



دانشگاه گواران و منابع طبیعی

نشریه پژوهش‌های حفاظت آب و خاک

جلد بیست و پنجم، شماره چهارم، ۱۳۹۷

<http://jwsc.gau.ac.ir>

DOI: 10.22069/jwsc.2018.14361.2910

کارایی فرامدل‌های شبیه‌ساز و رگرسیون خطی چندمتغیره در شبیه‌سازی هیدروگراف معرف آبخوان لور - اندیمشک

معصومه زینعلی^۱، *محمد رضا گلابی^۲ و مهدی بهرامی^۳

^۱ دانش‌آموخته کارشناسی‌ارشد منابع آب، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه رازی، کرمانشاه، ^۲ دانشجوی دکتری منابع آب، گروه مهندسی منابع آب، دانشکده مهندسی علوم آب، دانشگاه شهید چمران، اهواز، ^۳ استادیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه فسا
تاریخ دریافت: ۹۶۷/۱۱؛ تاریخ پذیرش: ۹۷/۲/۱۹

چکیده

سابقه و هدف: کاهش نزولات جوی، محدود بودن منابع آب و برداشت روزافزون از آب‌های زیرزمینی موجب افت سطح ایستابی دشت‌ها شده است و بنابراین الگوبندی آب‌های زیرزمینی به‌عنوان ابزار کارآمد جهت مدیریت و حفاظت این منابع مطرح هست. اکثر مطالعات انجام‌شده مربوط به پیش‌بینی در زمینه آب‌های زیرزمینی مربوط به پیش‌بینی سطح ایستابی است و کم‌تر به هیدروگراف معرف آبخوان توجه شده است. بنابراین هدف از این مطالعه در ابتدا شبیه‌سازی هیدروگراف معرف آبخوان با استفاده از فرامدل‌های شبیه‌ساز عصبی - فازی و بیان ژن و رگرسیون خطی چندمتغیره می‌باشد. سپس مقایسه این سه روش است که برای اولین بار در این مطالعه برای این هدف مورد استفاده قرار گرفته است و سؤال اساسی این پژوهش این است که برای شبیه‌سازی هیدروگراف معرف آبخوان، در شرایط کمبود داده و اطلاعات، کدام یک از این روش‌ها می‌تواند جایگزین مناسبی برای مدل‌های مفهومی باشند.

مواد و روش‌ها: محدوده مطالعاتی، دشت لور - اندیمشک، قسمتی از دشت دزفول - اندیمشک است. در منطقه دشت لور - اندیمشک، ۸ حلقه پیزومتر که پراکنش نسبتاً خوبی در منطقه دارد، شبکه پیزومتری دشت را تشکیل می‌دهد. برای انجام این مطالعه با استفاده از مختصات جغرافیایی هر پیزومتر و اطلاعات آماری ماهانه مربوط به سطح آب ۸ پیزومتر آبخوان دشت لور - اندیمشک، برای ۵ سال آبی (۸۸-۸۹ تا ۹۳-۹۲) و با استفاده از روش تسین در محیط GIS، میانگین وزنی هر پیزومتر به‌دست آمد و سری زمانی تراز آب زیرزمینی دشت که بیانگر هیدروگراف معرف آبخوان منطقه مورد مطالعه است، محاسبه گردید. سپس با استفاده از فرامدل شبیه‌ساز عصبی - فازی و فرامدل شبیه‌ساز بیان ژن هیدروگراف معرف آبخوان شبیه‌سازی شد و نتایج با هم مقایسه گردید.

یافته‌ها: با مقایسه فرامدل شبیه‌ساز عصبی - فازی و فرامدل شبیه‌ساز بیان ژن و رگرسیون خطی چندمتغیره مشاهده می‌شود که در مرحله آموزش ضریب تبیین فرامدل شبیه‌ساز عصبی - فازی از ضریب تبیین فرامدل شبیه‌ساز بیان ژن و رگرسیون خطی چندمتغیره بیشتر است. ولی در مرحله تست ضریب تبیین فرامدل شبیه‌ساز بیان ژن از ضریب تبیین

* مسئول مکاتبه: hamidgolabi65@gmail.com

فرامدل شبیه‌ساز عصبی- فازی و رگرسیون خطی چندمتغیره بیش‌تر هست. از طرفی با توجه به پارامترهای خطای استاندارد نسبی و میانگین خطا مشاهده می‌شود که فرامدل شبیه‌ساز بیان ژن برای این دو پارامتر دارای مقدار کم‌تری نسبت به بقیه مدل‌ها در مرحله تست بوده است. بر اساس معیار شاخص کلی عملکرد^۱ که هرچه مقادیر به یک نزدیک‌تر باشد مدل عملکرد بهتری دارد، مشاهده می‌شود که فرامدل شبیه‌ساز بیان ژن با اختلاف کمی دارای معیار شاخص کلی عملکرد بیش‌تری نسبت به دو مدل دیگر بوده است و می‌توان با مشاهده مقادیر جدول به این نتیجه رسید که عملکرد فرامدل شبیه‌ساز بیان ژن بهتر از دو مدل دیگر است و در شرایط کمبود داده و اطلاعات برای شبیه‌سازی هیدروگراف معرف آبخوان با استفاده از مدل‌های مفهومی هم‌چون مادفلو، فرامدل شبیه‌ساز بیان ژن می‌تواند جایگزین مناسبی باشد.

نتیجه‌گیری: نتایج نشان داد که فرامدل شبیه‌ساز بیان ژن با ضریب تبیین ۷۴ درصد در مرحله تست نسبت به فرامدل شبیه‌ساز عصبی- فازی با ضریب تبیین ۶۴ درصد و رگرسیون خطی چندمتغیره با ضریب تبیین ۵۷ درصد دارای عملکرد بهتری هست و می‌توان به این نتیجه رسید که مدل‌های بر مبنای عملکرد فازی که در اکثر مطالعاتی که کمبود داده و اطلاعات داریم جواب نسبتاً قابل‌قبولی می‌دهند در این مطالعه موردی عملکرد بهتری نسبت به فرامدل شبیه‌ساز بیان ژن نداشت ولی نسبت به روش ساده رگرسیون خطی چندمتغیره دارای عملکرد بهتری بود. بنابراین در شرایط کمبود داده و اطلاعات برای شبیه‌سازی هیدروگراف معرف آبخوان با استفاده از مدل‌های مفهومی هم‌چون مادفلو، فرامدل شبیه‌ساز بیان ژن می‌تواند جایگزین مناسبی باشد.

واژه‌های کلیدی: رگرسیون خطی چندمتغیره، فرامدل شبیه‌ساز بیان ژن، فرامدل شبیه‌ساز عصبی فازی، هیدروگراف معرف آبخوان

مقدمه

استفاده از منابع زیرزمینی همواره به‌عنوان گزینه‌ای در کنار آب‌های سطحی مطرح بوده است، البته در بسیاری از کشورهای خشک جهان از جمله ایران اصلی‌ترین منبع تأمین آب، ذخایر آب زیرزمینی است. برای اعمال مدیریت صحیح، نیاز به شناسایی و به مدل درآوردن سطح آب زیرزمینی جهت برنامه‌ریزی‌های بلندمدت و استفاده بیش‌تر و بهتر از پتانسیل‌های آبی موجود در دشت‌ها، عمیقاً احساس می‌شود. بنابراین استفاده بهینه از منابع آب‌های زیرزمینی، مستلزم مدیریت صحیح در بهره‌برداری، نیازمند سواد علمی و فنی بر سیستم منابع آبی هر منطقه است. برای اعمال

یک مدیریت صحیح نیاز به شناسایی، به مدل درآوردن و تخمین سطح آب زیرزمینی در دشت‌ها جهت برنامه‌ریزی‌های بلندمدت و استفاده بیش‌تر و بهتر از پتانسیل‌های آبی موجود در دشت‌ها، عمیقاً احساس می‌شود. از اساسی‌ترین موارد در مدیریت کمی منابع آب زیرزمینی تخمین سطح آب با استفاده از داده‌های برداشت‌شده از شبکه چاه‌های مشاهده‌ای هست (۲۳). اکبرزاده و همکاران (۲۰۱۶) از مدل شبکه عصبی مصنوعی RBF هیبرید برای پیش‌بینی تراز آب زیرزمینی دشت شاهرود استفاده کرده‌اند. این هیبرید بودن شبکه باعث افزایش دقت روش نسبت به شبکه RBF پایه می‌شود (۱). ندیری و همکاران (۲۰۱۶) پیش‌بینی سطح آب زیرزمینی را در دشت دوزدوزان

MARS و مدل درختی M5 سطح آب زیرزمینی را پیش‌بینی کردند. نتایج نشان داد که مدل W-MARS دقت بیش‌تری نسبت به مدل درختی M5 در پیش‌بینی سطح آب زیرزمینی دارد (۱۸). امام‌قلی‌زاده و کریمی دمنه (۲۰۱۷) پیش‌بینی و برآورد ضریب هوادهی دریاچه تخلیه‌کننده تختانی را مورد بررسی قرار دادند. در این پژوهش، روش برنامه‌ریزی بیان ژن (GEP) جهت برآورد ضریب هوادهی دریاچه تخلیه‌کننده تختانی مورد استفاده قرار گرفت. برای آموزش و صحت‌سنجی مدل، از داده‌های آزمایشگاهی به‌دست آمده از مدل‌های فیزیکی و هیدرولیکی چهار سد البرز، ژاوه، گتوند علیا و جره، استفاده گردید. نتایج نشان داد که روش برنامه‌ریزی بیان ژن با ضرایب همبستگی ۰/۸۰ و ۰/۶۴ و جذر میانگین مربعات خطا برابر با ۰/۱۶ و ۰/۱۳ به‌ترتیب در دو بخش آموزش و آزمون، ضریب هوادهی دریاچه تخلیه‌کننده تختانی را برآورد نمود. به‌عبارتی، استفاده از روش برنامه‌ریزی بیان ژن موجب کاهش ۲۸ درصدی خطای پیش‌بینی ضریب هوادهی دریاچه تخلیه‌کننده تختانی شده است (۴).

اکثر مطالعات انجام‌شده مربوط به پیش‌بینی در زمینه آب‌های زیرزمینی مربوط به پیش‌بینی سطح ایستابی است و کم‌تر به هیدروگراف معرف آبخوان توجه شده است. بنابراین هدف از این مطالعه در ابتدا شبیه‌سازی هیدروگراف معرف آبخوان با استفاده از فرا مدل‌های شبیه‌ساز عصبی- فازی و بیان ژن و رگرسیون خطی چندمتغیره است. سپس مقایسه این سه روش است که برای اولین بار در این مطالعه برای این هدف مورد استفاده قرار گرفته است و سؤال اساسی این پژوهش این است که آیا برای شبیه‌سازی هیدروگراف معرف آبخوان، در شرایط کمبود داده و اطلاعات، فرا مدل‌های شبیه‌ساز عصبی- فازی و بیان ژن و رگرسیون خطی چندمتغیره می‌توانند جایگزین مناسبی برای مدل‌های مفهومی باشند.

با استفاده از روش‌های هوش مصنوعی و زمین‌آمار مورد بررسی قرار دادند. بر اساس نتایج به‌دست آمده با افزایش بازه زمانی پیش‌بینی خطای مدل ترکیبی (کوکریجینگ عصبی) افزایش می‌یابد که بیش‌تر به‌دلیل افزایش خطای مدل شبکه عصبی مصنوعی با افزایش بازه زمانی پیش‌بینی هست و خطای مدل زمین‌آمار (کوکریجینگ) نامحسوس به‌نظر می‌رسد (۱۳). پورمحمدی و همکاران (۲۰۱۳) کارایی تکنیک شبکه عصبی مصنوعی و سری‌های زمانی را در پیش‌بینی سطح ایستابی آب زیرزمینی بررسی کردند. نتایج این پژوهش کارایی و دقت بالای هر دو تکنیک شبکه عصبی و سری زمانی را در پیش‌بینی سطح ایستابی چاه‌های منطقه نشان داد (۱۷). ملکی‌نژاد و همکاران (۲۰۱۳) برای پیش‌بینی نوسانات سطح آب زیرزمینی در دشت مروست از مدل‌های سری زمانی و شبکه عصبی استفاده کردند و مدل شبکه عصبی نسبت به سری زمانی تلفیقی برتری جزئی نشان داد (۱۰). یوون و همکاران (۲۰۱۶) با استفاده از روش‌های شبکه عصبی و ماشین بردار پشتیبان بر اساس سری‌های زمانی درازمدت سطح ایستابی را پیش‌بینی کردند. بر اساس نتایج مقایسه عملکرد دو مدل، نشان داده شد که پیش‌بینی عملکرد برگشت‌پذیر مدل ماشین بردار پشتیبان برتر از مدل شبکه عصبی هست (۲۲). استانلی راج و همکاران (۲۰۱۷) از شبکه عصبی مصنوعی برای پیش‌بینی تراز آب زیرزمینی در آبخوان کانیاکومری، تامیل نادو، هند استفاده کردند (۲۱). برزگر و همکاران (۲۰۱۷) با استفاده از مدل‌های ترکیبی موجک و شبکه عصبی، پیش‌بینی نوسانات سطح آب زیرزمینی را انجام دادند. استفاده از شبکه‌های تقویت عصبی WA عملکرد بهتری برای پیش‌بینی سطح آب زیرزمینی در مقایسه با مدل‌های مبتنی بر شبکه عصبی داشته‌اند (۲). رضایی و همکاران (۲۰۱۷) با استفاده از ترکیب موجک

مواد و روش‌ها


محدوده مطالعاتی، دشت لور- اندیمشک، قسمتی از دشت دزفول- اندیمشک با مساحتی حدود ۲۱۴ کیلومترمربع است که در حوضه آبریز رود دز و در شمال شهرستان اندیمشک، بین طول جغرافیایی $48^{\circ} 20'$ تا $48^{\circ} 47'$ شرقی و عرض جغرافیایی $32^{\circ} 36'$ تا $32^{\circ} 36'$ شمالی قرار گرفته و از جمله دشت‌های شمال جلگه خوزستان، در دامنه‌های غربی رشته‌کوه‌های زاگرس هست. این حوضه جزئی از بخش مرکزی شهرستان اندیمشک محسوب می‌شود و از شمال و شمال‌شرق به محدوده دریاچه سد دز، از شرق به شهر دزفول و رودخانه دز، از جنوب به شهر اندیمشک و از غرب و جنوب‌غرب به رودخانه بالا رود ختم می‌شود. موقعیت جغرافیایی منطقه مورد مطالعه در شکل ۱ نشان داده شده است. به جهت بررسی تغییرات سطح آب زیرزمینی، جهت جریان آب زیرزمینی، نقاط تغذیه و تخلیه و سایر ارزیابی‌های

هیدروژئولوژیکی، وجود یک شبکه پیزومتری مناسب در منطقه ضروری می‌باشد. در منطقه دشت لور- اندیمشک، ۸ حلقه پیزومتر که پراکنش نسبتاً خوبی در منطقه دارد، شبکه پیزومتری دشت را تشکیل می‌دهد. برای انجام این مطالعه با استفاده از مختصات جغرافیایی هر پیزومتر و اطلاعات آماری ماهانه مربوط به سطح ۸ پیزومتر آبخوان دشت لور- اندیمشک، برای ۵ سال آبی (۸۸-۸۹ تا ۹۳-۹۲) و با استفاده از روش تسین در محیط GIS، میانگین وزنی هر پیزومتر به دست آمد و سری زمانی تراز آب زیرزمینی دشت که بیانگر هیدروگراف معرف آبخوان منطقه مورد مطالعه است، محاسبه گردید (شکل ۲). سپس با استفاده از فرامدل شبیه‌ساز عصبی- فازی و فرامدل شبیه‌ساز بیان ژن هیدروگراف معرف آبخوان طی مراحل زیر شبیه‌سازی شد و نتایج باهم مقایسه گردید.



شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه.

Figure 1. Geographical location of the studied area.



شکل ۲- هیدروگراف واحد دشت لور- اندیمشک از مهر ۱۳۸۸ تا شهریور ۱۳۹۳.

Figure 2. Hydrograph unit of Lour-Andimeshk plain from October 2009 to September 2014.

۱۹۹۷ مدل سیستم شبکه عصبی- فازی تطبیقی را ارائه کردند که قابلیت ترکیب توانایی دو روش مذکور را داشت (۸).

سیستم استنتاج عصبی فازی تطبیقی از الگوریتم‌های یادگیری شبکه عصبی و منطق فازی به منظور طراحی نگاشت غیرخطی بین فضای ورودی و خروجی استفاده می‌کند و همچنین با توجه به توانایی در ترکیب قدرت زبانی یک سیستم فازی با قدرت عددی یک شبکه عصبی، در شبیه‌سازی فرایندهایی هم‌چون هیدرولوژی، هیدروژئولوژی، مدیریت مخازن و برآورد بار رسوب معلق بسیار قدرتمند می‌باشد (۹ و ۱۴). مدل فازی عصبی تطبیقی 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. در مدل سیستم استنتاج عصبی فازی تطبیقی از روش استنتاجی تاکاگی سوگنو استفاده می‌شود. زمانی عمل شبیه‌سازی به درستی استفاده شده است که تمامی پارامترهای مؤثر در ساختار مدل طوری تعیین گردند که مقدار خطای مدل به حداقل مقدار خود برسد و همچنین مقادیر کارایی، بیش‌ترین مقدار را داشته باشند.

فرامدل^۱ شبیه‌ساز عصبی- فازی: نظریه مجموعه فازی توسط آقای لطفی‌عسگرزاده مشهور به زاده در سال ۱۹۶۵ پیشنهاد شد و به‌طور گسترده در بسیاری از زمینه‌ها استفاده می‌شود (روس، ۱۹۹۵). این تئوری، ابزاری توانمند و انعطاف‌پذیر برای شبیه‌سازی عدم قطعیت‌ها و عدم صراحت‌های موجود در دنیای واقعی و بیان عبارات‌های زبانی برگرفته از تجربه و دانش بشر در قالب روابط ریاضی به‌شمار می‌آید. پیچیدگی و عدم قطعیت در سیستم‌های هیدرولوژیکی، کمبود اطلاعات در بسیاری از فرایندهای هیدرولوژیکی، مبهم و غیرصریح بودن این داده‌ها موجب شد تا استفاده از تئوری فازی در زمینه‌ی هیدرولوژی و بارش- رواناب که از اصلی‌ترین فرایندهای هیدرولوژیکی است افزایش یابد (۱۹). با این وجود، مشکل اصلی منطق فازی این است که روند سینماتیکی برای یک کنترل‌کننده فازی وجود ندارد. به‌عبارت دیگر، یک شبکه عصبی این توانایی را دارد که از محیط آموزش ببیند، جفت‌های ورودی و خروجی، ساختارش را خود مرتب کند و با شیوه‌ای، تعامل خود را تطبیق دهد. بدین منظور آقای ژانگ و همکاران در سال

مدل پیش‌بینی سیستم شبکه عصبی- فازی تطبیقی احتیاج نسبتاً زیاد به زمان برای آموزش ساختار و تعیین پارامترها می‌باشد. به منظور ساده‌سازی، فرض می‌شود که سیستم استنتاجی موردنظر دو ورودی x و y و یک خروجی z دارد. برای یک مدل فازی تاکاگی سوگنو درجه اول، می‌توان یک مجموعه قانون نمونه را با دو قانون اگر- آن‌گاه فازی به صورت زیر بیان کرد:

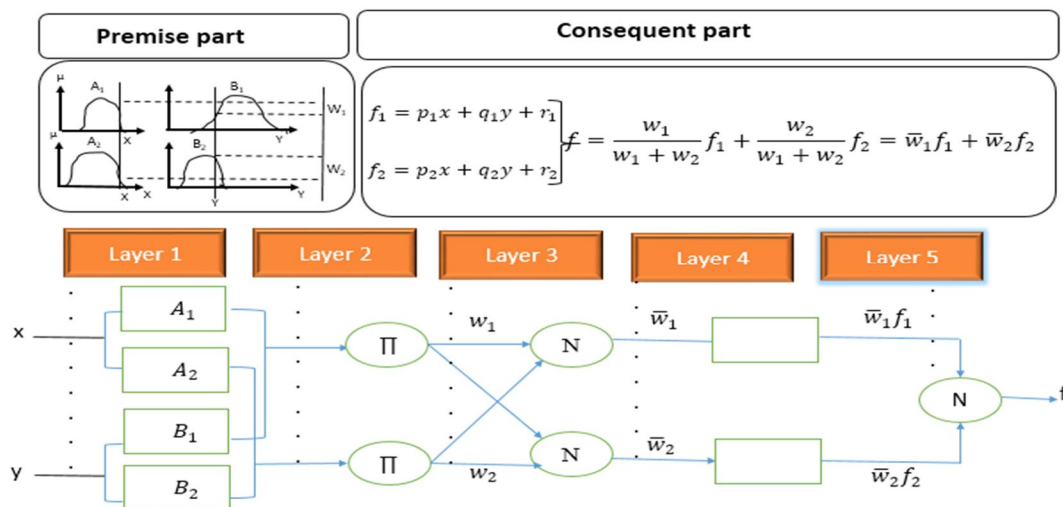
ساختار و الگوریتم: سیستم استنتاج فازی- عصبی تطبیقی قابلیت خوبی در آموزش، ساخت و طبقه‌بندی دارد و همچنین دارای این مزیت است که اجازه استخراج قوانین فازی را از اطلاعات عددی یا دانش متخصص می‌دهد و به طور تطبیقی یک قاعده- بنیاد می‌سازد. علاوه بر این، می‌تواند تبدیل پیچیده هوش بشری به سیستم‌های فازی را تنظیم کند. مشکل اصلی

$$z_1 = p_1x + q_1y + r_1 \quad \text{باشد آن‌گاه } B \text{ برابر } y_1 \text{ و } A \text{ برابر } x_1 \text{ اگر: قانون اول}$$

$$z_2 = p_2x + q_2y + r_2 \quad \text{باشد آن‌گاه } B \text{ برابر } y_2 \text{ و } A \text{ برابر } x_2 \text{ اگر: قانون دوم}$$

مطابق شکل ۳ ساختار سیستم استنتاج فازی- عصبی تطبیقی شامل پنج لایه می‌باشد (۱۶).

که در آن، پارامترهای خطی در $(i=1,2)$ r_i و q_i ، p_i بخش تالی مدل فازی تاکاگی- سوگنو درجه اول هستند (۱۵).



شکل ۳- سیستم ANFIS معادل با سیستم فازی سوگنو با تابع عضویت مثلثی.

Figure 3. ANFIS system equivalent to the Sogeno fuzzy system with triangular membership function.

$$i = 1 \text{ و } 2 \quad O_{1i} = \mu_{A_i}(x) \quad (1)$$

$$i = 3 \text{ و } 4 \quad O_{2i} = \mu_{B_i}(y)$$

لایه اول، گره‌های ورودی: هر گره از این لایه، مقادیر عضویتی که به هر یک از مجموعه‌های فازی مناسب تعلق دارند، با استفاده از تابع عضویت تولید می‌کنند.

که در آن، \bar{w}_i خروجی i امین گره از لایه قبلی است. همچنین (p_i, q_i, r_i) ضرایب این ترکیب خطی بوده، همچنین مجموعه پارامترهای بخش تالی مدل فازی تاکاگی- سوگنو نیز می‌باشند.

لایه پنجم، گره‌های خروجی: این تک‌گره، خروجی کلی را با جمع کردن همه سیگنال‌های ورودی محاسبه می‌کند. بنابراین، در این لایه فرآیند غیرفازی‌سازی، نتایج هر قانون فازی را به خروجی غیرفازی تغییر شکل می‌دهد.

$$O_{5,i} = \bar{w}_i f_i = \frac{\sum_{i=1}^4 w_i f_i}{\sum_{i=1}^4 w_i} \quad (5)$$

ویژگی متمایزکننده ANFIS، فراهم کردن الگوریتم یادگیری پیوندی روش شیب پسانتشار و روش حداقل مربعات، به منظور اصلاح پارامترها می‌باشد. روش شیب پسانتشار جهت تنظیم پارامترهای غیرخطی مقدماتی به کار گرفته می‌شود، در حالی که روش حداقل مربعات جهت تعیین پارامترهای خطی بخش تالی مورد استفاده قرار می‌گیرد. روند آموزش دو مرحله دارد: مرحله اول با ثابت فرض کردن پارامترهای بخش مقدماتی، از روش حداقل مربعات، پارامترهای بخش تالی تعیین می‌گردند. سپس در مرحله دوم، سیگنال‌های خطا پسانتشار می‌یابند. روش شیب پسانتشار به این جهت به کار می‌رود تا پارامترهای مقدماتی از طریق حداقل کردن تابع هزینه درجه دوم کلی، اصلاح شود. در شکل ۴ ساختاری از عملکرد و ارتباط بین لایه‌ها در مدل سیستم استنتاج عصبی فازی تطبیقی آورده شده است.

که در آن، x و y ورودی‌های غیرفازی به گره i ، A_1 و B_1 برجسب‌های زبانی هستند که به ترتیب با توابع عضویت مناسب μ_{Ai} و μ_{Bi} مشخص می‌شوند. باید پارامترهای این توابع عضویت که به عنوان پارامترهای مقدماتی در این لایه شناخته می‌شوند، مشخص شوند.

لایه دوم، گره‌های قاعده: در لایه دوم، عملگر "و" (AND) به کار برده می‌شود تا خروجی (قوه اشتعال) که نمایانگر بخش مقدم آن قانون است به دست آید. قوه اشتعال به مقدار درجه‌ای که بخش مقدم یک قانون فازی برآورده شده، گفته می‌شود و به تابع خروجی آن قانون، شکل می‌دهد. از این رو، خروجی‌های $O_{2,K}$ این لایه، حاصل ضرب درجات مربوط به لایه اول هستند.

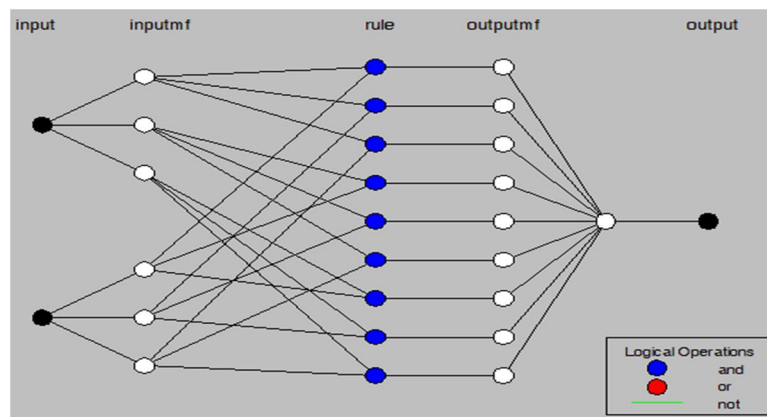
$$O_{2,K} = \mu_{Ai}(x) \times \mu_{Bi}(y) \quad (2)$$

لایه سوم، گره‌های متوسط: هدف اصلی در لایه سوم، تعیین نسبت هر قوه اشتعال به عنوان i امین قانون به مجموع همه قوه اشتعال قوانین می‌باشد در نتیجه w_i قوه اشتعال نرمال شده به دست می‌آید.

$$O_{3,i} = \bar{w}_i = \frac{w_i}{\sum_{k=1}^4 w_k} \quad (3)$$

لایه چهارم، گره‌های نتیجه: تابع گره چهارمین لایه توزیع i امین قانون را به کل خروجی محاسبه می‌کند و به صورت زیر تعریف می‌شود:

$$O_{4,i} = \bar{w}_i f_i = w_i (p_i x + q_i y + r_i) \quad (4)$$



شکل ۴- ساختار لایه‌ها در مدل سیستم استنتاج فازی عصبی تطبیقی.

Figure 4. Structure of the layers in the model of the adaptive neural fuzzy inference system.

مسأله انجام شود. سپس کروموزوم‌ها به صورت بیان درختی ارائه شده و توسط تابع برازش ارزیابی می‌گردند. در صورت دستیابی به راه حل مطلوب و یا رسیدن نسل‌ها به تعداد معین، تکامل متوقف شده و بهترین راه حل ارائه می‌شود. اگر شرایط توقف یافت نشود، نخه‌گزینی انجام می‌شود و باقی راه‌حل‌ها به فرآیندی گزینشی واگذار می‌شوند. این فرآیند برای چندین نسل تکرار می‌شود و با پیش رفتن نسل به جلو کیفیت جمعیت نیز به طور نسبی بهبود می‌یابد (۵).

فرامدل شبیه‌ساز بیان ژن نیز همانند الگوریتم ژنتیک و برنامه‌ریزی ژنتیک، یک الگوریتم ژنتیکی است به طوری که 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 به طوری که در الگوریتم ژنتیک، افراد رشته‌های خطی با طول ثابت (کروموزوم‌ها) و در برنامه‌ریزی ژنتیک، نهاده‌های غیرخطی با اندازه‌ها و اشکال متفاوت (درختان تجزیه) می‌باشند، در حالی که در فرامدل شبیه‌ساز بیان ژن، افراد به صورت رشته‌های خطی با طول ثابت (ژنوم یا کروموزوم‌ها) کدگذاری شده و سپس به شکل

فرامدل شبیه‌ساز بیان ژن: برنامه‌ریزی بیان ژن که در ادامه سیر تکاملی مدل‌های هوشمند به وجود آمده است جزء روش‌های الگوریتم گردشی محسوب می‌شود که مبنای تمامی آن‌ها بر اساس نظریه تکامل داروین استوار است (۳). مزیت فرامدل شبیه‌ساز بیان ژن نسبت به مدل‌های دیگر از جمله شبکه عصبی مصنوعی این است که در فرامدل شبیه‌ساز بیان ژن، ابتدا ساختار (متغیرهای ورودی، هدف و مجموع توابع) تعریف شده و سپس ساختار بهینه مدل و ضرایب طی فرآیند آموزش تعیین می‌شوند، در حالی که در شبکه‌های عصبی، ابتدا باید ساختار تعیین شده، فقط ضرایب مدل طی فرآیند آموزش حاصل می‌شوند. همچنین این الگوریتم به طور خودکار می‌تواند متغیرهای ورودی که در مدل بیش‌ترین تأثیر را دارند، انتخاب کند. در این روش کروموزوم‌های خطی و ساده با طول ثابت، مشابه با آنچه در الگوریتم ژنتیک استفاده می‌شود و ساختارهای شاخه‌ای با اندازه‌ها و اشکال متفاوت، مشابه با درختان تجزیه در برنامه‌ریزی ژنتیک ترکیب می‌شوند. اولین مرحله در الگوریتم مدل، تولید جمعیت اولیه از راه‌حل‌هاست. این امر می‌تواند به وسیله فرآیند تصادفی و یا در نظر گرفتن اطلاعات ورودی درباره

ساختارهای مختلف برای شبیه‌سازی: برای اجرای فرا مدل‌های شبیه‌ساز عصبی-فازی و بیان ژن، ۵ نوع ترکیب به‌عنوان پارامترهای ورودی مطابق جدول ۱ مورد بررسی قرار گرفت.

نهاده‌های غیرخطی با اندازه‌ها و اشکال متفاوت (یعنی نمایش دیاگرام ساده یا بیان درختی) بیان می‌شوند (۶). جهت کسب اطلاعات بیش‌تر با این مدل به منابع (۱۲ و ۲۰) مراجعه شود.

جدول ۱- ترکیب‌های مختلف فرا مدل‌های شبیه‌ساز.

Table 1. Different combinations of simulators.

ترکیب Combination	ورودی Input	خروجی Output
1	L_{t-1}	L_t
2	L_{t-1}, L_{t-2}	L_t
3	$L_{t-1}, L_{t-2}, L_{t-3}$	L_t
4	$L_{t-1}, L_{t-2}, L_{t-3}, L_{t-4}$	L_t
5	$L_{t-1}, L_{t-2}, L_{t-3}, L_{t-4}, L_{t-5}$	L_t

رگرسیون چندمتغیره: در تحلیل رگرسیون خطی چندمتغیره قصد داریم رابطه خطی بین متغیرهای مستقل و متغیرهای وابسته را پیش‌بینی کنیم. فرضی که رگرسیون چندمتغیره را از رگرسیون ساده دومتغیره متمایز می‌نماید این است که:

(۱) تعداد متغیرهای مستقل در رگرسیون باید کم‌تر از تعداد مشاهدات باشد.
(۲) همبستگی خطی کامل بین متغیرهای مستقل مدل وجود نداشته باشد.

در صورت نقض این دو فرض معادله رگرسیونی را نمی‌توان تخمین زد. در این مطالعه برای محاسبه ضرایب رگرسیون از نرم‌افزار SPSS استفاده شد. معیارهای ارزیابی مدل‌ها: برای ارزیابی مدل‌ها از چهار معیار، ضریب تبیین (R^2)، خطای استاندارد نسبی (RSE)، میانگین خطا (ME) و شاخص کلی عملکرد مدل (OI) استفاده شد. در زیر روابط این معیارها ارائه شده است.

پارامتر L_t تراز آب زیرزمینی در دوره زمانی ماهانه و $L_{t-1}, L_{t-2}, L_{t-3}, L_{t-4}, L_{t-5}$ تراز آب زیرزمینی در دوره‌های زمانی گذشته می‌باشد. به‌منظور هماهنگ‌تر شدن بهتر داده‌ها و افزایش سرعت اجرای مدل، داده‌ها با استفاده از روش استانداردسازی به اعدادی بین صفر تا یک تبدیل شدند و از رابطه زیر برای نرمال‌سازی (استانداردسازی) استفاده شده است (۷).

$$y = 0.1 + (0.8 \times \left(\frac{X - X_{\min}}{X_{\max} - X_{\min}} \right)) \quad (6)$$

که در آن‌ها، X داده موردنظر، \bar{X} میانگین داده‌ها، X_{\max} حداکثر داده‌ها، X_{\min} حداقل داده‌ها و y داده استاندارد شده می‌باشد. در این پژوهش از ۷۰ درصد داده‌ها برای مرحله آموزش و ۳۰ درصد برای مرحله تست استفاده شده است.

جدول ۲ ارائه شده است. در بین این ترکیب‌ها، ترکیب شماره ۵، ۴ و ۳ به ترتیب با ۵ تأخیر زمانی، ۴ تأخیر زمانی و ۳ تأخیر زمانی در مرحله آموزش به ترتیب نسبت به بقیه ترکیب‌ها عملکرد بهتری داشته‌اند و با افزایش تأخیرهای زمانی ضریب تبیین مدل بهتر شده است و ضریب تبیین آن‌ها به ترتیب برابر ۹۹/۵۲، ۹۲/۷۵ و ۹۲/۵۰ درصد می‌باشد و همچنین خطای استاندارد نسبی مرحله آموزش ترکیب شماره ۵ برابر ۲ درصد، ترکیب ۴ برابر ۵ درصد و ترکیب ۳ هم برابر ۵ درصد می‌باشد و همچنین با افزایش تأخیرهای زمانی خطای استاندارد نسبی نیز کاهش پیدا کرده است. از طرفی در بین این ترکیب‌ها در مرحله تست ترکیب شماره ۳، ۲ و ۵ با ۳ تأخیر زمانی، ۲ تأخیر زمانی و ۵ تأخیر زمانی به ترتیب نسبت به بقیه ترکیب‌ها عملکرد بهتری داشته‌اند و ضریب تبیین آن‌ها به ترتیب برابر ۶۳/۴۸، ۶۲/۵۹ و ۵۸ درصد می‌باشد و همچنین خطای استاندارد نسبی مرحله تست ترکیب شماره ۳ برابر ۲۵ درصد، ترکیب ۲ برابر ۲۵ درصد و ترکیب ۵ برابر ۴۳ درصد می‌باشد. در کل ترکیب ۳ با ۳ تأخیر زمانی، عملکرد بهتری نسبت به سایر ترکیب‌ها داشته است و بعد از آن ترکیب ۵ با افزایش تأخیر زمانی نسبت به ترکیب ۳ عملکرد بهتری داشته است. با توجه به نتایج ترکیب‌های مختلف می‌توان به این نتیجه رسید که تقریباً با ۳ تأخیر زمانی می‌توان به نتایج قابل قبولی در آموزش و تست فرامدل شبیه‌ساز عصبی-فازی رسید. شکل ۵ مقایسه مقادیر مشاهداتی با مقادیر برآوردی برای ساختار برتر فرامدل شبیه‌ساز عصبی-فازی در مرحله تست را نشان می‌دهد. با توجه به این شکل عملکرد مدل مناسب بوده است.

$$RSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (Z_{obs} - Z_{pre})^2}}{Z_{ave}} \quad (۷)$$

$$ME = \frac{1}{n} \sum (Q_{obs} - Q_{pre}) \quad (۸)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (Q_{obs} - Q_{pre})^2}{\sum_{i=1}^N (Q_{obs} - \bar{Q})^2} \quad (۹)$$

$$OI = \frac{1}{2} \left(2 - \frac{RMSE}{Q_{max} - Q_{min}} + \frac{\sum_{i=1}^N (Q_{obs} - Q_{pre})^2}{\sum_{i=1}^N (Q_{obs} - \bar{Q})^2} \right) \quad (۱۰)$$

که در آن‌ها، n تعداد داده‌ها، Q_{obs} داده‌های مشاهداتی، \bar{Q} میانگین داده‌های مشاهداتی، Q_{pre} داده‌های محاسباتی، Q_{max} حداکثر داده‌ها، Q_{min} حداقل داده‌ها می‌باشد. ضریب R^2 میزان انطباق داده‌هایی که توسط مدل به وجود می‌آید و داده‌های واقعی را نشان می‌دهد. RSE خطای استاندارد نسبی داده‌های محاسباتی و مشاهداتی را بیان می‌کند. واضح است که هرچه مقدار این عدد کم‌تر باشد به تبع، آموزش و شبیه‌سازی داده‌ها بهتر صورت گرفته است. هرچه مقدار RSE کم‌تر باشد، پیش‌بینی دقیق‌تر است. ME میانگین خطا می‌باشد. هرچه مقدار این معیار کم‌تر باشد بیانگر آن است که مدل به درستی عمل کرده است. OI شاخص کلی عملکرد مدل است. OI بین مقادیر $-\infty$ تا یک تغییر می‌کند. هرچه مقدار شاخص کلی عملکرد مدل به یک نزدیک‌تر باشد نشان‌دهنده یک تناسب کامل بین مقادیر تجربی و پیش‌بینی می‌باشد (۱۱).

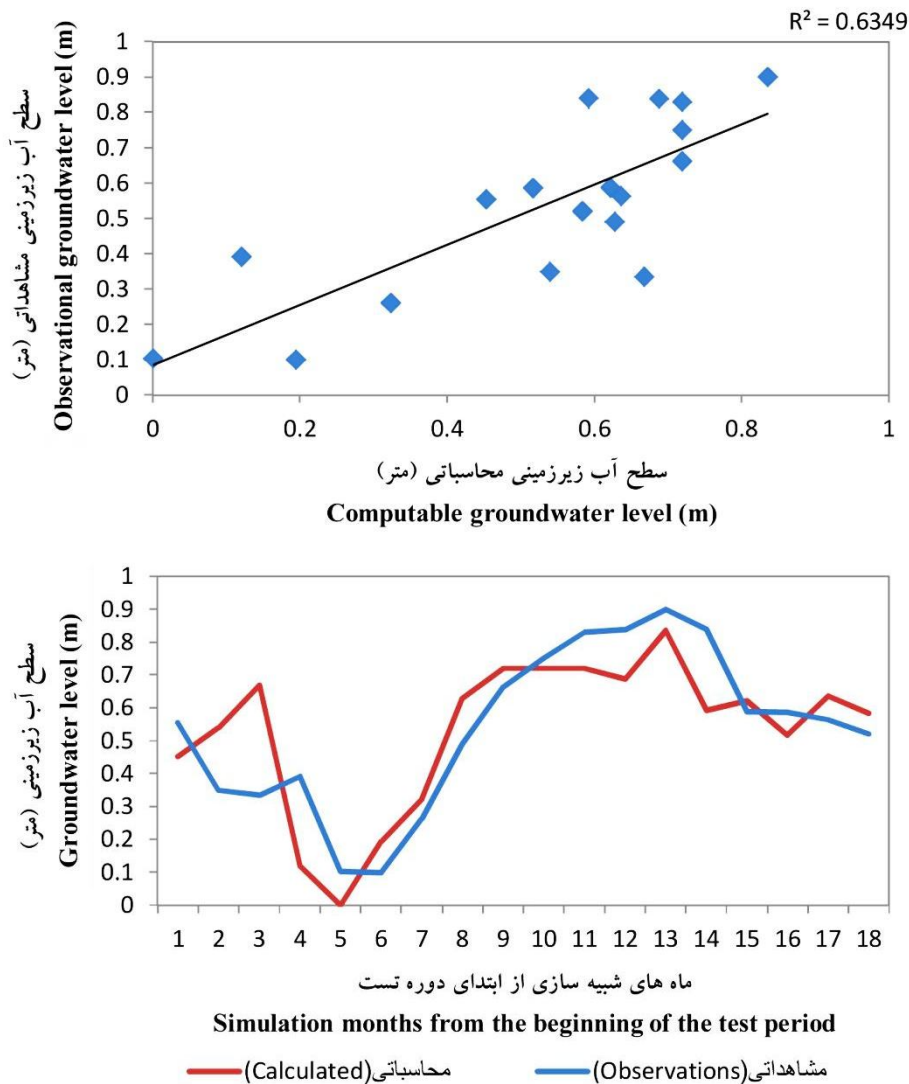
بحث و نتایج

نتایج فرامدل شبیه‌ساز عصبی-فازی: نتایج حاصل از بررسی ترکیب‌های مختلف مدل عصبی فازی در

جدول ۲ - بهترین ساختار مدل عصبی فازی.

Table 2. The best structure of the fuzzy neural model.

تست ME	آموزش ME	تست RSE	آموزش RSE	تست R ²	آموزش R ²	تعداد تابع عضویت Number of membership function	نوع تابع عضویت خروجی Type of membership output function	نوع تابع عضویت ورودی Type of membership entry function	الگوی به کار گرفته شده Pattern applied
0.05	0.03	0.28	0.08	0.57	0.81	3	constant	منشی Trimf	L_{t-1}
0.08	0.03	0.25	0.08	0.63	0.82	3 3	constant	منشی Trimf	L_{t-1}, L_{t-2}
0.06	0.02	0.25	0.05	0.64	0.93	3 3 3	constant	ذوزنقهای Trapmf	$L_{t-1}, L_{t-2}, L_{t-3}$
0.08	0.02	0.38	0.05	0.47	0.93	3 3 3 3	constant	ذوزنقهای Trapmf	$L_{t-1}, L_{t-2}, L_{t-3}, L_{t-4}$
0.06	0.01	0.43	0.02	0.58	0.99	3 3 3 3 3	constant	ذوزنقهای Trapmf	$L_{t-1}, L_{t-2}, L_{t-3}, L_{t-4}, L_{t-5}$



شکل ۵- مقایسه نتایج مدل عصبی فازی با مقادیر مشاهده‌ای، مرحله تست.

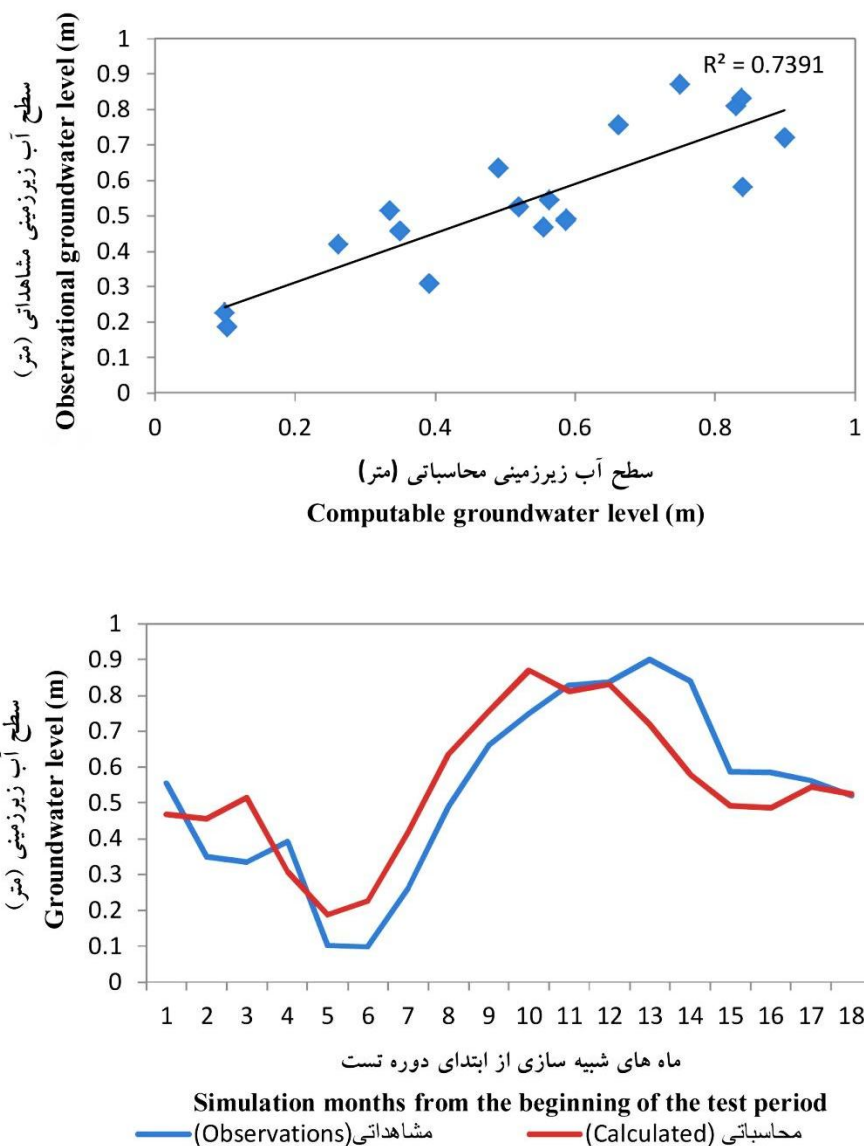
Figure 5. Comparison of the results of fuzzy neural model with observational values, test stage.

استاندارد نسبی ترکیب شماره ۵ برابر ۸ درصد، ترکیب ۴ برابر ۱۰ درصد و ترکیب ۱ برابر ۱۰ درصد می‌باشد. از طرفی در بین این ترکیب‌ها در مرحله تست ترکیب شماره ۵، ۲ و ۱ با ۵ تأخیر زمانی، ۲ تأخیر زمانی و ۱ تأخیر زمانی به ترتیب نسبت به بقیه ترکیب‌ها عملکرد بهتری داشته‌اند و ضریب تبیین آن‌ها به ترتیب برابر ۷۳/۹، ۶۲ و ۶۱/۷ درصد می‌باشد و همچنین خطای استاندارد نسبی ترکیب شماره ۵

نتایج فرامدل شبیه‌ساز بیان ژن: نتایج حاصل از بررسی ترکیب‌های مختلف مدل برنامه‌ریزی بیان ژن در جدول ۳ ارائه شده است. در بین این ترکیب‌ها، ترکیب شماره ۵، ۴ و ۱ به ترتیب با ۵ تأخیر زمانی، ۴ تأخیر زمانی و ۱ تأخیر زمانی در مرحله آموزش به ترتیب نسبت به بقیه ترکیب‌ها عملکرد بهتری داشته‌اند و ضریب تبیین آن‌ها به ترتیب برابر ۸۱/۲، ۷۵/۱ و ۷۵ درصد می‌باشد و همچنین خطای

نتایج قابل قبولی در آموزش و تست فرامدل شبیه ساز بیان ژن رسید. شکل ۶ مقایسه مقادیر مشاهداتی با مقادیر برآوردی برای ساختار برتر فرامدل بیان ژن در مرحله تست را نشان می دهد. با توجه به این شکل عملکرد مدل مناسب بوده است.

برابر ۲۰ درصد، ترکیب ۲ برابر ۲۶ درصد و ترکیب ۱ برابر ۲۸ درصد می باشد. در کل ترکیب ۵ با ۵ تاخیر زمانی، عملکرد بهتری نسبت به سایر ترکیبها داشته است. با توجه به نتایج ترکیبهای مختلف می توان به این نتیجه رسید که تقریباً با ۵ تاخیر زمانی می توان به



شکل ۶- مقایسه نتایج مدل برنامه ریزی بیان ژن با مقادیر مشاهده ای، مرحله تست.

Figure 6. Comparison of the results of the model of gene expression planning with the observed values, the test stage.

جدول ۳- بهترین ساختار مدل برنامه‌ریزی بیان ژن.


Table 3. Best structure of gene expression programming model.

میانگین خطای تست ME		خطای استاندارد نسبی RSE		ضریب تبیین R ²		ترکیب Combinatin
تست Test	آموزش Train	تست Test	آموزش Train	تست Test	آموزش Train	
0.04	0.03	0.28	0.10	0.62	0.75	1
0.08	0.03	0.26	0.10	0.62	0.72	2
0.08	0.06	0.30	0.12	0.54	0.55	3
0.06	0.03	0.26	0.10	0.59	0.75	4
0.05	0.02	0.20	0.08	0.74	0.81	5


ساختارهای نسبتاً پیچیده برای گسترش در هر مرحله خواهد بود. در این شکل مقادیر C مربوط به ضرایب فرامدل شبیه‌ساز بیان ژن و مقادیر d مربوط به پارامترهای ورودی می‌باشد که با تأخیرهای مختلف ارائه شده است.

در شکل ۷ ساختار درختی برای ترکیب برتر فرامدل شبیه‌ساز بیان ژن نشان داده است. این ساختار در هر مرحله جمعیت اولیه را به صورت ساختار خطی ساده نشان می‌دهد و همه تغییرات فقط بر روی ساختارهای ساده انجام می‌گیرد، در نتیجه نیازی به

Sub-ET 1



Sub-ET 2



Sub-ET 3



شکل ۷- ساختار درختی ترکیب برتر مدل برنامه‌ریزی بیان ژن.

Figure 7. Tree Structure The Great Combination of the Gene Expression Programming Model.

می‌باشد. در کل ترکیب ۳ با ۳ تأخیر زمانی، عملکرد بهتری نسبت به سایر ترکیب‌ها داشته است و بعد از آن ترکیب ۲ عملکرد بهتری داشته است. با توجه به نتایج ترکیب‌های مختلف می‌توان به این نتیجه رسید که تقریباً با ۳ تأخیر زمانی می‌توان به نتایج قابل‌قبولی در آموزش و تست رگرسیون چندمتغیره رسید. شکل ۸ مقایسه مقادیر مشاهداتی با مقادیر برآوردی برای ساختار رگرسیون چندمتغیره در مرحله تست را نشان می‌دهد.

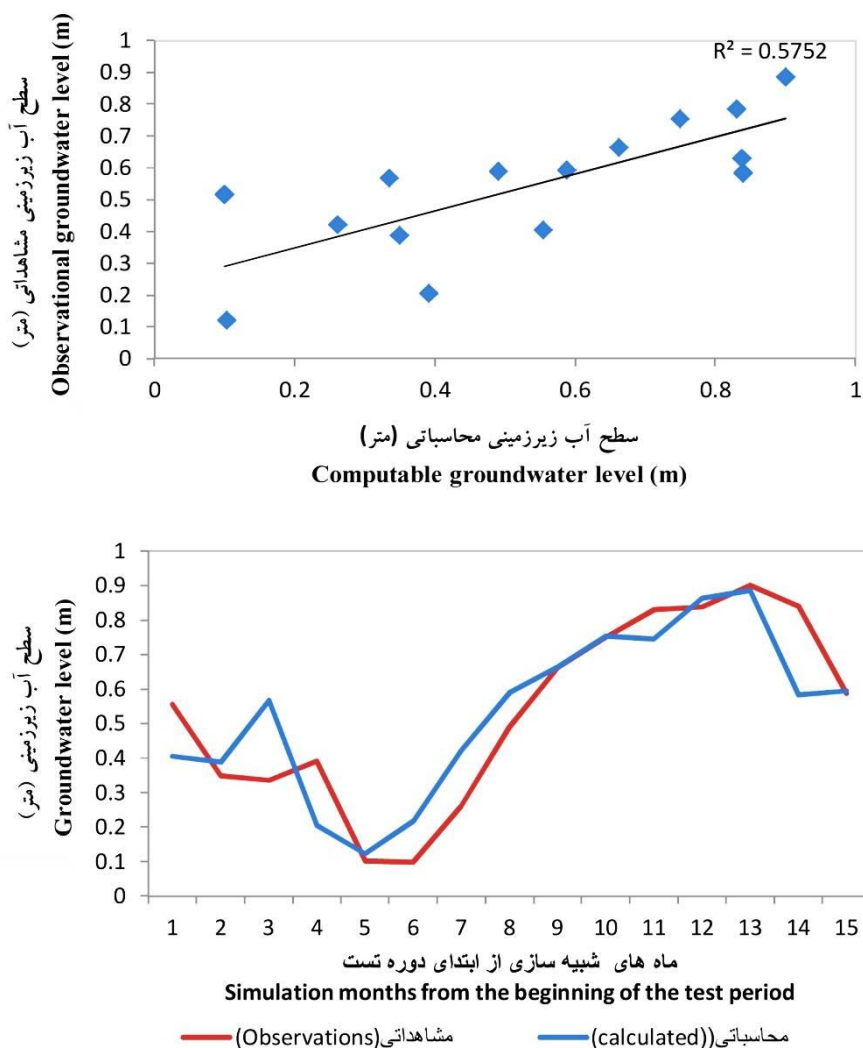
مقایسه نتایج مدل‌های استفاده شده: در این قسمت به‌منظور این‌که مقایسه مناسبی بین عملکرد سه مدل صورت گیرد، مقایسه کمی صورت گرفته است. برای مقایسه کمی بین سه مدل از چهار معیار ارزیابی به نام‌های ضریب تبیین، میانگین خطا، خطای استاندارد نسبی و شاخص کلی عملکرد مدل استفاده شد. نتایج این بررسی در جدول ۵ ارائه شده است.

نتایج رگرسیون چندمتغیره: نتایج حاصل از بررسی ترکیب‌های مختلف رگرسیون چندمتغیره در جدول ۴ ارائه شده است. در بین این ترکیب‌ها، ترکیب شماره ۴، ۳ و ۵ به‌ترتیب با ۴ تأخیر زمانی، ۳ تأخیر زمانی و ۵ تأخیر زمانی در مرحله آموزش به‌ترتیب نسبت به بقیه ترکیب‌ها عملکرد بهتری داشته‌اند و ضریب تبیین آن‌ها به‌ترتیب برابر ۸۸، ۸۷ و ۸۱ درصد می‌باشد و همچنین خطای استاندارد نسبی ترکیب شماره ۴ برابر ۱۲ درصد، ترکیب ۳ برابر ۱۲ درصد و ترکیب ۵ برابر ۷ درصد می‌باشد. از طرفی در بین این ترکیب‌ها در مرحله تست ترکیب شماره ۳، ۲ و ۵ با ۳ تأخیر زمانی، ۲ تأخیر زمانی و ۵ تأخیر زمانی به‌ترتیب نسبت به بقیه ترکیب‌ها عملکرد بهتری داشته‌اند و ضریب تبیین آن‌ها به‌ترتیب برابر ۵۷، ۵۵ و ۴۷ درصد می‌باشد و همچنین خطای استاندارد نسبی ترکیب شماره ۳ برابر ۲۸ درصد، ترکیب ۲ برابر ۲۸ درصد و ترکیب ۵ برابر ۵۳

جدول ۴- بهترین ساختار رگرسیون چندمتغیره.

Table 4. Best structure of Multivariate regression.

تست ME	آموزش ME	تست RSE	آموزش RSE	تست R ²	آموزش R ²	الگوی به کار گرفته‌شده Pattern applied
0.75	0.25	1.3	0.25	0.42	0.65	L_{t-1}
0.02	0.03	0.28	0.15	0.55	0.79	L_{t-1}, L_{t-2}
0.01	0.01	0.28	0.12	0.57	0.87	$L_{t-1}, L_{t-2}, L_{t-3}$
0.95	0.57	0.58	0.12	0.44	0.88	$L_{t-1}, L_{t-2}, L_{t-3}, L_{t-4}$
0.24	0.17	0.53	0.07	0.47	0.81	$L_{t-1}, L_{t-2}, L_{t-3}, L_{t-4}, L_{t-5}$



شکل ۸- مقایسه نتایج رگرسیون چندمتغیره خطی با مقادیر مشاهده‌ای، مرحله تست.

Figure 8. Comparison of Linear Multivariate Regression Results with Observed Values, Testing Stage.

جدول ۵- مقایسه مدل‌های استفاده شده در این پژوهش.

Table 5. Comparison of the models used in this research.

شاخص کلی عملکرد مدل		میانگین خطا		خطای استاندارد نسبی		ضریب تبیین		مدل Model
OI		ME		RSE		R ²		
تست	آموزش	تست	آموزش	تست	آموزش	تست	آموزش	
Test	Train	Test	Train	Test	Train	Test	Train	
0.72	0.93	0.06	0.02	0.25	0.05	0.64	0.93	ANFIS
0.79	0.85	0.05	0.02	0.20	0.08	0.74	0.81	GEP
0.68	0.81	0.06	0.03	0.28	0.12	0.57	0.87	MLR

تسین در محیط GIS، میانگین وزنی هر پیزومتر به دست آمد و سری زمانی تراز آب زیرزمینی دشت که بیانگر هیدروگراف معرف آبخوان منطقه مورد مطالعه است، محاسبه گردید. سپس از سه مدل به نام‌های فرامدل شبیه‌ساز عصبی- فازی و فرامدل شبیه‌ساز بیان ژن و رگرسیون خطی چندمتغیره جهت شبیه‌سازی هیدروگراف معرف آبخوان استفاده شده است. هدف از این مطالعه نشان دادن تفاوت‌های بین سه مدل و همچنین بررسی توانایی آن‌ها برای شبیه‌سازی نوسانات سطح ایستابی دشت لور- اندیمشک بوده است. نتایج نشان داد که فرامدل شبیه‌ساز بیان ژن با ضریب تبیین ۷۴ درصد در مرحله تست نسبت به فرامدل شبیه‌ساز عصبی- فازی با ضریب تبیین ۶۴ درصد و رگرسیون خطی چندمتغیره با ضریب تبیین ۵۷ درصد دارای عملکرد بهتری می‌باشد. در این مطالعه مشاهده شد که مقدار میانگین خطا و خطای استاندارد نسبی برای بهترین ترکیب فرامدل بیان ژن در مرحله تست به ترتیب برابر ۵ درصد و ۲۰ درصد و برای فرامدل شبیه‌ساز عصبی- فازی در مرحله تست ۶ درصد و ۲۵ درصد و برای مدل رگرسیون خطی چندمتغیره در مرحله تست برابر ۶ درصد و ۲۸ درصد بود. در نهایت می‌توان به این نتیجه رسید که مدل‌های بر مبنای عملکرد فازی، که در اکثر مطالعاتی که کمبود داده و اطلاعات داریم جواب نسبتاً قابل‌قبولی می‌دهند در این مطالعه موردی عملکرد بهتری نسبت به فرامدل شبیه‌ساز بیان ژن نداشت ولی نسبت به روش ساده‌ای مثل رگرسیون خطی چندمتغیره نتایج بهتری داشت و فرامدل شبیه‌ساز برتر در این مطالعه فرامدل بیان ژن بود.

با توجه به جدول ۵ مقایسه فرامدل شبیه‌ساز عصبی- فازی و فرامدل شبیه‌ساز بیان ژن و رگرسیون خطی چندمتغیره مشاهده می‌شود که در مرحله آموزش ضریب تبیین فرامدل شبیه‌ساز عصبی- فازی از ضریب تبیین فرامدل شبیه‌ساز بیان ژن و رگرسیون خطی چندمتغیره بیش‌تر می‌باشد. ولی در مرحله تست ضریب تبیین فرامدل شبیه‌ساز بیان ژن از ضریب تبیین فرامدل شبیه‌ساز عصبی- فازی و رگرسیون خطی چندمتغیره بیش‌تر می‌باشد. همچنین با توجه به پارامتر خطای استاندارد نسبی، مشاهده می‌شود که فرامدل شبیه‌ساز بیان ژن دارای خطای استاندارد نسبی کم‌تری در مرحله تست بوده است. بر اساس معیار OI که هرچه مقادیر به یک نزدیک‌تر باشد مدل عملکرد بهتری دارد، مشاهده می‌شود که فرامدل شبیه‌ساز بیان ژن با اختلاف کمی دارای معیار OI بیش‌تری نسبت به فرامدل شبیه‌ساز عصبی- فازی و رگرسیون خطی چندمتغیره بوده است و می‌توان با مشاهده مقادیر جدول به این نتیجه رسید که عملکرد فرامدل شبیه‌ساز بیان ژن بهتر از فرامدل شبیه‌ساز عصبی- فازی و رگرسیون خطی چندمتغیره است و به جواب سوال پژوهش این‌گونه جواب داد که در شرایط کمبود داده و اطلاعات برای شبیه‌سازی هیدروگراف معرف آبخوان با استفاده از مدل‌های مفهومی هم‌چون مادفلو، فرامدل شبیه‌ساز بیان ژن می‌تواند جایگزین مناسبی باشد.

نتیجه‌گیری

در این پژوهش ابتدا با استفاده از مختصات جغرافیایی هر پیزومتر و اطلاعات آماری ماهانه مربوط به سطح آب ۸ پیزومتر آبخوان دشت لور- اندیمشک، برای ۵ سال آبی (۸۹-۸۸ تا ۹۳-۹۲) و با استفاده از روش

منابع

1. Akbarzadeh, F., Hasanpour, H., and Emam Gholizadeh, S. 2016. The prediction of groundwater level in Shahrood plain using artificial neural network based on radial base function. *J. Manage. Water*. 13: 7. 104-118. (In Persian)
2. Barzegar, R., Fijani, E., Asghari Moghaddama, A., and Tziritis, E. 2017. Forecasting of groundwater level fluctuations using ensemble hybrid multi-wavelet neural network-based models. *J. Sci. Total Environ*. 599-600: 20-31.
3. Danandeh Mehr, A., and Majdzadeh Tabatabai, M.R. 2010. Prediction of Daily Discharge Trend of River Flow Based on Genetic Programming. *J. Water Soil*. 24: 2. 325-333. (In Persian)
4. Emam Gholizadeh, S., and Karimi Demne, R. 2017. Application of gene expression programming approach to estimate the aeration coefficient of bottom outlet gates of dams. *J. Water Soil Cons*. 24: 1. 279-286. (In Persian)
5. Ferreira, C. 2006. Gene Expression Programming: Mathematical Modeling by an Artificial Intelligence (Studies in Computational Intelligence). Edition, editor. Springer-Verlag New York, Inc. Secaucus, NJ, USA.
6. Ferreira, C. 2001. Gene expression programming: a new adaptive algorithm for solving problems. *Complex Syst*, 13: 2. 87-129.
7. Golabi, M.R., Akhond Ali, A.M., and Radmanesh, F. 2013. Comparison of the performance of different artificial neural network algorithms in seasonal rainfall modeling (Case study: Selected stations in Khuzestan province). *J. Appl. Geosci. Res*. 30: 13. 151-169. (In Persian)
8. Jang, J.S.R., Sun, C.T., and Mizutani, E. 1997. *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Prentice-Hall International. New Jersey.
9. Kişi, Ö. 2009. Evolutionary fuzzy models for river suspended sediment concentration estimation. *J. Hydrol*. 372 (1-4): 68-79.
10. Malekinezhad, H., and Pourshareyati, R. 2013. Application and comparison of cumulative time series model and artificial neural network model in prediction of groundwater level variation (Case study: Marvast plain). *Irrigation Science & Engineering*. 36: 3. 81-92. (In Persian)
11. Mattar, M.A., and Alamoud, A.I. 2015. Artificial neural networks for estimating the hydraulic performance of labyrinth-channel emitters. *Computers and Electronics in Agriculture*. 114: 189-201.
12. Meshkani, A., and Nazemi, A. 2009. Introduction to Data mining. Ferdowsi University of Mashhad. 456p. (In Persian)
13. Nadiri, A., Naderi, K., Asghari Moghadam, A., and Habibi, M.H. 2016. Time and place prediction of groundwater level using artificial intelligence and ground statistics methods (Case study: Aqueduct of Duzduzan plain). *Geograph. J. Plan*. 20: 58. 2. 281-301. (In Persian)
14. Navabian, M., Liaghat, A., and Homari, M. 2003. Determination of soil saturated hydraulic conductivity using pedotransfer function. *J. Agric. Engin. Res*. 4: 16. 1-12. (In Persian)
15. Nayak, P.C., Sudheer, K.P., Rangan, D.M., and Ramasastri, K.S. 2004. A neuro-fuzzy computing technique for modeling hydrological time series. *J. Hydrol*. 291: 1-2. 52-66.
16. Nourani, V., and Salehi, K. 2008. Rainfall-runoff modeling using adaptive fuzzy neural network method and comparing it with neural network and fuzzy inference method Case study: (Lighvan Chay catchment area in East Aegean province). Fourth National Congress on Civil Engineering. University of Tehran. (In Persian)
17. Nourani, V., and Komasi, M. 2013. A geomorphology-based ANFIS model for multi-station modeling of rainfall-runoff process. *J. Hydrol*. 490: 41-55.
18. Pourmahammadi, S., Malekinezhad, H., and Pourshareyati, R. 2013. Comparison of the Efficiency of Neural Network Techniques and Time Series in Groundwater Forecasting (Case study: Bakhtegan Subzone of Fars Province). *J. Water Soil Cons. Res*. 20: 4. 251-262. (In Persian)

19. Rezaie-Balf, M., Naganna, S.R., Ghaemi, A., and Deka, P.C. 2017. Wavelet coupled MARS and M5 model tree approaches for groundwater level forecasting. *J. Hydrol.* 553: 356-373.
20. Ross, T.J. 1995. *Fuzzy logic with engineering application*. McGraw Hill Inc. USA.
21. Singh, V.P. Translation: Najafi, M.R. 2002. *Hydrological systems for rainfall modeling*. First volume. Tehran University Press. First Edition. 578p. (In Persian)
22. Stanley Raj, A., Hudson Oliver, D., Srinivas, Y., and Viswanath, J. 2017. Wavelet based analysis on rainfall and water table depth forecasting using Neural Networks in Kanyakumari district. Tamil Nadu, India. *Groundwater for Sustainable Development*. 5. 178-186.
23. Yoon, H., Hyun, Y., Ha, K., Lee, K.K., and Kim, G.B. 2016. A method to improve the stability and accuracy of ANN- and SVM-based time series models for long-term groundwater level predictions. *Computers and Geosciences*. 90: 144-155.



Gorgan University of Agricultural
Sciences and Natural Resources

J. of Water and Soil Conservation, Vol. 25(4), 2018

<http://jwsc.gau.ac.ir>

DOI: 10.22069/jwsc.2018.14361.2910

Efficiency of Meta Model Simulators and Multivariate Linear Regression in Hydrograph Simulation of Aquifer Representation Loor-Andimeshk

M. Zeinali¹, *M.R. Golabi² and M. Bahrami³

¹M.Sc. Graduate of Water Resources, Dept. of Water Engineering, Faculty of Agriculture, Razi University of Kermanshah, ²Ph.D. Student of Water Resources, Dept. of Water Resources Engineering, Faculty of Water Engineering Sciences, Shahid Chamran University of Ahvaz,

³Assistant Prof., Dept. of Water Engineering, Faculty of Agriculture, Fasa University

Received: 10.03.2017; Accepted: 05.09.2018

Abstract

Background and Objectives: The reduction of atmospheric precipitation, limited water resources and the increase to withdraw from groundwater have led to a decline in the water table of the plains and therefore the modeling of groundwaters is an effective tool for managing and protecting these resources. Most studies carried out on groundwater prediction are related to the prediction of the water level and less attention has been paid to hydrographs of the aquifer. Therefore, the purpose of this study was to first introduce hydrograph modeling of the aquifer using a neuro-fuzzy metamorphic model and then compare the result with modeling by the trans-model of gene expression simulator, which both models for the first time in this study for this. The purpose of the study was to address the fundamental question of whether fuzzy-function models, which are fairly acceptable in most of the studies that lack data and information, can also be better in this case study than the simulation model. The gene expression, which has shown good performance in most recent studies.

Materials and Methods: The study area, Laur-Andimeshk Plain, is part of the Dezful-Andimeshk Plain. In the area of the Laura-Andimeshk Plain, the 8 piezometer loops, which have relatively good distribution in the region, form the plain piezometric network. To do this study, using the geometric coordinates of each piezometer and the monthly statistical information of the 8th piezometer of the Laura-Andimeshk plain, for 5 years (89-88-93-92) and using the Tesine method in the GIS environment, weighted average Piezometer was obtained and the time series of the groundwater level of the plain, which represents the hydrograph of the representative aquifer of the study area, was calculated.

Results: By comparing the transmutation of the neuro-fuzzy simulator and the transmutation of the gene expression simulator, it is observed that in the training stage, the coefficient of non-fuzzy-simulation of the transcoding explanation is more than the transcoding explanatory factor of the gene expression simulator. However, in the test stage, the transdermal expression coefficient of the gene expression simulator is greater than the fuzzy-fuzzy simulator. On the other hand, according to the mean square error of the error, it is observed that the transcendental-neural-fuzzy simulator has a lower mean square root mean square error in the test phase. Based on the OI criterion, the closer the values are to one, the better the model performs, it is observed that the transmutation of the gene expression simulator has, by difference, a more OI benchmark than that of the neuro-fuzzy simulator and can be seen by observing the table values. It is concluded that the performance of the trans-model of the gene

* Corresponding Author; Email: hamidgolabi65@gmail.com

expression simulator is better than the framed-neural-fuzzy simulator and, in the absence of data and information for the modeling of the hydrograph representing the aquifer, using conceptual models such as the Modflow, the Transmodel gene expression simulator can be a good alternative.

Conclusion: The results showed that Transformer gene expression simulator with coefficient of explanation of 74 percent at test stage compared to non-fuzzy-simulation model with coefficient of explanation of 64 percent has better performance and it can be concluded that models based on fuzzy function, which in most of the studies that lack data and information, we have relatively acceptable results. In this case study, we did not have a better performance than the conventional model of gene expression simulation. In the absence of data and information for modeling hydrographs, representing the aquifer using conceptual models such as Modflow, Gene expression simulator can be a good alternative.

Keywords: Hydrograph representing aquifer, Meta model gene expression simulator, Meta model Neural-Fuzzy simulator, Modeling

