



دانشگاه گوارز و منابع آب

نشریه پژوهش‌های حفاظت آب و خاک
جلد بیست و یکم، شماره اول، ۱۳۹۳
<http://jwsc.gau.ac.ir>

مقایسه عملکرد سه روش هوشمند به منظور پیش‌بینی نوسانات سطح ایستابی (مطالعه موردی: دشت زرین گل)

*فرزانه ابارشی^۱، مهدی مفتاح‌هلقی^۲، هادی ثانی‌خانی^۳ و امیراحمد دهقانی^۲

^۱ دانشجوی کارشناسی ارشد گروه مهندسی منابع آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، ^۲ دانشیار گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، ^۳ دانشجوی دکتری گروه مهندسی منابع آب و عضو باشگاه پژوهشگران جوان و نخبگان، دانشگاه آزاد اسلامی، واحد ساوه، ایران
تاریخ دریافت: ۹۱/۱۰/۶؛ تاریخ پذیرش: ۹۲/۳/۱۵

چکیده

آب زیرزمینی مهم‌ترین منابع تأمین آب در جهان برای مصارف خانگی و شرب می‌باشد. در این خصوص، سیاست تأمین آب مناسب به‌خصوص در طول فصول خشک مستلزم پیش‌بینی نوسانات تراز آب با دقت قابل قبول می‌باشد. در این پژوهش به مقایسه عملکرد سه روش هوش مصنوعی برای پیش‌بینی نوسانات تراز سطح ایستابی پرداخته شده است. این مدل‌ها شامل شبکه‌های عصبی مصنوعی، سامانه استنتاج تطبیقی فازی-عصبی و برنامه‌ریزی بیان ژن می‌باشند که برای پیش‌بینی سری زمانی تراز سطح آب در حوضه زرین گل در استان گلستان به کار گرفته شدند. داده‌های تراز سطح آب در مقیاس ماهانه در دوره آماری ۸۹-۱۳۵۹ برای آموزش و آزمون مدل‌ها استفاده شدند. پارامترهای آماری شامل ریشه میانگین مربعات خطا (RMSE) و ضریب تعیین (R^2) به منظور بررسی عملکرد مدل‌ها به کار گرفته شدند. نتایج به دست آمده بیانگر آن بودند که هر سه روش شبکه‌های عصبی، فازی-عصبی و برنامه‌ریزی بیان ژن می‌توانند به‌طور موفقیت‌آمیزی برای پیش‌بینی نوسانات سطح ایستابی مورد استفاده قرار گیرند. در بهترین حالت اجرای مدل، بالاترین مقدار ضریب تعیین، برای چاه‌های سلاخ غیب ($R^2=0/83$)، کوچک خرطوم ($R^2=0/80$) و ایمرتره ملا ($R^2=0/84$) محاسبه شد، که مقادیر بالا مربوط به روش برنامه‌ریزی بیان ژن می‌باشد. از طرفی عملکرد مدل برنامه‌ریزی بیان ژن در مقایسه با دو روش دیگر از جنبه‌های مختلف بهتر بود. در روش برنامه‌ریزی بیان ژن می‌توان رابطه ریاضی حاکم بر مسأله مورد بررسی را به صورت دقیق مشخص نمود.

واژه‌های کلیدی: شبکه عصبی مصنوعی، فازی-عصبی تطبیقی، برنامه‌ریزی بیان ژن، تراز سطح ایستابی

*مسئول مکاتبه: farzaneh.abareshi@gmail.com

مقدمه

آب‌های زیرزمینی همواره به‌عنوان یک منبع مهم تأمین آب شیرین جایگاه ویژه‌ای در مطالعات منابع آب دارد. مطالعات آب‌های زیرزمینی با اهدافی چون بررسی وضعیت فعلی منابع آب زیرزمینی، تعیین پتانسیل موجود آب زیرزمینی، پیش‌بینی و تغییرات تراز آب زیرزمینی در دوره‌های آتی و امکان برنامه‌ریزی و مدیریت منابع آب برای بهبود شرایط آبخوان در آینده انجام می‌گیرد (انصاری و همکاران، ۲۰۱۱). در سال‌های اخیر برداشت بی‌رویه از منابع آب زیرزمینی از یک‌سو و فعالیت برای تأمین غذا از سوی دیگر، لطمات جبران‌ناپذیری را به این منابع از نقطه‌نظر کمی و کیفی وارد کرده است. به‌منظور ارزیابی اثرات ناشی از توسعه در شرایط موجود و ارایه روش‌های مدیریتی بر منابع آب‌های زیرزمینی، چه از نقطه‌نظر کمی و یا کیفی، شبیه‌سازی ریاضی و کامپیوتری، ابزاری قوی در بهره‌برداری بهینه از این منابع محسوب می‌گردد. اخیراً مدل‌های ریاضی و کامپیوتری بسیاری به‌منظور شبیه‌سازی رفتار هیدرولیکی منابع آب زیرزمینی مورد توجه قرار گرفته است.

با توجه به اهمیت پیش‌بینی تراز آب زیرزمینی از نقطه‌نظرهای مختلف، یافتن روشی مناسب در این خصوص دارای اهمیت می‌باشد. در سال‌های اخیر کاربرد سامانه‌های هوشمند برای پیش‌بینی تراز آب زیرزمینی به سرعت رو به افزایش است که دلیل این امر به آسانی کاربرد و دقت بالای این مدل‌ها در تقریب معادله‌های غیرخطی و پیچیده ریاضی برمی‌گردد (پارولو و توماسل، ۱۹۹۷). یکی از این سامانه‌های هوشمند شبکه عصبی مصنوعی است که برگرفته از مغز می‌باشد. کولیالی و همکاران (۲۰۰۱) از شبکه عصبی مصنوعی برای مدل کردن نوسانات ماهانه تراز آب زیرزمینی استفاده کردند و نتایج آن را رضایت‌بخش دانستند. یانگ و همکاران (۲۰۰۹) نیز برای پیش‌بینی تراز آب زیرزمینی در غرب چین از شبکه عصبی مصنوعی استفاده کردند و عملکرد این مدل را مناسب دانستند. در ایران نیز مطالعاتی بر روی آب زیرزمینی با استفاده از سیستم‌های هوشمند عصبی صورت گرفته است. ایزدی و همکاران (۲۰۰۷) نشان دادند که شبکه عصبی مصنوعی در پیش‌بینی تراز آب زیرزمینی طی ۶ ماه آینده نتایج به‌نسبت خوبی را ارایه می‌نماید. محتشم و همکاران (۲۰۱۰) نیز به‌منظور پیش‌بینی سطح ایستابی دشت بیرجند از شبکه عصبی مصنوعی استفاده کردند و نتایج نشان داد که با استفاده از شبکه عصبی می‌توان تراز آب زیرزمینی را تا ۱۲ ماه بعد و با دقت بالاتر نسبت به روش‌های دیگر تخمین زد.

سامانه استنتاج فازی عصبی- تطبیقی نیز از جمله روش‌هایی است که در تحلیل پدیده‌های غیرخطی و بررسی رابطه بین ورودی و خروجی به‌کار برده می‌شود. کیشی (۲۰۰۵) به تخمین میزان

رسوبات معلق با استفاده از روش‌های فازی-عصبی و شبکه‌های عصبی پرداخت. کیشی و اوزترک (۲۰۰۷) با استفاده از این روش به پیش‌بینی اندازه نیاز آبی گیاه مرجع پرداختند. ثانی‌خانی و کیشی (۲۰۱۲) از دو روش مختلف فازی-عصبی شامل افراز شبکه و دسته‌بندی تفریقی برای پیش‌بینی میزان جریان رودخانه استفاده نمودند. نتایج به‌دست آمده بیانگر دقت قابل‌قبول هر دو روش در پیش‌بینی میزان جریان بود.

برنامه‌ریزی ژنتیک و برنامه‌ریزی بیان ژن^۱ از جدیدترین الگوریتم‌های فراکاوشی هستند که به دلیل دارا بودن دقت کافی، مورد توجه پژوهش‌گران قرار گرفته‌اند. از برتری‌های عمده این مدل‌ها این است که می‌تواند برای شرایطی که، ۱- ارتباط موجود بین متغیرهای مسأله به خوبی شناخته شده نباشد، یا صحت و سقم شناخت فعلی از رابطه نام برده با تردید همراه باشد، ۲- پیدا کردن حل نهایی مسأله مورد بررسی مشکل باشد، ۳- حل ریاضی مرسوم وجود نداشته باشد (یا حل تحلیلی را ایجاب می‌کند)، ۴- راه‌حل تقریبی قابل‌قبول باشد و ۵- تعداد داده‌هایی که باید به‌وسیله کامپیوتر مورد آزمون، دسته‌بندی و جمع‌بندی قرار گیرند زیاد باشد (مانند داده‌های ماهواره‌ای) به‌کار برده شوند (بنزاف و همکاران، ۱۹۹۸). برنامه‌ریزی بیان ژن نیز همانند الگوریتم‌های ژنتیک و برنامه‌ریزی ژنتیک، یک الگوریتم ژنتیکی است به‌طوری‌که از جمعیتی از افراد استفاده می‌کند که آن‌ها را مطابق برازندگی انتخاب می‌کند و تغییرات ژنتیکی را با استفاده از یک یا چند عمل‌گر ژنتیکی اعمال می‌نماید. تفاوت اساسی بین این سه الگوریتم، مربوط به ماهیت افراد آن‌ها می‌باشد به‌طوری‌که در الگوریتم ژنتیک، افراد رشته‌های خطی با طول ثابت (کروموزوم‌ها) و در برنامه‌ریزی ژنتیک، نهادهای غیرخطی با اندازه‌ها و اشکال متفاوت (درختان تجزیه) می‌باشند، در حالی‌که در برنامه‌ریزی بیان ژن، افراد به‌صورت رشته‌های خطی با طول ثابت (ژنوم یا کروموزوم‌ها) کدگذاری شده و سپس به شکل نهادهای غیرخطی با اندازه‌ها و اشکال متفاوت (یعنی نمایش دیاگرام ساده یا بیان درختی) بیان می‌شوند (فریرا، ۲۰۰۱).

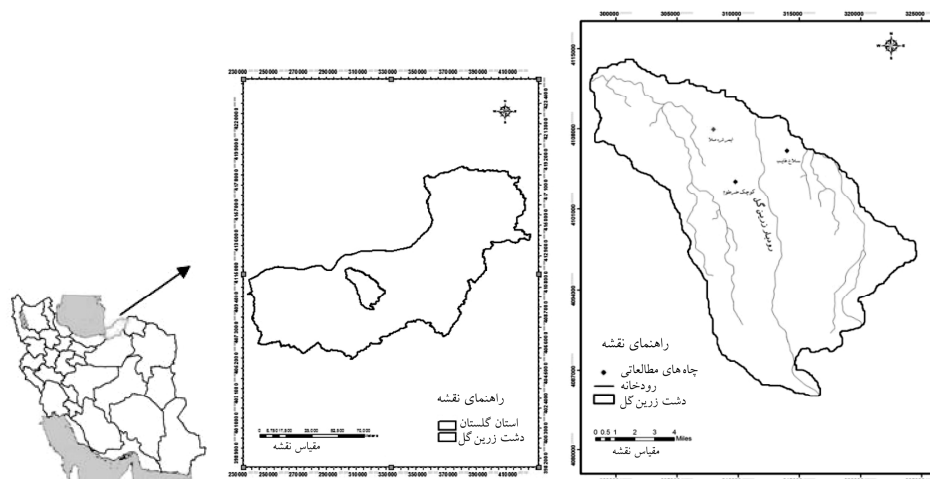
آیتک و آلپ (۲۰۰۸) برای مدل‌سازی فرآیند بارش-رواناب از برنامه‌ریزی ژنتیک استفاده کردند. آیتک و کیشی (۲۰۰۸) با مطالعه در مورد پدیده حمل رسوب در آبراه‌ها روش برنامه‌ریزی ژنتیک را به‌عنوان یک رهیافت مناسب برای شبیه‌سازی بار معلق معرفی کردند. شیری و کیشی (۲۰۱۱) به‌منظور بررسی نوسانات کوتاه‌مدت سطح آب زیرزمینی دو چاه در ترکیه، از روش‌های برنامه‌ریزی بیان ژن و فازی-عصبی استفاده کردند. نتایج به‌دست آمده از پژوهش ایشان بیانگر مناسب بودن دو روش بالا در

1- Gene Expression Programming

بررسی نوسانات سطح ایستابی بود. ترا اوره و گاون (۲۰۱۲) از مدل برنامه‌ریزی بیان ژن برای تخمین تبخیر و تعرق در منطقه‌ای در آفریقا پرداختند و دقت این مدل را قابل قبول گزارش نمودند. با بررسی منابع انجام شده، مشخص گردید که دامنه مطالعات در خصوص به‌کارگیری روش برنامه‌ریزی بیان ژن برای تخمین سطح ایستابی کم و محدود می‌باشد. بنابراین این پژوهش با هدف بررسی عملکرد برنامه‌ریزی بیان ژن در تخمین تراز سطح آب در حوضه آبریز دشت زرین گل استان گلستان انجام گردید و نتایج به‌دست آمده با عملکرد سیستم استنتاج فازی-عصبی تطبیقی و شبکه‌های عصبی مصنوعی مورد مقایسه قرار گرفت.

مواد و روش‌ها

مشخصات منطقه مورد مطالعه: دشت زرین گل با مساحت ۳۷۰ کیلومترمربع و متوسط بارندگی ۷۰۹ میلی‌متر در جنوب شهر علی‌آباد کتول در استان گلستان واقع شده است. در سال‌های اخیر، تراز آب زیرزمینی این منطقه افت محسوسی داشته است. شکل ۱ موقعیت جغرافیایی منطقه مورد مطالعه و موقعیت چاه‌ها را نشان می‌دهد. در این پژوهش از اطلاعات سه چاه ایمرتره‌ملا، کوچک خرطوم و سلاخ غایب استفاده شده است.



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه.

داده‌های سطح ایستابی مورد استفاده در این پژوهش برای یک دوره ۳۰ ساله از مهر ۱۳۵۹ تا شهریور ۱۳۸۹ با مقیاس ماهانه می‌باشند. از داده‌های ۲۳ سال اول هر چاه به منظور آموزش و از بقیه داده‌ها برای آزمون مدل‌ها استفاده شد. پارامترهای آماری ماهانه داده‌های سطح ایستابی چاه‌ها در جدول ۱ نمایش داده شده است. با توجه به جدول ۱ محدوده داده‌های دوره آموزش برای چاه ایمرتره‌ملا بین ۳/۲۷-۰/۹۴ متر است، در حالی که حداکثر مقدار دوره آزمون بیش‌تر از مقدار بالا و حداقل مقدار آن از مقدار بالا کم‌تر است. به عبارت دیگر داده‌های دوره آزمون خارج از محدوده دوره آموزش می‌باشند. برای چاه کوچک خرطوم نیز حداقل داده‌های دوره آزمون مدل در دوره آموزش قرار نگرفته‌اند. این مسأله می‌تواند کارایی روش‌های مورد استفاده برای برون‌یابی داده‌های دوره آزمون را بهتر مورد ارزیابی قرار دهد (کیشی، ۲۰۰۷).

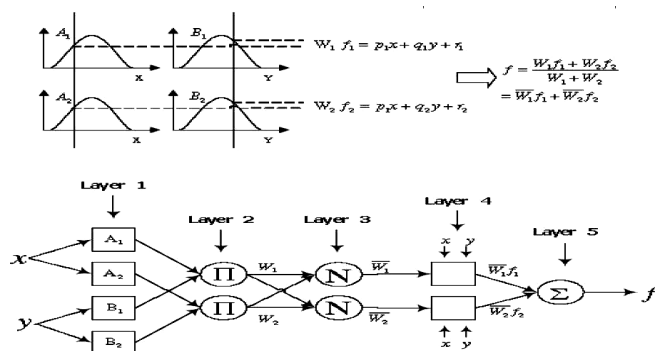
جدول ۱- مقادیر پارامترهای آماری داده‌های ماهانه سطح ایستابی.

پارامترهای آماری							
نوع داده	چاه	میانگین (متر)	حداکثر (متر)	حداقل (متر)	انحراف معیار (متر)	ضریب تغییرات	ضریب چولگی
آموزش	ایمرتره‌ملا	۲/۲۹	۳/۲۷	۰/۹۴	۰/۵۵	۰/۲۴	-۰/۳۸
	سلاخ‌غایب	۲/۸۹	۴/۳۵	۰/۷۵	۰/۷۳	۰/۲۵	-۰/۶۴
	کوچک‌خرطوم	۲/۴۹	۳/۸	۱/۰۵	۰/۵۴	۰/۲۲	۰/۱۲
آزمون	ایمرتره‌ملا	۲/۱۸	۳/۵۴	۰/۷۶	۰/۷۲	۰/۳۳	۰/۰۵
	سلاخ‌غایب	۲/۶۳	۳/۸	۱/۰۲	۰/۷۹	۰/۳۰	-۰/۴۲
	کوچک‌خرطوم	۱/۹۴	۲/۸۴	۰/۶۰	۰/۵۷	۰/۲۹	-۰/۶۲

شبکه عصبی مصنوعی^۱: شبکه‌های عصبی مصنوعی مدل‌های ریاضی و انعطاف‌پذیری هستند که می‌توانند در مدل‌سازی سیستم‌های پیچیده به کار برده شوند. هم‌چنین این شبکه‌ها قادرند با انتخاب مناسب تعداد لایه‌ها و نرون‌ها یک نگاشت غیرخطی بین ورودی‌ها و خروجی‌ها ارائه دهند. پردازش در شبکه عصبی مصنوعی براساس بسیاری از واحدهای پردازش که نرون نام دارند، انجام می‌شود. هر نرون در هر لایه به همه عناصر لایه قبل و بعد با یک‌سری وزن‌هایی متصل شده است. توانایی کلی

شبکه عصبی مصنوعی یادگیری ارتباط غیرخطی بین داده‌ها و تعمیم نتایج برای داده‌های دیگر است (کاریانیز و نفسانوپولوس، ۱۹۹۳). دو نوع از شبکه‌های عصبی مصنوعی پرکاربرد در علوم مهندسی آب شبکه پرسپترون چند لایه (MLP)^۱ و شبکه تابع پایه شعاعی (RBF)^۲ می‌باشد. در این پژوهش از شبکه عصبی از نوع پرسپترون چندلایه موجود در نرم‌افزار MATLABIO استفاده شده است.

سیستم استنتاج فازی-عصبی تطبیقی^۳: این سامانه اولین بار توسط ژانگ (۱۹۹۳) معرفی شد و ابزاری جهانی برای تخمین توابع پیوسته حقیقی در دامنه‌ای محدود می‌باشد که به‌ازای هر درجه‌ای از صحت قابل استفاده است. مدل فازی-عصبی قابلیت خوبی در آموزش، ساخت و طبقه‌بندی دارد و ساختار آن شامل ۵ لایه با تعدادی متغیر ورودی است که هر ورودی دو یا چند تابع عضویت دارد. در لایه اول (ورودی) میزان تعلق هر ورودی به بازه‌های مختلف فازی توسط کاربر مشخص می‌شود. با ضرب مقادیر ورودی به هر گره در یکدیگر، وزن قانون‌ها در لایه دوم به دست می‌آید. در لایه سوم عمل محاسبه وزن نسبی قوانین انجام می‌شود. لایه چهارم، لایه قوانین است که از انجام عملیات بر روی سیگنال‌های ورودی به این لایه به دست می‌آید. لایه آخر، لایه خروجی شبکه می‌باشد که هدف آن حداقل نمودن اختلاف‌های خروجی به دست آمده از شبکه و خروجی واقعی است (چانگ و چانگ، ۲۰۰۵). در شکل ۲ مدل فازی مرتبه اول نوع سوگنو به همراه قانون فازی و هم‌چنین مدل فازی-عصبی معادل آن نشان داده شده است.



شکل ۲- مدل فازی مرتبه اول سوگنو با دو قانون فازی و سیستم ANFIS معادل آن.

- 1- Multi Layer Perceptron
- 2- Radial Basis Function
- 3- Adaptive Neuron-Fuzzy Inference System

برنامه‌ریزی بیان ژن: برنامه‌ریزی بیان ژن توسط فریرا در سال ۱۹۹۹ ارایه شد (فریرا، ۲۰۰۱). در این برنامه، کروموزوم‌های خطی و ساده با طول ثابت، مشابه با آنچه که در الگوریتم ژنتیک استفاده می‌شود و ساختارهای شاخه‌ای با اندازه‌ها و شکل‌های متفاوت، مشابه با درختان تجزیه در برنامه‌ریزی ژنتیک، ترکیب می‌شوند. اولین مرحله در الگوریتم مدل، تولید جمعیت اولیه از راه‌حل‌ها است. این موضوع می‌تواند به وسیله فرآیند تصادفی و یا با استفاده از مقاداری اطلاعات درباره مسأله انجام شود. سپس کروموزوم‌ها به صورت بیان درختی بیان شده مطابق با یک تابع برازش ارزیابی می‌گردد تا میزان مناسب بودن یک راه‌حل در حیطه مسأله تعیین گردد. معمولاً تابع برازش به وسیله پردازش تعدادی نمونه از مسأله هدف، که موارد برازش نیز نامیده می‌شوند، ارزیابی می‌گردد. اگر کیفیت رضایت‌بخش از یک راه‌حل پیدا شود و یا نسل‌ها به تعداد معینی برسد، تکامل متوقف شده و بهترین راه‌حل یافت شده تا به حال، گزارش داده می‌شود. از طرف دیگر اگر شرایط توقف یافت نشود، بهترین راه‌حل از نسل حاضر نگه داشته می‌شود (به معنای نخبه‌گزینی است) و بقیه راه‌حل‌ها به فرآیندی گزینشی واگذار می‌شوند. گزینش یا انتخاب، نقش بقا شایستگی را انجام می‌دهد و براساس آن بهترین افراد شانس بهتری برای تولید فرزندان دارند. کل این روند برای چندین نسل تکرار می‌شود و با پیش رفتن نسل به جلو، انتظار می‌رود که کیفیت جمعیت نیز به‌طور متوسط بهبود یابد (فریرا، ۲۰۰۶).

در برنامه‌ریزی بیان ژن از عملگرهای مختلفی مانند جهش و ترکیب استفاده می‌شود. این مدل، از روش معروف چرخ رولت، برای انتخاب افراد استفاده می‌کند. هدف عملگر جهش، به‌سازی تصادفی داخل کروموزوم‌های معینی است. خصوصیت این عملگر این است که برای جلوگیری از ایجاد افراد معیوب از نظر قواعد، برخی عملیات بدون نقص را اجرا می‌نماید. در این مدل از ترکیب تک‌نقطه‌ای و دو نقطه‌ای استفاده می‌شود. نوع ترکیب دو نقطه‌ای تا حدی جالب‌تر است چون می‌تواند نواحی کدگذاری نشده داخل کروموزوم‌ها را به مراتب زیادی روشن و خاموش کند. به‌علاوه در این روش، نوع دیگری از ترکیب، به نام ترکیب ژنی نیز اجرا می‌شود که در آن ژن‌ها به‌طور کامل ترکیب می‌شوند. این عملگر، به‌طور تصادفی ژن‌ها را در موقعیت یکسانی در دو کروموزوم والد انتخاب می‌کند تا دو فرزند جدید را تشکیل دهد. از دیگر عملگرهای مورد استفاده می‌توان عملگر ترانسپوز را نام برد. در این روش پدیده‌های مختلف با استفاده از مجموعه‌ای از توابع و مجموعه‌ای از ترمینال‌ها، مدل‌سازی می‌شوند. مجموعه توابع، معمولاً شامل توابع اصلی حسابی $\{+, -, \times, \div\}$ ، توابع مثلثاتی یا هر نوع تابع ریاضی دیگر $\{\sqrt{\quad}, x^2, \exp, \log, \sin, \cos, \dots\}$ و یا توابع تعریف شده توسط کاربر است که معتقد

است، می‌توانند برای تفسیر مدل مناسب باشند. مجموعه ترمینال‌ها، از مقادیر ثابت و متغیرهای مستقل مسأله تشکیل شده‌اند (فریرا، ۲۰۰۱).

در این پژوهش برای به‌کارگیری مدل برنامه‌ریزی بیان ژن از نرم‌افزار GeneXpro استفاده گردید. به‌طور خلاصه پارامترهای استفاده شده در هر بار اجرای مدل در جدول ۲ ارائه شده است.

جدول ۲- مقادیر پارامترهای به‌کار گرفته شده در برنامه‌ریزی بیان ژن.

تعداد کروموزوم‌ها	۳۰	نرخ برگشت	۰/۱	نرخ ترکیب تک‌نقطه‌ای	۰/۳
طول هر راس	۸	نرخ ترانسپوزیون	۰/۱	نرخ ترکیب دونقطه‌ای	۰/۳
تعداد ژن‌ها	۳	نرخ جهش	۰/۰۴	نرخ ترکیب ژنی	۰/۱

معیارهای ارزیابی مدل‌ها: برای ارزیابی عملکرد مدل‌های مورد استفاده در این پژوهش از چندین شاخص آماری شامل ضریب تعیین (R^2)، ریشه میانگین مربعات خطا (RMSE) استفاده گردید. ضریب تعیین در محدوده بین صفر تا ۱ تغییر می‌کند، که مقادیر بالای این ضریب نشان‌دهنده عملکرد بهتر مدل است. لگات و مکاب (۱۹۹۹) بیان کردند که این شاخص به تنهایی به‌عنوان معیاری برای عملکرد مدل مورد استفاده قرار نمی‌گیرد. بنابراین علاوه بر ضریب تعیین از شاخص ریشه میانگین مربعات خطا مطابق با رابطه زیر استفاده گردید.

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

که در آن، N: تعداد داده‌ها، h_{ie} : مقدار تراز آب زیرزمینی محاسباتی و h_{io} : مقدار تراز آب زیرزمینی اندازه‌گیری شده است.

در این پژوهش برای پیش‌بینی تراز سطح آب زیرزمینی در زمان فعلی ($h(t)$) از داده‌های تراز سطح آب در گام‌های زمانی قبلی مطابق الگوهای زیر استفاده شد:

$$h(t-1), h(t-2), h(t-3), h(t-4) \quad \text{الف)}$$

$$h(t-1), h(t-2), h(t-3), h(t-4) \quad \text{ب)}$$

$$h(t-1), h(t-2), h(t-3) \quad \text{ج)}$$

$$h(t-1), h(t-2), h(t-3), h(t-4) \quad \text{د)}$$

نتایج و بحث

شبکه عصبی مصنوعی: به منظور پیش‌بینی نوسانات سطح ایستابی در زمان فعلی، به‌ازای الگوهای مختلف ورودی مدل شبکه عصبی اجرا شد. برای این منظور ابتدا داده‌ها به ۳ دسته آموزش و صحت‌سنجی و نیز آزمون به نسبت ۸۰ و ۲۰ درصد تقسیم‌بندی شدند. پس از آماده‌سازی داده‌ها، به‌ازای الگوهای مختلف ورودی مدل شبکه عصبی پرسپترون چندلایه اجرا شد. به‌منظور دستیابی به نتایج مطلوب، پارامترهایی مانند تعداد لایه‌های میانی، تعداد نرون‌های لایه میانی، نوع تابع انتقال مورد بررسی قرار گرفتند. به‌ازای تمامی الگوهای مختلف ورودی، تابع انتقال از نوع سیگموئید بهترین نتایج را ارائه داد. نتایج به‌دست آمده از بهترین حالت اجرای مدل، به همراه معیارهای ارزیابی در جدول ۳ نمایش داده شده است. با توجه به جدول زیر، تخمین‌های مبتنی بر داده‌های دو روز قبل، بهترین شبیه برای تراز سطح ایستابی چاه ایمرتره‌ملا بوده در حالی که برای چاه‌های سلاخ‌غایب و کوچک‌خرطوم الگوی چهارم ورودی یعنی مقادیر تراز سطح ایستابی ۴ روز قبل بالاترین نتایج را برای تخمین تراز سطح ایستابی نمایش داد.

جدول ۳- نتایج اجرای مدل شبکه عصبی مصنوعی.

RMSE(m)	R ²	تعداد نرون‌های لایه میانی	الگوی به‌کار گرفته شده	
۰/۴۵۴۵	۰/۶۲۴۴	۱۰	$h(t-1)$	ایمرتره‌ملا
۰/۳۸۰۶	۰/۷۳۱۴	۲۰	$h(t-1), h(t-2)$	
۰/۳۹۴۳	۰/۷۱۶۹	۳۰	$h(t-1), h(t-2), h(t-3)$	
۰/۴۰۰۹	۰/۷۰۹۳	۴۰	$h(t-1), h(t-2), h(t-3), h(t-4)$	
۰/۴۲۹۵	۰/۷۱۰۶	۱۰	$h(t-1)$	سلاخ‌غایب
۰/۴۱۶۱	۰/۷۳۱۵	۵	$h(t-1), h(t-2)$	
۰/۴۲۱۲	۰/۷۳۱۹	۵	$h(t-1), h(t-2), h(t-3)$	
۰/۴۱۳۲	۰/۷۳۶۳	۳۰	$h(t-1), h(t-2), h(t-3), h(t-4)$	
۰/۳۸۰۵	۰/۶۰۲۴	۵	$h(t-1)$	کوچک‌خرطوم
۰/۳۵۳۴	۰/۶۴۸۸	۵	$h(t-1), h(t-2)$	
۰/۳۵۱۷	۰/۶۶۴۱	۳۰	$h(t-1), h(t-2), h(t-3)$	
۰/۳۵۹۵	۰/۶۷۱۹	۱۰	$h(t-1), h(t-2), h(t-3), h(t-4)$	

مدل فازی-عصبی: در مدل فازی عصبی هیچ قاعده کلی برای تعیین تعداد تابع عضویت وجود ندارد و معمولاً تعداد توابع از طریق سعی و خطا تعیین می‌گردد. در انتخاب تعداد تابع عضویت، باید از تعداد زیاد توابع یا پارامترها به منظور صرفه‌جویی در زمان و محاسبه‌ها جلوگیری شود. ۲، ۳ یا ۴ تابع عضویت معمولاً برای تخمین نوسانات عمق سطح ایستابی کفایت می‌کند. به‌عنوان مثال، با کاربرد ترکیبات ورودی $h(t-1), h(t-2), h(t-3), h(t-4)$ برای چاه سلاخ غایب، مدل فازی عصبی دارای تعداد تابع عضویت (۲، ۲، ۴، ۳) و نوع مثلثی می‌باشد. تابع عضویت فازی می‌تواند فرم‌های مختلفی به خود بگیرد، اما گاهی اوقات تابع عضویت مثلثی برای استفاده کاربردی انتخاب می‌شود (روسل و کامبل، ۱۹۹۶). در این پژوهش دو نوع تابع عضویت مثلثی و گوسی که نسبت به سایر توابع کاربردی‌تر هستند، مورد استفاده قرار گرفت. همچنین برای هر تابع عضویت، مقادیر مختلف از تعداد توابع شامل ۲، ۳ و ۴ مورد بررسی قرار گرفتند و در نهایت بهترین تابع عضویت و تعداد آن بر مبنای کم‌ترین مقدار RMSE انتخاب گردید. نتایج اجرای مدل فازی عصبی در غالب نمایش خطاها در جدول ۴ نمایش داده شده است.

جدول ۴- نتایج سیستم استنتاجی فازی-عصبی با به‌کارگیری توابع عضویت مختلف.

RMSE(m)	R ²	تعداد تابع عضویت	نوع تابع عضویت	الگوی به‌کار گرفته شده	
۰/۴۵۸۲	۰/۶۱۶۲	۴	مثلثی	$h(t-1)$	تعمیر در موتور
۰/۳۷۰۳	۰/۷۴۸۰	۳،۳	گوسی	$h(t-1), h(t-2)$	
۰/۴۲۹۴	۰/۶۸۴۸	۳،۲،۳	مثلثی	$h(t-1), h(t-2), h(t-3)$	
۰/۴۲۵۱	۰/۶۹۲۷	۲،۲،۲،۳	مثلثی	$h(t-1), h(t-2), h(t-3), h(t-4)$	
۰/۴۲۹۲	۰/۷۰۹۱	۴	گوسی	$h(t-1)$	نوع ظرف بزرگ
۰/۴۱۰۲	۰/۷۳۴۵	۴،۴	مثلثی	$h(t-1), h(t-2)$	
۰/۴۰۸۸	۰/۷۴۲۷	۳،۲،۲	مثلثی	$h(t-1), h(t-2), h(t-3)$	
۰/۳۹۳۱	۰/۷۶۵۳	۳،۴،۲،۲	مثلثی	$h(t-1), h(t-2), h(t-3), h(t-4)$	
۰/۳۷۷۵	۰/۵۹۵۵	۲	گوسی	$h(t-1)$	برای کار در ظرف کوچک
۰/۳۵۱۴	۰/۶۶۸۹	۳،۳	مثلثی	$h(t-1), h(t-2)$	
۰/۳۶۴۲	۰/۶۴۵۳	۳،۴،۲	مثلثی	$h(t-1), h(t-2), h(t-3)$	
۰/۴۴۱۹	۰/۴۸۰۶	۳،۲،۲،۲	گوسی	$h(t-1), h(t-2), h(t-3), h(t-4)$	

با توجه به جدول بالا، برای چاه‌های ایمرتره‌ملا و کوچک‌خرطوم، بهترین عملکرد مدل فازی-عصبی به‌ازای الگوی ۲ می‌باشد که در این حالت کم‌ترین مقدار RMSE و بیش‌ترین مقدار R^2 به‌دست آمده است، در حالی‌که برای چاه سلاخ‌غایب بهترین عملکرد مدل به‌ازای الگوی ۴ به‌دست آمده است. ضعیف‌ترین نتایج نیز برای دو چاه ایمرتره‌ملا و سلاخ‌غایب مربوط به الگوی ۱ است، در حالی‌که برای چاه کوچک‌خرطوم ضعیف‌ترین نتایج مربوط به الگوی ۴ می‌باشد.

مدل برنامه‌ریزی بیان ژن: مدل‌های گوناگون برنامه‌ریزی بیان ژن با همان ترکیبات ورودی مدل فازی عصبی ایجاد شدند. اولین گام در بررسی مدل برنامه‌ریزی بیان ژن، انتخاب تابع برازش مناسب است که می‌تواند شکل‌های مختلفی به خود بگیرد. هدف از انتخاب تابع برازش، یافتن راه‌حلی است که برای تمامی موارد برازش به اندازه یک خطای معین به‌خوبی عمل کند. نتایج انتخاب اولیه تابع برازش در مدل برنامه‌ریزی بیان ژن بیانگر آن بود که استفاده از تابع برازش ریشه نسبی مربعات خطا (RRSE)^۱ در مقایسه با سایر توابع برای همه چاه‌های مورد بررسی در این پژوهش عملکرد بهتری دارد.

بنابراین تابع RRSE به‌عنوان تابع برازش هر سه چاه انتخاب شد. گام بعد انتخاب عملگرهای اصلی برای ساخت درخت تجزیه است. توابع ریاضی به‌کار گرفته شده در این پژوهش و عملکرد مدل به‌ازای مجموعه‌ای معین از توابع در جدول ۵ نمایش داده شده است. با توجه به جدول ۵ براساس مقادیر RMSE برای داده‌های چاه ایمرتره‌ملا تابع F_1 ، برای چاه کوچک‌خرطوم تابع F_4 و برای چاه سلاخ‌غایب تابع F_5 کم‌ترین مقادیر را نمایش می‌دهند. پس از انتخاب بهترین تابع برای هر یک از چاه‌ها، گام بعد شامل پیدا کردن تابع پیوند مناسب است. از بین توابع پیوند شامل جمع و ضرب، تابع پیوند جمع عملکرد بهتری در مقایسه با تابع پیوند ضرب دارد که نتایج ارایه شده در جدول ۵ این مطلب را تأیید می‌کند.

نتایج نهایی اجرای مدل برنامه‌ریزی بیان ژن به‌ازای الگوهای مختلف ورودی، در قالب نمایش خطاها، در جدول ۶ نمایش داده شده است.

1- Root Relative Squared Error (RRSE)

جدول ۵- نتایج به‌کارگیری توابع ریاضی مختلف بر روی مقدار شاخص RMSE

تابع	مدل ریاضی	کوچک‌خراطوم	ایم‌تره‌ملا	سلاخ‌غایب
RMSE (m)				
F _۱	+, -, ×, ÷	۰/۳۲	۰/۳۹	۰/۳۸
F _۲	+, -, ×, ÷, ln x, e ^x	۰/۳۳	۰/۳۰	۰/۳۷
F _۳	+, -, ×, ÷, √, √, x ^r , x ^r	۰/۳۷	۰/۳۷	۰/۳۷
F _۴	+, -, ×, ÷, ln x, e ^x , √, √, x ^r , x ^r	۰/۲۸	۰/۴۴	۰/۳۶
F _۵	+, -, ×, ÷, ln x, e ^x , √, √, x ^r , x ^r , sin x, cos x, Arctg x	۰/۳۸	۰/۳۵	۰/۳۳
نوع تابع پیوند				
جمع		۰/۲۸	۰/۳۰	۰/۳۳
ضرب		۰/۳۱	۰/۳۴	۰/۳۵

جدول ۶- نتایج مدل برنامه‌ریزی بیان ژن با به‌کارگیری الگوهای مختلف ورودی.

الگوی به‌کار گرفته شده	R ^r	RMSE(m)	نوع
$h(t-1)$	۰/۷۵	۰/۳۴	ایم‌تره‌ملا
$h(t-1), h(t-2)$	۰/۸۴	۰/۲۹	
$h(t-1), h(t-2), h(t-3)$	۰/۷۹	۰/۳۳	
$h(t-1), h(t-2), h(t-3), h(t-4)$	۰/۷۸	۰/۳۳	
$h(t-1)$	۰/۷۶	۰/۳۸	سلاخ‌غایب
$h(t-1), h(t-2)$	۰/۷۸	۰/۳۵	
$h(t-1), h(t-2), h(t-3)$	۰/۷۹	۰/۳۴	
$h(t-1), h(t-2), h(t-3), h(t-4)$	۰/۸۳	۰/۳۲	
$h(t-1)$	۰/۷۶	۰/۳۱	کوچک‌خراطوم
$h(t-1), h(t-2)$	۰/۸۰	۰/۲۶	
$h(t-1), h(t-2), h(t-3)$	۰/۷۰	۰/۳۴	
$h(t-1), h(t-2), h(t-3), h(t-4)$	۰/۶۷	۰/۳۷	

با توجه به نتایج به دست آمده از جدول بالا، بهترین عملکرد مدل برنامه ریزی بیان ژن برای دو چاه ایمرتره ملا و کوچک خرطوم به ازای الگوی ۲ به دست آمد، زیرا به ازای این الگو کمترین مقدار RMSE و بیشترین مقدار R^2 به دست آمد. در حالی که برای چاه سلاخ غایب بهترین عملکرد مدل به ازای الگوی ۴ به دست آمده است.

از دیگر قابلیت های مدل برنامه ریزی بیان ژن نسبت به سایر مدل های هوشمند، ارایه معادله ریاضی بین متغیر وابسته و سایر متغیرهای مستقل می باشد که این مسأله برای پیش بینی های آتی اهمیت به سزایی دارد. معادله ارایه شده توسط مدل برنامه ریزی بیان ژن برای تخمین میزان تراز سطح ایستابی بر مبنای داده های پیشین به ازای بهترین الگوی ورودی در مدل برای چاه های ایمرتره ملا، سلاخ غایب و کوچک خرطوم به ترتیب در رابطه های ۲، ۳ و ۴ آورده شده است.

$$h_t = 0.1854h_{t-1} - (0.11 \log h_{t-2})h_{t-1} + 0.29h_{t-1} \quad (2)$$


$$h_t = \ln(h_{t-1} - 3/0.3) + 2 \ln(h_{t-1}) + \ln \left[(1 + h_{t-2} - h_{t-1}) \left(\frac{h_{t-2} - h_{t-1}}{-2/68h_{t-1}} \right) \right] \quad (3)$$

$$h_t = \cos(h_{t-2}) + 0.55h_{t-1} + (h_{t-2})^{0.33} + \sin(h_{t-1}) \quad (4)$$

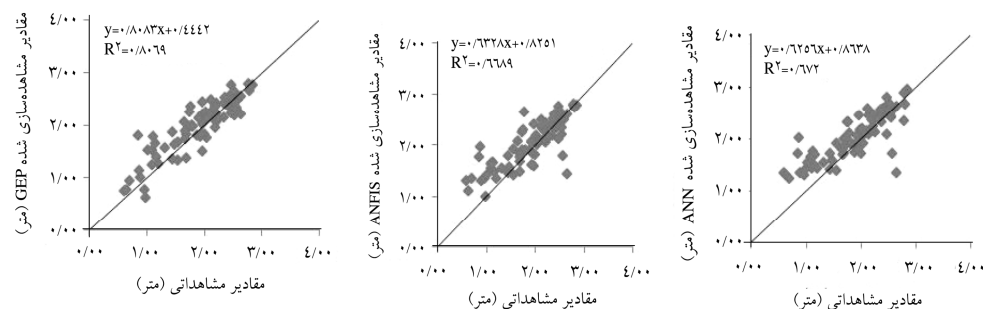
در شکل های ۳ تا ۶ نمودار پراکندگی داده های مشاهداتی و محاسباتی و همچنین سری زمانی تراز سطح ایستابی به ازای همه مدل های به کار گرفته شده برای چاه های مورد بررسی در این پژوهش نشان داده شده است.

با توجه به آنچه از نتایج به دست آمد، به منظور پیش بینی نوسانات سطح ایستابی زمان فعلی برای چاه های ایمرتره ملا و سلاخ غایب بهینه ترین حالت اجرای سه مدل به ترتیب به ازای الگوهای ۲ و ۴، یعنی استفاده از مقادیر سطح ایستابی ۲ روز قبل و ۴ روز قبل به دست آمد، در حالی که برای چاه کوچک خرطوم اجرای مدل شبکه عصبی الگوی ۴ و اجرای مدل های فازی-عصبی و برنامه ریزی بیان ژن الگوی ۲ را پیشنهاد داد. این در حالی است که مقادیر R^2 و RMSE به دست آمده از اجرای مدل فازی-عصبی و برنامه ریزی بیان ژن بیشتر از شبکه عصبی مصنوعی به دست آمد. در حالت کلی با توجه به نتایج به دست آمده از مقادیر R^2 و RMSE که برای مقایسه نتایج به دست آمده از مدل ها به کار برده شد، برای سه چاه مطالعاتی مقادیر شبیه سازی تراز سطح ایستابی مدل برنامه ریزی بیان ژن، تخمین بهتری از تراز سطح ایستابی در زمان فعلی را نشان داده و مدل های فازی-عصبی و شبکه


عصبی مصنوعی در مراتب بعدی قرار می‌گیرند، که نتایج بالا با مطالعات انجام شده توسط شیر و کیشی (۲۰۱۱) که به بررسی نوسانات سطح ایستابی دو چاه در ترکیه پرداختند، مطابقت دارد.



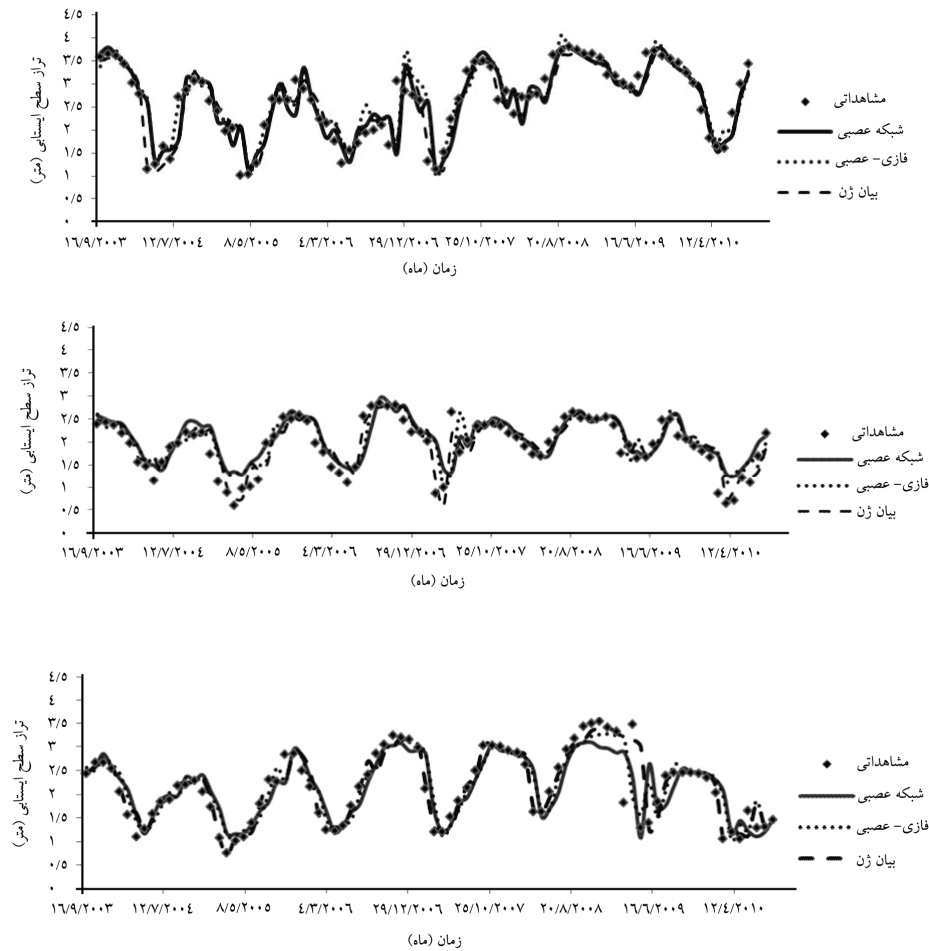
شکل ۳- نمودار پراکندگی داده‌های مشاهداتی و محاسباتی در بهترین حالت اجرای مدل‌های مختلف- سلاخ‌غایب.



شکل ۴- نمودار پراکندگی داده‌های مشاهداتی و محاسباتی در بهترین حالت اجرای مدل‌های مختلف- کوچک‌خرطوم.



شکل ۵- نمودار پراکندگی داده‌های مشاهداتی و محاسباتی در بهترین حالت اجرای مدل‌های مختلف- ایمرتره‌ملا.



شکل ۶- نمودار سری زمانی تراز سطح ایستابی در بهینه‌ترین حالت اجرای مدل‌های مختلف، به ترتیب برای چاه‌های سلاخ‌غایب، کوچک خرطوم و ایمرته‌ملا.

نتیجه‌گیری

تخمین تراز سطح ایستابی از پارامترهای مهمی است که در برنامه‌ریزی کشاورزی و مدیریت منابع آب و تعیین نیاز آب گیاهان دارای اهمیت فراوانی است. در این پژوهش به منظور تخمین تراز سطح ایستابی از سه روش شبکه عصبی مصنوعی، سامانه فازی-عصبی تطبیقی و برنامه‌ریزی بیان ژن استفاده شد. براساس محاسبات انجام شده و نتایج به دست آمده از پارامترهای آماری، هر سه روش

بالا دارای توانایی قابل‌توجهی در تخمین تراز سطح ایستابی بوده و نتایج قابل اطمینانی را ارائه می‌دهند. شایان ذکر است که با وجود برخی تفاوت‌های جزئی در دقت به‌دست آمده از به‌کارگیری سه مدل، روش برنامه‌ریزی بیان ژن به‌عنوان بهترین روش پیشنهاد می‌شود و مدل‌های فازی-عصبی و شبکه عصبی مصنوعی در مراتب بعدی قرار دارند. علاوه بر این از دیگر قابلیت‌های مدل برنامه‌ریزی بیان ژن نسبت به سایر مدل‌های هوشمند، ارائه معادله ریاضی بین متغیر وابسته و سایر متغیرهای مستقل می‌باشد که این مسأله برای پیش‌بینی‌های آتی اهمیت به‌سزایی دارد. با توجه به این‌که در این پژوهش برای پیش‌بینی تراز سطح ایستابی ماهانه در گام زمانی فعلی از داده‌های تراز سطح آب در ماه‌های پیشین استفاده شده است، می‌توان دید که با به‌کارگیری برنامه‌ریزی بیان ژن برای چاه‌های ایمرتره‌ملا و سلاخ‌غایب استفاده از تراز سطح ایستابی تا ۲ ماه قبل بهترین نتیجه را در بر داشته است. هم‌چنین بهترین نتیجه برای چاه کوچک‌خرطوم با به‌کارگیری داده‌های سطح ایستابی تا ۴ ماه قبل به‌دست آمده است.

منابع

1. Ansari Mahabadi, S., Shamsai, A., and Massah Bavani, A. 2011. Ground water level modeling in Sefiddasht by GMS model. P 1-9, Second National Conference on Applied Research in Water Resources. Zanjan, Iran.
2. Aytok, A., and Alp, M. 2008. An application of artificial intelligence for rainfall runoff modeling. *J. Earth Syst. Sci.* 117: 145-155.
3. Aytok, A., and Kisi, O. 2008. A genetic programming approach to suspended sediment modeling. *J. Hydrol.* 351: 288-298.
4. Banzhaf, W., Nordin, P., Keller, P.E., and Francone, F.D. 1998. Genetic programming. Morgan Kaufmann, San Francisco. CA. 512p.
5. Chang, F.J., and Chang, Y.T. 2005. Adaptive neuron-fuzzy inference system for prediction of water level in reservoir. *Advance. Water Res.* 29: 1. 1-10.
6. Coulilaly, P., Anclil, F., Aravena, R., and Brnard B. 2001. Artificial neural network modeling of water table depth fluctuations. *J. Hydrol.* 309: 229-240.
7. Ferreira, C. 2001. Gene expression programming: a new adaptive algorithm for solving problems. *Complex Syst.* 13: 87-129.
8. Ferreira, C. 2006. Gene expression programming: mathematical modeling by an artificial intelligence. 2nd ed. Springer-Verlag, Germany. 478p.
9. Izadi, A., Davari, K., Alizadeh, A., Ghahreman, B., and Haghayeghimoghadam, S.A. 2007. Groundwater level determination by using artificial neural network (Case study: Nishabor plain). *Iran. J. Irrig. Drain.* 1: 2. 71-59.

10. Jang, J.S.R. 1993. ANFIS: adaptive-network-based fuzzy inference system. *IEEE. Trans. Syst. Man. Cybern.* 23 :665-685.
11. Karayiannis, N.B., and Venetsanopoulos, A.N. 1993. *Artificial Neural Network: Learning Algorithms, Performance Evaluation, and Application*. Kluwer Academic Publisher, Boston. 455p.
12. Kisi, O. 2005. Suspended sediment estimation using neuro-fuzzy and neural network approaches. *Hydrol. Sci. J.* 50: 683-696.
13. Kisi, O. 2007. Streamflow forecasting using different artificial neural network algorithms. *ASCE, J. Hydrol. Eng.* 12: 532-539.
14. Kisi, O., and Ozturk, O. 2007. Adaptive neurofuzzy computing technique for evapotranspiration estimation. *J. Irrig. Drain. Engin.* 133: 368-379.
15. Legates, D.R., and McCabe, G.J. 1999. Evaluating the use of goodness-of-fit measures in hydrologic and hydroclimatic model validation. *Water Resour. Res.* 35: 233-241.
16. Mohtasham, M., Dehghani, A.A., Akbarpour, A., Meftah, M., and Etebari, B. 2010. Groundwater level determination by using artificial neural network (Case study: Birjand Aquifer). *Iran. J. Irrig. Drain.* 1: 4. 1-10.
17. Paruelo, J.M., and Tomasel, F. 1997. Prediction of functional characteristics of ecosystems: a comparison of artificial neural networks and regression models. *Ecolog. Model.* 98: 173-18.
18. Russel, S.O., and Campbell, P.F. 1996. Reservoir operating rules with fuzzy programming. *J. Water Res. PI-ASCE.* 122: 165-170.
19. Sanikhani, H., and Kisi, O. 2012. River flow estimation and forecasting by using two different adaptive neuro-fuzzy approaches. *Water Resour. Manag.* 26: 1715-1729.
20. Shiri, J., and Kisi, O. 2011. Comparison of genetic programming with neuro-fuzzy systems for predicting short-term water table depth fluctuations. *Comput. Geosci.* 37: 1692-1701.
21. Traore, S., and Guven, A. 2012. Regional-specific numerical models of evapotranspiration using gene-expression programming interface in Sahel. *Water Resour. Manag.* 26: 4367-4380.
22. Yang, Z.P., Lu, W.X., Long, Y.Q., and Li, P. 2009. Application and comparison of two prediction models for groundwater levels: a case study in Western Jilin Province, China. *J. Arid Environ.* 73: 487-492.



Gorgan University of Agricultural
Sciences and Natural Resources

J. of Water and Soil Conservation, Vol. 21(1), 2014
<http://jwsc.gau.ac.ir>

Comparison of three intelligence techniques for predicting water table depth fluctuations (Case study: Zarringol plain)

***F. Abareshi¹, M. Meftah Halghi², H. Sanikhani³ and A.A. Dehghani²**

¹M.Sc. Student, Dept. of Water Resources Engineering, Gorgan University of Agricultural Sciences and Natural Resources, ²Associated Prof., Dept. of Water Engineering, Gorgan University of Agricultural Sciences and Natural Resources, ³Ph.D. Student, Dept. of Water Resources Engineering and Young Researchers and Elite Club, Islamic Azad University, Saveh Branch, Saveh, Iran

Received: 12/26/2012; Accepted: 06/05/2013

Abstract

Groundwater is a prominent source of drinking and domestic water in the world. In this context a reliable water supply policy, specifically during the dry season necessitates accurately acceptable predictions of water table depth fluctuations. The inter-comparison of three artificial intelligence (AI) techniques are presented using the results of water table depth fluctuation time series. These models comprise Artificial Neural Network (ANN), Adaptive Neuro-Fuzzy Inference System (ANFIS) and GeneExpression Programming (GEP), which are for water table predicting of Zarringol basin in Golestan province, Iran. The monthly mean water table data with a period between 1980 and 2010 were used for training and testing the models. Statistical parameters, namely, the root mean square error (RMSE) and determination coefficient (R^2) were used to measure their performance. Overall, the results indicate that ANN, ANFIS and GEP models could be employed successfully in forecasting water table fluctuation. The best performing model, The highest coefficient of determination for Salakhgheib well ($R^2=0.83$), Kochak Khortom well ($R^2=0.80$) and Imeretaremola well ($R^2=0.84$) calculated that these values are related to gene expression programming method. However, the performance of GEP displayed a better edge over the other two modeling approaches in most of the respects especially in giving explicit expression for the problem.

Keywords: ANN, ANFIS, GEP, Water table depth

* Corresponding Author; Email: farzaneh.abareshi@gmail.com