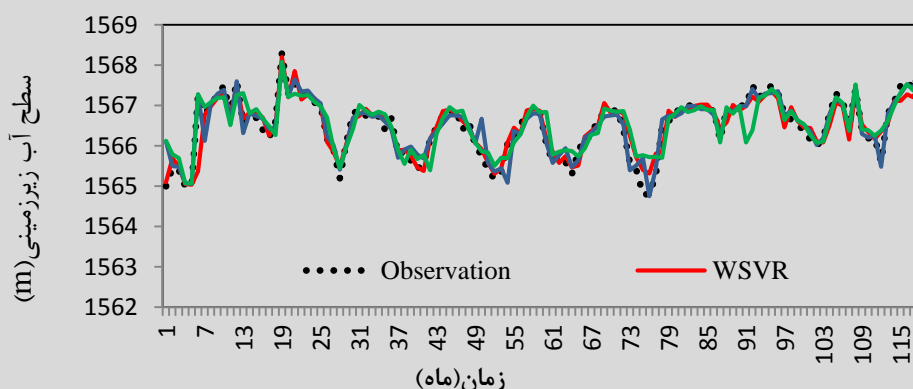
جدول (۴): تحلیل نتایج مدل‌های هیبریدی مورد بررسی در چاه مشاهداتی فیض‌آباد

Table (4): Analysis of the results of hybrid models studied in Feyzabad observation well

صحت سنجی					آموزش					مدل
PBIAS	NS	MAE(m)	RMSE(m)	R ²	PBIAS	NS	MAE(m)	RMSE(m)	R ²	
۰/۰۰۱	۰/۹۶۳	۰/۰۹۳	۰/۱۴۶	۰/۹۷۵	۰/۰۰۲	۰/۹۳۶	۰/۱۳۶	۰/۲۸۸	۰/۹۵۱	WSVR
۰/۰۰۲	۰/۹۴۸	۰/۱۲۸	۰/۲۶۱	۰/۹۶۴	۰/۰۰۳	۰/۹۲۴	۰/۲۵۲	۰/۳۷۵	۰/۹۳۷	GWO-SVR
۰/۰۰۲	۰/۹۳۳	۰/۱۸۷	۰/۳۴۱	۰/۹۵۳	۰/۰۰۳	۰/۹۰۸	۰/۳۴۱	۰/۴۴۵	۰/۹۲۲	BA-SVR

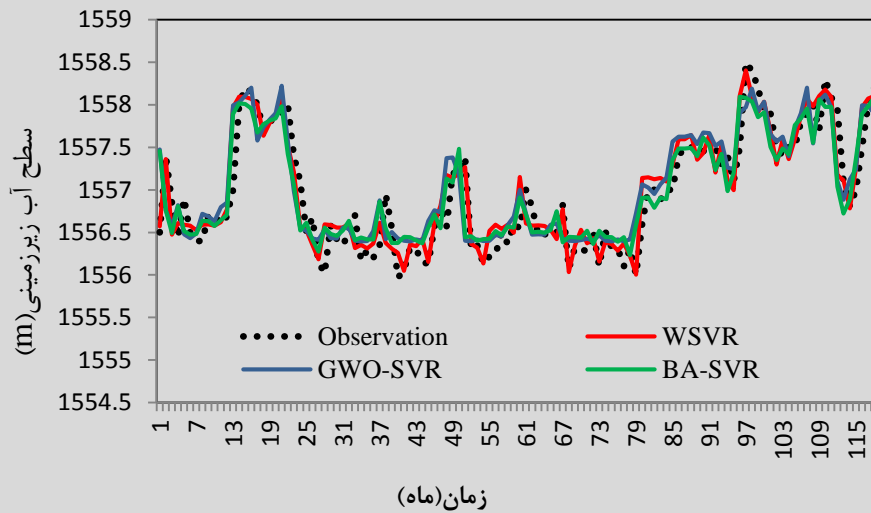
در شکل ۵ و ۶ نمودار تغییرات سری زمانی مقادیر مشاهداتی و محاسباتی بیان نشان داده شده است در این شکل مدل رگرسیون بردار پشتیبان-موجک در برآورد نقاط ماکزیمم و مینیمم خطای کمتری دارد و همچنین مدل‌های رگرسیون بردار پشتیبان-گرگ خاکستری و رگرسیون بردار پشتیبان-خفاش در برآورد مقادیر میانی و مینیمم از دقت مطلوبی برخوردار است بگونه‌ای که هر سه مدل هیبریدی مقادیر محاسباتی را نزدیک به مقادیر مشاهداتی برآورد نموده، که در این بین مدل WSVR عملکرد مناسب‌تری نسبت به سایر مدل‌ها دارد.

همچنین در شکل ۷ نمودار خطای مدل‌های هیبریدی مورد بررسی نسبت به مدل منفرد نشان می‌دهد که مدل‌های رگرسیون بردار پشتیبان-موجک، رگرسیون بردار پشتیبان-گرگ خاکستری و رگرسیون بردار پشتیبان-خفاش میزان خطای محاسباتی مدل منفرد را به ترتیب به میزان (۲۰/۲۶-۱۲/۷۸)٪، (۱۷/۶۱-۱۰/۱۳)٪ و (۱۶/۷۵-۹/۲۷)٪ کاهش داده و این امر سبب افزایش عملکرد مدل‌های هیبریدی می‌گردد.

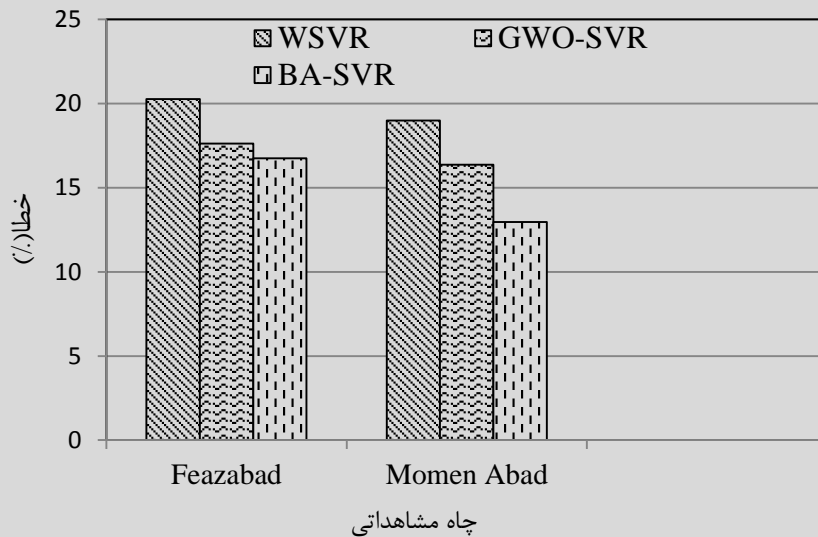


شکل (۵): نمودار مقادیر مشاهداتی و محاسباتی مدل‌های هیبریدی مورد بررسی در چاه مشاهداتی مومن‌آباد

Figure (5): Diagram of observational and computational values of hybrid models studied in Momenabad observation well



شکل (۶): نمودار مقادیر مشاهداتی و محاسباتی مدل‌های هیبریدی مورد بررسی در چاه مشاهداتی فیض آباد
Figure (6): Diagram of observational and computational values of hybrid models studied in Fezabad observation well



شکل (۷): نمودار خطای مدل‌های هیبریدی مورد بررسی در چاه‌های مشاهداتی
Figure (7): Error diagram of hybrid models studied in observation wells

به‌طور کلی می‌توان اذعان نمود که مدل‌های توسعه‌یافته برای تمامی چاه‌های مشاهداتی مورد مطالعه به نتایج پیش‌بینی مطلوب رسیده‌اند، اما مقایسه‌ی عملکرد مدل‌ها برای دو چاه مشاهداتی مورد بررسی نشان می‌دهد که عملکرد مدل‌ها برای چاه مشاهداتی مومن‌آباد بهتر از سایر چاه‌های مورد بررسی بوده است. نتایج حاصل از بررسی پارامترهای موثر نشان داد که هر چه تعداد پارامترهای مؤثر (متغیرهای وابسته) بیشتر باشد عملکرد شبکه بهتر خواهد بود. همچنین هرچه میزان ورودی به شبکه بیشتر باشد کارایی و دقت مدل افزایش خواهد یافت. همچنین نتایج حاصل از معیارهای ارزیابی مدل‌ها نشان داد که هر سه مدل مورد بررسی، می‌توانند با دقت نسبتاً بالایی سطح آب زیرزمینی را شبیه‌سازی نمایند. در این میان، مدل رگرسیون بردار پشتیبان-موجک دقت بیشتر و خطای کمتری نسبت به مدل‌های رگرسیون بردار پشتیبان-گرگ خاکستری و رگرسیون بردار پشتیبان-خفاش از خود نشان داده است. در مجموع پیشنهاد می‌گردد جهت کاهش افت سطح آب زیرزمینی از حفر چاه‌های غیرمجاز و برداشت‌های بی‌رویه جلوگیری شود و نیز جهت کنترل برداشت‌ها، نصب کنتور هوشمند در اولویت قرار گیرد که بتوان از افت منابع آب زیرزمینی جلوگیری نمود.

۴-منابع

- Adamowski, J., Chan, H. (2011). A wavelet neural network conjunction model for groundwater level forecasting. *Journal of Hydrology*, 407(1-4), 28-40.
<https://doi.org/10.1016/j.jhydrol.2011.06.013>.
- Amuda, A., Brest, J., Mezura-Montes, E. (2013). Structured Population Size Reduction Differential Evolution with Multiple Mutation Strategies on CEC 2013 real parameter optimization. *In Proceedings of the IEEE Congress on Evolutionary Computation*, Cancun, Mexico, 1925-1931.
- Ashmaul Husna, N.E., Hefzul bari, S., Shouroy, H., Rahman, T. (2016). Ground water level prediction using artificial neural network, *International Journal of Hydrology Science and Technology*, 6(4):371-381. <https://doi.org/10.1016/j.jhydrol.2004.12.001>.
- Bahmani, R., Taha, B.M., Ouarda, J. (2021) Groundwater level modeling with hybrid artificial intelligence techniques. *Journal of hydrology*, 595:460-475.
- Basak, D., Pal, S., and Patranabis, D.C. (2007). Support vector regression. *Neural Inf Process*, 11(2), 203-225.
- Chen, S.T., and Yu, P.S. (2007). Real-time probabilistic forecasting of flood stages, *Journal of Hydrology*, 340(2), 63-77.
- Daneshvar Vosoghi, F., Monafian Azar, V. (2017). Using Hybrid Wavelet-Support Vector Machine and Wavelet-Neural Network Models for Groundwater Level Prediction in Ardabil Plain, *Journal of Hydrogeomorphology*, 5, 45-64.
- Dehghani, R., Torabi, H. (2021). Application of novel hybrid artificial intelligence algorithms to groundwater simulation. *International Journal of Environmental Science and Technology*, 18(12),4075-4090
- Ebtehaj, I., Bonakdari, H. (2014). Performance Evaluation of Adaptive Neural Fuzzy Inference System for Sediment Transport in Sewers. *Water Resources Management*, 28:4765-4779.
<https://doi.org/10.1007/s11269-014-0774-0>.
- Hamel, L. (2009). *Knowledge discovery with support vector Machines*, hoboken, N.J. John Wiley.
- Jalali, M., Kamangar, M., Razmi, R. (2018). Prediction of the Water Table Surface Model using the Hyperbolic Tangent Function of the Neural, Network Case Study: Sarkhoon Plain, *Journal of Hydrogeomorphology*, 6, 101-119.
- Khosravi, K., Pham, B.T., Chapi, K., Shirzadi, A., Shahabi, H., Revhaug, I., Prakash, I., Tien Bui, D. (2018). A comparative assessment of decision trees algorithms for flash flood susceptibility modeling at Haraz watershed, northern Iran. *Science of the Total Environment*, 627:744-755. <https://doi.org/10.1016/j.scitotenv.2018.01.266>.

- Kisi, O., Dailr, A.H., Cimen, M., Shiri, J. (2012). Suspended sediment modeling using genetic programming and soft computing techniques. *Journal of Hydrology*, 450:48–58. <https://doi.org/10.1016/j.jhydrol.2012.05.031>.
- Li, H., Lu, Y., Zheng, C., Yang, M., Li, S. (2019). Groundwater Level Prediction for the Arid Oasis of Northwest China Based on the Artificial Bee Colony Algorithm and a Back-propagation Neural Network with Double Hidden Layers. *Water Resources Management and Governance*, 11(4):2-20. <https://doi.org/10.3390/w11040860>.
- Melesse, A.M., Ahmad, S., McClain, M.E., Wang, X., Lim, Y.H. (2011). Suspended sediment load prediction of river systems: An artificial neural network approach. *Agric. Water Manag.*, 98:855-866. <https://doi.org/10.1016/j.agwat.2010.12.012>.
- Milan, S.G., Roozbahani, A., Arya Azar, N., Javadi, S. (2021) Development of adaptive neuro fuzzy inference system –Evolutionary algorithms hybrid models (ANFIS-EA) for prediction of optimal groundwater exploitation, *Journal of hydrology*, 598:574-592.
- Ostu, N. (1979). A Threshold Selection Method from Gray-Level Histograms [J]. *IEEE Transactions on Systems Man and Cybernetics*, 9 (1): 62-66.
- Rajaei, T., Mirbagheri, S.A., Zounemat-Kermani, M., Nourani, V. (2009). Daily suspended sediment concentration simulation using ANN and neuro-fuzzy models. *Sci. Total Environ*, 407:4916–4927. <https://doi.org/10.1016/j.scitotenv.2009.05.016>.
- Senthil Kumar, A.R., Sudheer, K.P., Jain, S.K., Agarwal, P.K. (2004). Rainfall–runoff modeling using artificial neural network: comparison of networks types. *Hydrol. Process*, 19 (6):1277–1291. <https://doi.org/10.1002/hyp.5581>.
- Sreekanth, P.D., Geethanjali, N., Sreedevi, P.D., Shakeel, A., Ravi Kumar, N., Kamala Jayanthi, PD. (2009). Forecasting groundwater level using artificial neural networks, *Current Science*, 96(7), 99-112. <https://www.jstor.org/stable/24104683>
- Steyl, G. (2009). Application of Artificial Neural Networks in the Field of Geohydrology. *University of the Free State, South Africa*.
- Thendiyath, R., Madan, K., Deo, R., Vandana, A. (2019). Development and Evaluation of Hybrid Artificial Neural Network Architectures for Modeling Spatio-Temporal Groundwater Fluctuations in a Complex Aquifer System. *Water Resources Management*, 33(7):2381-2397. <https://doi.org/10.1007/s11269-019-02253-4>.
- Vapnik, V., and Chervonenkis, A. (1991). The necessary and sufficient conditions for consistency in the empirical risk minimization method, *Pattern Recognition and Image Analysis*, 1(3), 283-305.
- Vapnik, V.N. (1995). *The Nature of Statistical Learning Theory*. Springer, New York.
- Vapnik, V.N. (1998). *Statistical learning theory*. Wiley, New York.

- Wang, D., Safavi, A.A., and Romagnoli, J.A. (2000). Wavelet-based adaptive robust M-estimator for non-linear system identification, *AIChE Journal*, 46(4), 1607-1615.
- Yoon, H., Jun, S.C., Hyun, Y., Bae, G.O., Lee, K.K. (2011) A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. *Journal of Hydrol* , 396(4):128–138
- Zare, M., Koch, M. (2018). Groundwater level fluctuations simulation and prediction by ANFIS- and hybrid Wavelet-ANFIS/Fuzzy C-Means (FCM) clustering models: Application to the Miandarband plain. *Journal of Hydro-environment Research*, 18:63-76. <https://doi.org/10.1016/j.jher.2017.11.004>
- Ziya Kaya, Y., Unes, F., Demirci, M., Tasar, B. (2018). Groundwater Level Prediction Using Artificial Neural Network and M5 Tree Models. *Air and Water Components of the Environment Conference*. DOI: 10.24193/AWC2018_23.