پیش بینی تراز سطح ایستابی با استفاده از سامانه‌های هوشمند (مطالعه‌ی موردی: دشت شبستر)

علی اصغرمیرزایی*[۱] و امیرحسین ناظمی[۲]

تاریخ دریافت:۸۹/۱۰/۲۷ تاریخ پذیرش:۹۰/۱/۱۸

چکیده

تخمین تراز سطح ایستابی از مسایل مهم و اساسی است که در برنامه‌ریزی کشاورزی، مدیریت منابع آب و تعیین نیاز آبی گیاهان بویژه در مواردی که از راهکارهای کم آبیاری بهره برده شود، دارای اهمیت فراوانی است. آگاهی از تراز سطح ایستابی می‌تواند در شوری و ماندابی شدن زمین وحتی زهکشی اراضی مفید باشد. در تحقیق حاضر از سامانه های هوشمند استنتاج عصبی – فازی تطبیقی، شبکه های عصبی مصنوعی و برنامه ریزی ژنتیک برای تخمین تراز سطح ایستابی دشت شبستر در استان آذربایجان شرقی، واقع در شمال غرب ایران بهره وری گردیده است. دراین تحقیق از اطلاعات ۲۰ پیزومتر که دارای آمار بالای ۱۷ سال بودند، استفاده شده است. نتایج حاصل حاکی از توانایی مطلوب برنامه ریزی ژنتیک در تحلیل پدیده‌ی غیر خطی تغییرات تراز سطح ایستابی است. با توجه به شاخص های آماری به کار گرفته شده در تحقیق حاضر، شبکه‌ی عصبی مصنوعی و نیز سامانه‌ی عصبی – فازی تطبیقی و برنامه ریزی ژنتیک قادر به تخمین دقیق تراز سطح ایستابی بوده و با وجود برخی تفاوت های جزیی در دقت حاصل از به کارگیری این سه روش، که روش برنامه ریزی ژنتیک را به عنوان بهترین روش پیشنهاد می نماید، هر سه روش از دقت قابل قبولی برخوردارند. نتایج نشان دادند که شبیه عصبی – فازی به عنوان بهترین شبیه در تخمین های مبتنی بر داده های ۳ ماه قبل بوده و شبیه ژنتیک و عصبی مصنوعی به ترتیب در مراتب بعدی قرار دارند. همچنین راه حل های صریحی که نشانگر ارتباط بین متغیر های ورودی و خروجی می باشند، بر مبنای برنامه ریزی ژنتیک ارائه گردیده‌اند که این امر بر ارجحیت شبیه های ژنتیک بر دو شبیه دیگر می افزاید.

واژه های کلیدی: برنامه ریزی ژنتیک، تخمین، تراز سطح ایستابی، سامانه‌ی عصبی- فازی تطبیقی، شبکه های عصبی.

۱ و ۲- به ترتیب دانشجوی کارشناسی ارشد و استاد گروه مهندسی آب دانشگاه تبریز.
*نویسنده‌ی مسوول مقاله: a_mirzaie62@yahoo.com

مقدمه

آبهای زیرزمینی به عنوان تنها منبع مورد اعتماد مصرف آب در زمین،در زمینه های شرب، کشاورزی و صنعت در بیشتر مناطق خشک و نیمه خشک محسوب می‌شوند. با توجه به این که ریزشهای جوی در این مناطق بیشتر به گونه ای است که در زمانهای محدود اتفاق می‌افتند ، لذا جریانهای سطحی عموماً به صورت سیلابی و پس از هر بارش مشاهده و قطع می گردند. بنابراین، در این مناطق مهارکردن و بهره وری از آبهای سطحی فقط به صورت طرحهای آبخیزداری و در جهت تغذیه‌ی آبهای زیرزمینی انجام می گیرد، لذا کلیه‌ی برنامه ریزی های کوتاه مدت و دراز مدت تأمین آب در این مناطق بر مبنای حجم آب زیرزمینی در دسترس می باشند. تاکنون از شبیه های زیادی برای پیش بینی سطح آب زیرزمینی بهره برده شده است از جمله‌ی اینها می توان به شبیه های سری زمانی تجربی و شبیه های فیزیکی اشاره کرد (ایزدی و همکاران، ۱۳۸۶). از شبیه‌های سری زمانی تجربی، به طور گسترده ای برای شبیه سازی سطح آب زیرزمینی استفاده شده است، ولی هنگامی که رفتار پویایی یک سامانه‌ی آبشناسی با گذشت زمان تغییر می‌کند، به دلیل تأثیر فراسنجهای مختلف، تعیین معادلات حاکم بر آن نیز مشکل بوده و در صورت تعیین شبیه ریاضی نیز دسترسی به اطلاعات پیچیده‌ی زمین شناسی، مشخصات لایه های آبخوان و غیره در اکثر موارد به آسانی میسر نمی باشد. ارزیابی تغییرات تراز آب زیرزمینی و پیش بینی آن با توجه به وجود فراسنجهای متنوع مرتبط با موضوع، نظیر متغیرهای آبشناسی، زمین شناسی ، خاکشناسی و غیره مسئله ای غیرخطی و پیچیده است (دارلیاکوپولوس و همکاران،۲۰۰۵). با توجه به اهمیت پیش بینی تراز آب زیرزمینی از نقطه نظرهای مختلف، یافتن روشی مناسب برای انجام آن حائز اهمیت است. شبکه های عصبی مصنوعی می توانند در پیش بینی سطح آب زیرزمینی موثر واقع شوند. ایزدی (۱۳۸۶) نشان داد که شبکه عصبی در پیش بینی سطح آب زیرزمینی طی ۶ ماه آینده نتایج نسبتاً خوبی را ارائه می نماید. درسالهای اخیر روشهای جدید رایانه ای از نوع الگوریتم های گردشی و شبکه های عصبی مصنوعی بطور وسیعی در تمامی زمینه های علوم و مهندسی، بویژه در مورد مسائل کشاورزی-آبشناسی به کار گرفته می شوند (فرانسل و پنی گراهی، ۱۹۹۷ و الیزوندو و همکاران،۱۹۹۴). کاربرد سامانه های هوشمند برای پیش بینی تراز آبهای زیرزمینی به سرعت رو به افزایش است که دلیل این امر به سهولت کاربرد و دقت بالای این شبیه ها در تقریب معادلات غیر خطی و پیچیده ریاضی بر می گردد (پارولو و توماسل،۱۹۹۷). در کاربرد های مهندسی، از برنامه ریزی ژنتیک نیز در شبیه سازی مسائل مربوط به تعیین ساختار پدیده ها استفاده گردد. این روش جزء روشهای الگوریتم فرا کاوشی محسوب می شود که مبنای تمامی آنها بر اساس نظریه تکامل داروین استوار است. الگوریتمهای یاد شده اقدام به تعریف یک تابع هدف در قالب معیار های کیفی نموده، و سپس تابع یاد شده را برای اندازه گیری و مقایسه روشهای مختلف حل، در یک فرآیند گام به گام تصحیح ساختار داده ها به کار گرفته و در نهایت، روش حل مناسب را ارائه می نمایند. برنامه ریزی ژنتیک جدیدترین شیوه الگوریتمهای فراکاوشی است، که به دلیل دارا بودن دقت کافی ، از کاربرد بیشتری برخوردار است. خو و همکاران (۲۰۰۱) در یک تحقیق در مورد حوضه آبخیز اورگوال در فرانسه، از برنامه ریزی ژنتیک برای پیش بینی رواناب بهره برده و نتایج حاصل را با مقادیر مشاهداتی، و نیز مقادیر محاسبه شده با کابرد روشهای کهن مورد مقایسه قرار دادند. حاصل تحقیق بیانگر دقت قابل قبول برنامه ریزی ژنتیک بود. لیونگ و همکاران (۲۰۰۲) با مطالعه رابطه بارش- رواناب بدین نتیجه دست یافتند که استفاده از برنامه ریزی ژنتیک در پیش بینی رفتار بارش – رواناب در حوضه های آبخیز سبب بروز خطای کمتری خواهد گردید آیتک وکیشی (۲۰۰۸) با مطالعه در مورد پدیده حمل رسوب در آبراهه ها روش برنامه ریزی ژنتیک را به عنوان یک رهیافت مناسب جهت شبیه سازی بار معلق معرفی نمودند. همچنین درکورت (۱۹۹۹)، بابویک و کیزر (۲۰۰۲) و ماتیل و لیونگ (۲۰۰۱) از برنامه ریزی ژنتیک برای شبیه سازی بارش- رواناب بهره بردند. سامانه استنتاج عصبی -فازی تطبیقی، از جمله روشهایی است که در تحلیل پدیده های غیر خطی و بررسی رابطه بین

ورودی – خروجی در سامانه های متشکل از فراسنجهای مختلف، به کار بسته می شود. تاکنون برخی مطالعات در زمینه های کشاورزی - آبشناسی با استفاده از سامانه یاد شده به انجام رسیده اند. مقدم نیا و همکاران (۲۰۰۹) از سامانه استنتاج عصبی -فازی تطبیقی برای تخمین اندازه تبخیر روزانه در سیستان بهره بردند. کیشی و اوزترک (۲۰۰۷) با استفاده از این سامانه به پیش بینی اندازه نیاز آبی گیاه مرجع پرداختند. کسکین و همکاران (۲۰۰۴) رهیافت منطق فازی را برای تخمین اندازه تبخیر روزانه در مناطق غربی ترکیه به کار بستند.

هدف از انجام این تحقیق پیش بینی تراز سطح ایستابی تا ۲۴ ماه آینده با استفاده از سامانه های هوشمند برنامه ریزی ژنتیک،شبکه عصبی و سامانه عصبی- فازی تطبیقی وتخمین دقت آنها وانتخاب بهترین روش برای پیش بینی تراز سطح ایستابی است.

مواد و روشها

مشخصات منطقه مورد مطالعه

دشت شبستر واقع درشمال شرقی استان آذربایجان شرقی وشهرتبریز در موقعیت "۴۸ ' ۴ ° ۳۸ شمالی و "۳۱ ' ۱۷ ° ۴۶ شرقی در ارتفاع ۱۴۰۰ متری از سطح دریا واقع شده است. شکل ۱موقعیت جغرافیایی منطقه مورد مطالعه را نشان می دهد.در این تحقیق از اطلاعات۲۰ چاه مشاهده ای که دارای بیش از۱۷ سال آمار بودند استفاده شده است.

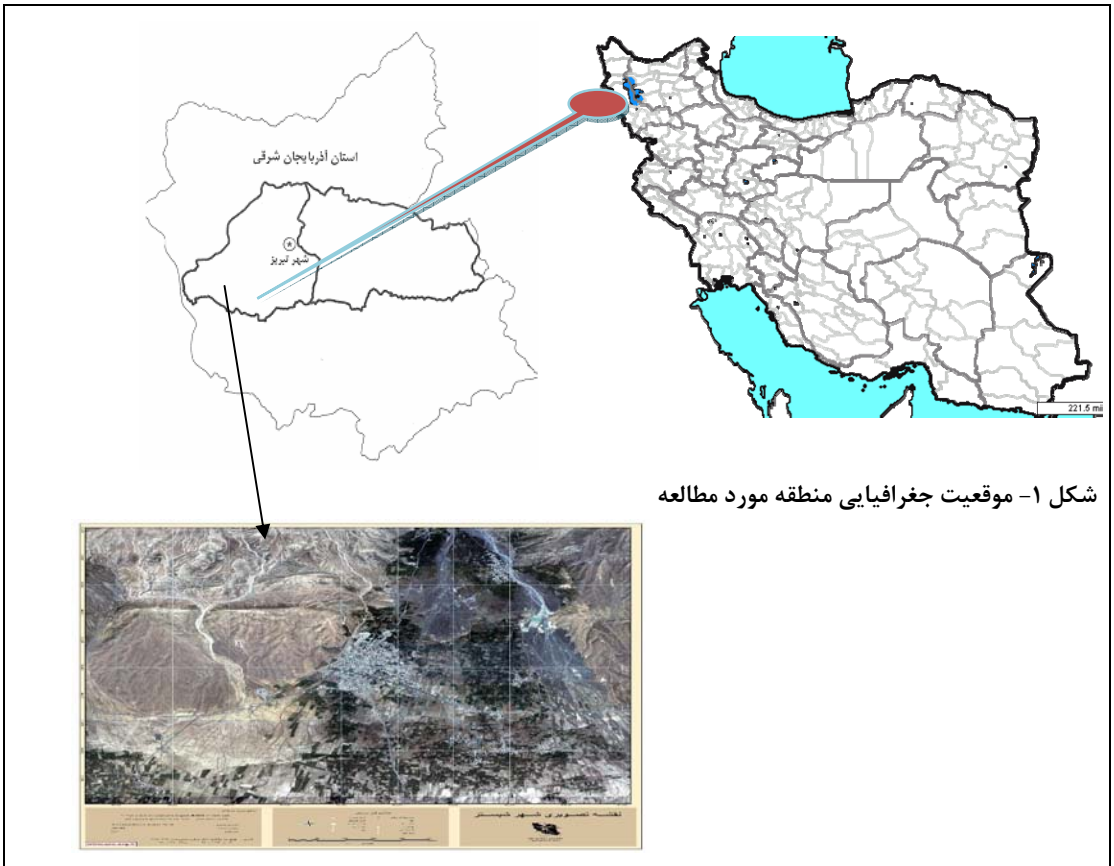

شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه

سامانه استنتاج عصبی– فازی تطبیقی

سامانه استنتاج فازی- عصبی تطبیقی[1](ANFIS) شامل شبکه‌های چند لایه‌ای می‌باشند و از الگوریتمهای یادگیری شبکه عصبی و منطق فازی به منظور طراحی و نگاشت غیرخطی بین فضای ورودی و خروجی استفاده می‌کنند. این سامانه با توجه به توانایی در ترکیب قدرت زبانی یک سامانه فازی با قدرت عددی یک شبکه عصبی، موفقیتهای بسیاری را در شبیه‌سازی و اداره سامانه‌های پیچیده داشته است. سامانه ANFIS در ابتدا به وسیله جانگ (۱۹۹۳) معرفی گردید، و از آن پس به عنوان یکی از ابزارهای تقریب ساز توابع حقیقی پیوسته (و با هر مقدار دلخواه درجه دقت) در سطح جهانی مورد استفاده قرار گرفت این سامانه از نظر عملکرد مشابه سامانه های استنتاج فازی است سامانه استنتاج عصبی– فازی تطبیقی به کار گرفته شده در تحقیق حاضر، معادل شبیه فازی از مرتبه سوگنو است (جانگ و همکاران،۱۹۹۷). در تحقیق حاضر از توابع عضویت گوسی استفاده به عمل آمد و در هر مرحله، پس از آزمون توابع عضویت متعدد، بهترین تابع با توجه به مقدار حداقل مربع خطاها انتخاب گردید. بر مبنای مراحل سعی و خطای انجام یافته در این تحقیق، تعداد توابع عضویت در هر مورد و برای هر یک از متغیرهای ورودی برابر با ۴ عدد در نظر گرفته شده است.

شبکه های عصبی مصنوعی

شبکه های عصبی مصنوعی بر اساس استنباط از سامانه عصبی زیستی استوار است. در میان نمونه های متعدد شبکه های عصبی، شبکه انتشار به عقب دارای کاربرد بیشتری است (لیپمن، ۱۹۸۷). شبکه یاد شده متشکل از لایه هایی است که دارای عناصری با عملکرد موازی هستند که به آنها نرون (عصب) گفته می شود. هر لایه با لایه قبل و بعد از خود در ارتباط است. شکل۲ نمای کلی یک شبکه عصبی را نشان می دهد که از سه لایه تشکیل گردیده است.

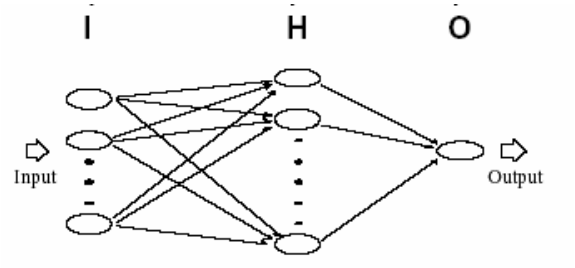

شکل ۲- ساختار یک شبکه عصبی مصنوعی

WIH و WHO نشانگر وزن های مربوط به اتصالات بین لایه ها است. تخمین اولیه وزنهای یاد شده با پیشرفت شبیه تصحیح می گردند، که این امر در مرحله آموزش (و مقایسه مقادیر خروجی مشاهداتی و شبیه سازی شده) برای تعیین مقادیر تصحیح لازم برای به حداقل رساندن خطا است.

برنامه ریزی ژنتیک

زمینه اصلی برنامه ریزی ژنتیک روش الگوریتم ژنتیک است (گلدبرگ، ۱۹۸۹). برنامه ریزی ژنتیک می تواند بطور موفقیت آمیزی در شرایط زیر به کار بسته شود (بنزهف و همکاران، ۱۹۹۸): ۱. رابطه موجود بین متغیر های مسأله به خوبی شناخته نشده باشد (یا صحت و سقم شناخت فعلی از رابطه مذکور با تردید همراه باشد)، ۲. پیدا کردن اندازه و شکل روش حل نهایی بسیار سخت بوده و بخش عمده مسأله را تشکیل دهد، ۳. روشهای معمول تحلیل ریاضی قادر به ارائه روشهای حل تحلیل نباشند، ۴. راه حل تقریبی قابل قبول باشد، ۵. هر گونه بهبود جزئی در عملکرد به صورت منظم اندازه گیری شده و این بهبود از ارزش زیادی برخوردار باشد، ۶. تعداد داده هایی که بایستی به وسیله رایانه مورد آزمون، دسته بندی و جمع بندی قرار گیرند زیاد باشد (نظیر داده های مربوط به ستاره شناسی، داده های مشاهداتی ماهواره ها، داده های مالی و یا هرگونه داده دیگر). در تحقیق حاضر از برنامه GeneXproTools (فریرا، ۲۰۰۱) برای توسعه و اجرای شبیه های مبتنی بر برنامه ریزی ژنتیک استفاده به عمل آمده است. برنامه یاد شده بر اساس برنامه ریزی

[1]- Adaptive Neural Network Fuzzy Inference System

صریح ژنتیک [1](GEP) استوار است.GEP ویرایش جدیدی از برنامه ریزی ژنتیک است که به استنتاج برنامه های رایانه ای با اندازه ها و شکلهای مختلف می پردازد (فریرا، ۲۰۰۱).

استخراج شبیه های ترازسطح ایستابی بر اساس برنامه ریزی ژنتیک

گام اول، شامل انتخاب تابع برازش مناسب است. در مطالعه حاضر، تابع RMSE (جذر میانگین مربع خطاها) به عنوان تابع برازش انتخاب گردید. گام دوم، انتخاب مجموعه متغیر های ورودی و مجموعه توابع به منظور تولید کروموزومها است. در مسأله حاضر ورودی ها متشکل از مقادیر تراز سطح ایستابی در چاههای مشاهده ای است. مرحله سوم شامل انتخاب ساختار و معماری کروموزومها است . اندازه طول هر رأس برابر با ۸ و تعداد ژنها نیز برابر با ۳ در نظر گرفته شدند. مرحله چهارم انتخاب تابع پیوندی است که در این مطالعه تابع جمع کننده (مجموع) برای ایجاد پیوند بین زیر شاخه ها مورد استفاده قرار گرفت. در نهایت، در مرحله پنجم عملگر های ژنتیک و نرخ هر یک از آنها انتخاب می گردد. در مورد شبیه سازی تراز سطح ایستابی ، ترکیبی از کلیه عملگرها نظیر جهش، برگشت، سه نوع مختلف ترانهش و سه نوع عملگر ترکیب مجدد مورد استفاده قرار گرفت. مقادیر عددی این فراسنجها به صورت خلاصه به شرح زیر است: تعداد کروموزوم=۳۰، تعداد ژن=۳، نرخ جهش=۰/۰۴۴، نرخ برگشت=۰/۱، نرخ ترکیب مجدد ژنی=۰/۳، نرخ ترکیب مجدد تک نقطه ای=۰/۳، نرخ ترکیب مجدد دو نقطه ای=۰/۳ و نرخ ترانهش=۰/۱.

شاخصهای تعیین دقت شبیه

شاخصهای آماری ضریب رگرسیون (وایازی)، جذر میانگین مربع خطاها به منظور بررسی و ارزیابی دقت شبیه ها مورد استفاده واقع شدند. شاخصهای یاد شده به ترتیب با استفاده از روابط زیر قابل محاسبه می باشند:

$$RMSE=\sqrt{\frac{\sum_{i=1}^{N}(y_i-\hat{y}_i)^2}{N}} \qquad [۱]$$

$$R^2=1-\frac{\sum(y-\hat{y})^2}{\sum y_i^2-\frac{\sum \hat{y}_i^2}{N}} \qquad [۲]$$

در روابط اخیر، $\hat{y}_i$ و y_i به ترتیب مقادیر تراز مشاهداتی و تخمینی در گام زمانی i ام می باشد. N نیز نشانگر تعداد داده هاست. داده های مورد استفاده در تحقیق حاضر شامل مقادیر تراز سطح ایستابی دشت شبسترند که طی یک دوره آماری ۱۷ساله، و با اختصاص حدود ۱۰ سال برای دوره آموزش و حدود ۷ سال برای دوره آزمون، در ترکیبهای مختلف ورودی شبیه ها وارد گردیدند. به منظور بررسی دقت هریک از روشهای یاد شده، ترکیبهای مختلفی از مقادیر ترازسطح ایستابی تشکیل گردیده و به عنوان ورودیهای این شبیه ها مورد استفاده قرار گرفتند. در هر مورد، ابتدا مقادیر تراز سطح ایستابی با استفاده ازتراز یک ماه قبل تعیین گردید و شبیه هایی با عناوین NN1[2] (شبیه شبکه عصبی)، NF1[3] (شبیه عصبی – فازی تطبیقی) و GP1[4] (شبیه برنامه ریزی ژنتیک) معرفی گردیدند. به همین ترتیب در مورد دو شبیه بعدی نیز مقادیر ترازسطح ایستابی در گامهای زمانی دو ماه و سه ماه قبل به عنوان ورودیهای شبیه به کار گرفته شده و شبیه های حاصل، به ترتیب با پسوند های ۲ و ۳ مشخص گردید. شبیه های به کار گرفته شده بر اساس مقادیر ترازسطح ایستابی در ماههای قبل تشکیل یافته و لذا در هر مورد، سه شبیه بر مبنای مقادیر تراز سطح در یک، دو و سه ماه قبل توسعه یافتند.

[1] -Genetic Expression Programing

[2] -Neural Network
[3] -Neural Fuzzy
[4] -Genetic Programming

نتایج وبحث

دوره آموزش

جدول ۱ مقادیر مربوط به هر یک از شاخص ها را در دوره آموزش نشان می دهد. با توجه به این جدول ملاحظه می شود که شبیه های مبتنی بر شبکه عصبی حساسیت کمتری در برابر افزوده شدن مؤلفه های ورودی نشان می دهند.

جدول۱- مؤلفه های آماری مربوط به شبیه های مختلف تخمین ترازسطح ایستابی در دوره آموزش

نوع شبیه		R^2	RMSE
GP	1	۰/۹۵۶	۱/۹۳۴
	2	۰/۹۵۲	۱/۸۲
	3	۰/۹۶۹	۱/۹۸
ANN	1	۰/۹۵۶	۱/۹۳۷
	2	۰/۹۵۷	۱/۹۳۳
	3	۰/۹۵۷	۱/۹۱۶
ANFIS	1	۰/۹۵۷	۲/۰۰۹
	2	۰/۹۵۷	۱/۹۱۷
	3	۰/۹۶۹	۱/۸۷۲

از سوی دیگر، شبیه های برنامه ریزی ژنتیک و سامانه عصبی – فازی دارای چنین رفتاری نبوده و افزوده شدن مقادیر تراز سطح ایستابی مربوط به گامهای زمانی مختلف به عنوان فراسنجهای ورودی، سبب تغییر و بهبود نسبی آنها می شود. همچنین، دقت شبیه های شبکه عصبی در هر سه مورد تقریبا یکسان است. با توجه به جدول ۱ ملاحظه می شود که در این حالت مقادیر ضریب تبیین مربوط به برنامه ریزی ژنتیک، بیشتر از مقادیر مشابه مربوط به دو شبیه عصبی – فازی و شبیه های شبکه عصبی است و از این منظر می توان برنامه ریزی ژنتیک را به عنوان بهترین شبیه در این بخش معرفی نمود؛ لکن بررسی مقادیر شاخص آماری دیگر، حاکی از آن است که به رغم بیشتر بودن مقدار ضریب تبیین در شبیه های مبتنی بر برنامه ریزی ژنتیک ، مقادیر خطا نیز در این شبیه ها بیشتر از مقادیر خطای مربوط به شبیه های شبکه عصبی در شرایط مشابه است، به نحوی که در شبیه GP3 که دارای ضریب تبیین برابر با ۰/۹۶۹ است (در مقایسه با شبیه NN3 که ضریب تبیین آن برابر با ۰/۹۵۷ است) مقدار شاخص RMSE نیز به مراتب بیشتر از مقدار این شاخص در شبیه شبکه عصبی است. این امر ارجحیت مطلق شبیه های مبتنی بر برنامه ریزی ژنتیک را در تخمین میزان تراز سطح ایستابی با تردید مواجه می سازد، لذا در این حالت می توان اظهار داشت که شبیه عصبی – فازی به عنوان بهترین شبیه در تخمینهای مبتنی بر داده های ۳ ماه قبل بوده و شبیه ژنتیک و عصبی مصنوعی به ترتیب در مراتب بعدی قرار دارند. در مورد شبیه های مبتنی بر تراز سطح ایستابی یک ماه و دو ماه قبل، شبیه های ژنتیک در مرتبه اول قرار داشته و شبیه های عصبی – فازی و عصبی مصنوعی (با دقت تقریبی یکسان) در مرتبه بعدی واقع می شوند.

دوره آزمون

جدول ۲ مقادیر مربوط به هر یک از شاخصها را در دوره آزمون نشان می دهد.

جدول ۲- مؤلفه های آماری مربوط به شبیه های مختلف تخمین تراز سطح ایستابی در دوره آزمون

نوع شبیه		ورودی های شبیه	شاخصهای آماری	
			R^2	RMSE
برنامه ریزی ژنتیک	GP1	H_{i-1}	۰/۹۵۶	۱/۹۳۴
	GP2	H_{i-2}, H_{i-1}	۰/۹۵۷	۱/۵۴
	GP3	H_{i-3}, H_{i-2}, H_{i-1}	۰/۹۶۹	۲/۰۴۵
شبکه عصبی مصنوعی	NN1	H_{i-1}	۰/۹۵۵	۱/۹۳۷
	NN2	H_{i-2}, H_{i-1}	۰/۹۵۷	۱/۹۳۳
	NN3	H_{i-3}, H_{i-2}, H_{i-1}	۰/۹۵۷	۱/۹۱۷
عصبی – فازی	NF1	H_{i-1}	۰/۹۵۳	۲/۰۰۹
	NF2	H_{i-2}, H_{i-1}	۰/۹۵۷	۱/۹۱۷
	NF3	H_{i-3}, H_{i-2}, H_{i-1}	۰/۹۶۹	۱/۸۷۲

همان طور که از جدول معلوم است شبیه های GP1 و NN1 دارای مقادیر ضریب تبیین تقریبا یکسانی است، لذا دقت هر دو شبیه از نظر درجه همبستگی بین داده های مشاهداتی و مقادیر تخمینی در حد یکسانی قرار دارد (R^2=(۰/۹۵۶)). از سوی دیگر، مقایسه مقادیر RMSE حاکی از دقت بیشتر شبیه های ژنتیک است که البته این اختلاف در حد کمی بوده و لذا می توان دقت هر دو شبیه را در حد یکسانی ارزیابی کرد. در مورد تخمینهای مبتنی بر داده های دو ماه قبل، شبیه های NN2 و NF2 دارای درجه همبستگی بیشتری (R^2=(۰/۹۵۷)) نسبت به شبیه GP2 با درجه همبستگی (R^2=(۰/۹۵۲))می باشند، لیکن مقدار شاخص RMSE مربوط به شبیه ژنتیک بطور قابل ملاحظه ای کمتر از مقادیر مربوط به شبیه های عصبی و عصبی – فازی است لذا در این حالت، شبیه ژنتیک به عنوان بهترین و شبیه های عصبی – فازی و شبکه های عصبی به ترتیب در اولویتهای بعدی قرار می گیرند. در مورد حالت سوم که شبیه های مذکور بر اساس داده های آماری سه ماه قبل تشکیل شده اند، شبیه عصبی – فازی دارای بیشترین مقدار ضریب تبیین(R^2=(۰/۹۶۹)) و کمترین مقادیر جذر میانگین مربع خطاها (RMSE=(۱/۸۷۲)) بوده، لذا به عنوان بهترین روش بر اساس داده های آماری سه ماه قبل است. معادله ارائه شده توسط برنامه ریزی ژنتیک برای تخمین میزان تراز سطح ایستابی در ماه i ام نیز بر بنای داده های ترازسطح ایستابی در طی سه ماه قبل به شکل زیر خواهد بود.که H_i ترازسطح ایستابی درماه i است.

$$H_i = d(0)+\exp(G2C1)-d(1))+ (d(1)/ \exp((\exp((\sqrt{G3C0})*G3C1))^2)))$$

مقادیر ثابت موجود در این معادله عبارتند از: G2C1=-1.45، G3C0=4.18 و G3C1=-1.02. با جا گذاری مقادیر یاد شده در معادله اخیر، رابطه زیر حاصل می شود:

$$H_i=H_{i-1} + (0.083-H_{i-2}) + H_{i-2}/ (1.01)$$

شکلهای ۳ تا ۵ تراز سطح ایستابی مشاهده ای و محاسباتی برای هر سه شبیه ژنتیک، عصبی و عصبی – فازی را در ۲۴ ماه آینده نشان می دهد.

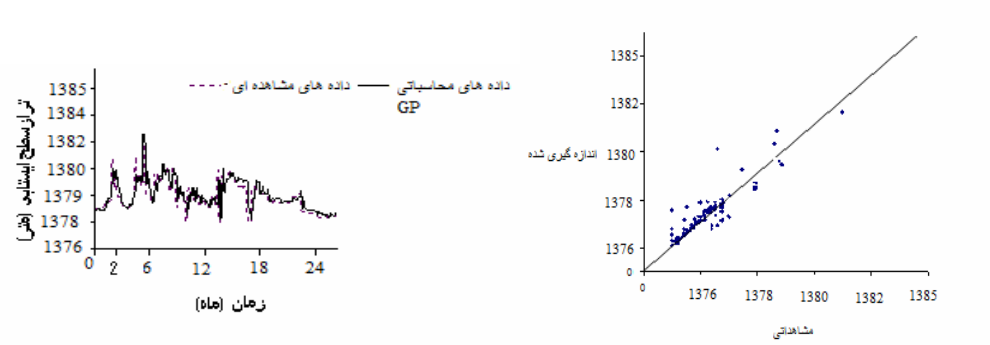

شکل۳ – الف- نمودار مقادیر مشاهداتی – محاسباتی ترازسطح ایستابی نسبت به زمان در بهینه ترین حالت شبیه برنامه ریزی ژنتیک ب- پراکندگی داده های مشاهداتی و محاسباتی حول نیمساز در بهینه ترین حالت شبیه برنامه‌ریزی ژنتیک

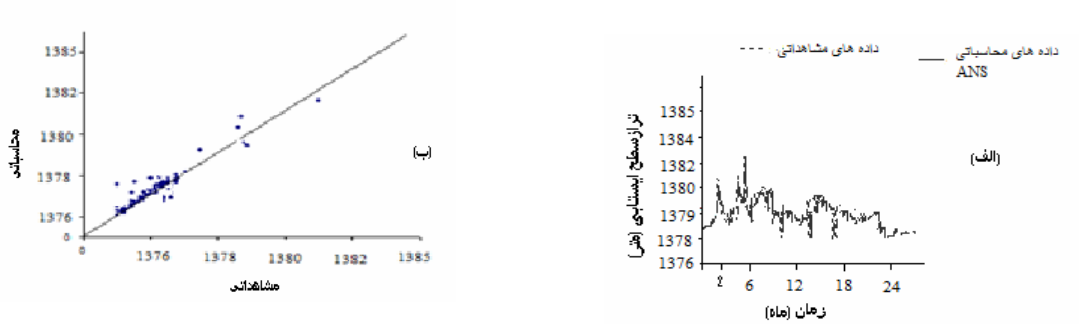

شکل۴ – الف- نمودار مقادیر مشاهداتی – محاسباتی تراز سطح ایستابی نسبت به زمان در بهینه ترین حالت شبیه شبکه‌های عصبی مصنوعی و ب- پراکندگی داده های مشاهداتی و محاسباتی حول نیمساز در بهینه ترین حالت شبیه شبکه های عصبی مصنوعی

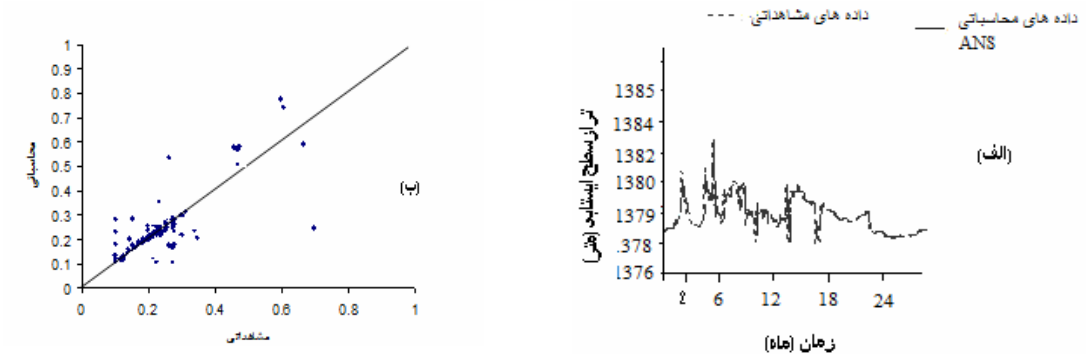

شکل۵ – الف- نمودار مقادیر مشاهداتی – محاسباتی تراز سطح ایستابی نسبت به زمان در بهینه ترین حالت شبیه شبکه های عصبی –فازی تطبیقی و ب- پراکندگی داده های مشاهداتی و محاسباتی حول نیمساز در بهینه ترین حالت شبیه شبکه های عصبی-فازی تطبیقی

همان طور که ملاحظه می شود شبیه برنامه ریزی ژنتیک تخمین بهتری از تراز سطح ایستابی در ۲۴ ماه را نشان داده، شبیه های شبکه عصبی و عصبی-فازی تطبیقی، با وجود اختلاف جزئی، به ترتیب در اولویتهای بعدی قرار می گیرند.

نتیجه گیری

شبیه سازی و تخمین تراز سطح ایستابی یکی از مؤلفه های مهم و قابل توجه در زمینه برنامه ریزی کشاورزی و نیز ، طراحی و مدیریت منابع آب است. در تحقیق حاضر از روش شبکه های عصبی مصنوعی، سامانه استنتاج عصبی – فازی تطبیقی و برنامه ریزی ژنتیک به منظور تخمین تراز سطح ایستابی متوسط بهره برده شد. بر پایه محاسبات انجام یافته، هر سه روش داری توانایی قابل توجهی در تخمین میزان تراز سطح ایستابی بوده، لذا با اطمینان کافی می توان از آنها در تراز سطح ایستابی بهره برد. شایان ذکر است که دقت برنامه ریزی ژنتیک در برخی موارد به طور جزئی بیشتر از دو روش دیگر است ولی این تفاوت چندان قابل ملاحظه نبوده و در حالت کلی می توان هر سه شبیه را به عنوان شبیه های قابل قبول تخمین تراز سطح ایستابی معرفی نمود. شبیه های مبتنی بر برنامه ریزی ژنتیک راه حلهای صریحی ارائه می نمایند که بر مبنای آنها می توان رابطه بین متغیر های ورودی و خروجی را مشخص نمود. در این تحقیق رابطه ای صریح برای تخمین تراز سطح ایستابی ارائه گردید که بر مبنای آنها می توان شبیه های تجربی تخمین تراز سطح ایستابی را صحت سنجی نمود.

منابع

۱- ایزدی، ع.، ک. داوری، ا. علیزاده، ب. قهرمان و س. ا. حقایقی مقدم. ۱۳۸۶. پیش بینی سطح ایستابی با استفاده از شبکه عصبی مصنوعی (مطالعه موردی: دشت نیشابور). مجله آبیاری و زهکشی ایران. ۱(۲): ۵۹-۷۱.

2- Aytek, A., and O. Kisi. 2008. A genetic programming approach to suspended sediment modeling. J. Hydrol. 351: 288-298.

3- Babovic, V., and M. Keijzer. 2002. Rainfall runoff modeling based on genetic programming . Nordic Hydrol. 33: 331-343.

4- Banzhaf, W., P. Nordin, R. E. Keller, and F. D. Francone. 1998. Genetic Programming. Morgan Kaufmann, San Francisco, CA.

5- Daliakopoulos, N. I., P. Coulibaly, and I. K. Tsanis. 2005. Ground water level forecasting using artificial neural networks. J. Hydrol. 309: 229-240.

6- Drecourt, J. P. 1999. Application of neural networks and genetic programming to rainfall runoff modeling. D2K Technical Rep. 0699-1-1. Danish Hydraulic Institute, Denmark.

7- Elizondo, D.A., R. W. McClendon, and G. Hoogenboom. 1994. Neural network models for predicting flowering and physiological maturity of soybean. Trans. ASAE. 37(3): 981-988.

8- Ferreira, C. 2001. Gene expression programming: a new adaptive algorithm for solving problems. Complex Syst. 13(2): 87-129.

9- Francl, L. J., and S. Panigrahi. 1997. Artificial neural network models of wheat leaf wetness. Agric. Forest. Meteorol. 88: 57-65.

10- Goldberg, D. E. 1989. Genetic algorithms in search, optimization, and machine learning. Addison –Wesley, Reading, Mass.

11- Jang, J. S. R. 1993. ANFIS: adaptive-network-based fuzzy inference system. IEEE Trans. Syst. Manage. Cyber. 23(3): 665-685.

12- Jang, J. S. R., C. T. Sun, and E. Mizutani. 1997. Neurofuzzy and soft computing: a computational approach to learning and machine intelligence. Prentice-Hall, New Jersey.

13- Keskin, M. E., O. Terzi, and D. Taylan. 2004. Fuzzy logic model approaches to daily pan evaporation estimation in Western Turkey. Hydrol. Sci. J. 49(6): 1001-1010.

14- Khu, S. T., S. Y. Liong, V. Babovic, H. Madsen, and N. Muttil. 2001. Genetic programming and its application in real- time runoff forming. J. Am. Water Resour. Assoc. 37(2): 439-451.

15- Kisi, O., and O. Ozturk. 2007. Adaptive neurofuzzy computing technique for evapotranspiration estimation. J. Irrig. Drain. Engin. 133(4): 368-379.

16- Liong, S. Y., T. R. Gautam, S. T. Khu, V. Babovic, M. Keijzer, and N. Muttil, 2002. Genetic programming: A new paradigm in rainfall runoff modeling. . J. Am. Water Resour. Assoc. 38(3): 705-718.

17- Lippman, R. 1987. An introduction to computing with neural nets. IEEE ASSP Mag. 4: 4-22.

18- Moghaddamnia, A., M. Ghafari Gousheh, J. Piri, S. Amin, and D. Han. 2009. Evaporatin estimation using artificial neural networks and adaptive neurofuzzy inference system techniques. Advanc. water Resour. 32: 88-97.

19- Muttil, N., and S. Y. Liong. 2001. Improving runoff forecasting by input variable

selection in GP. In: Proceedings of world water congres, ASCE.
20- Paruelo, J. M., and F. Tomasel. 1997. Prediction of functional characteristics of ecosystems: a comparison of artificial neural networks and regression models. Ecolog. Model. 98: 173-18.