

مقایسه روش‌های سیستم استنتاج فازی - عصبی تطبیقی، شبکه عصبی مصنوعی و برنامه‌ریزی بیان ژن در تخمین میزان سختی آب زیرزمینی (مطالعه موردی: دشت مازندران)

رضا دهقانی^{۱*}، امیر پورحقی^۲، مهرداد خیرایی^۳

۱- کارشناس ارشد منابع آب، دانشگاه تبریز

۲- دانشجوی دکتری منابع آب، دانشگاه چمران اهواز

۳- کارشناسی ارشد سازه آبی، دانشگاه چمران اهواز

نویسنده مسئول: reza.dehghani67@yahoo.com *

دریافت: ۹۳/۶/۱۲ پذیرش: ۹۴/۸/۵

چکیده

میزان سختی آب زیرزمینی عامل مهمی در مسائل هیدروژئولوژی و بویژه مطالعه کیفی آب‌های زیرزمینی می‌باشد. در چند دهه اخیر سیستم‌های هوش مصنوعی کاربرد زیادی در علوم مختلف از جمله مدیریت منابع آب داشته است. در این پژوهش تخمین میزان سختی آب زیرزمینی دشت مازندران، با استفاده از برنامه‌ریزی بیان ژن مورد بررسی قرار گرفته و نتایج آن با سایر روش‌های هوشمند همچون شبکه عصبی مصنوعی و سیستم استنتاج فازی-عصبی تطبیقی مقایسه شده است. برای این منظور هیدروژن کربنات، کلرید، سولفات، منیزیم و کلسیم در مقیاس زمانی ماهانه در طی دوره آماری (۱۳۷۳-۱۳۹۳) بعنوان ورودی و میزان سختی آب بعنوان پارامتر خروجی انتخاب گردید. معیارهای ضریب همبستگی، ریشه میانگین مربعات خطا، میانگین قدر مطلق خطا و ضریب نش ساتکلیف برای ارزیابی و نیز مقایسه عملکرد روش‌ها مورد استفاده قرار گرفت. نتایج حاصله نشان داد مدل برنامه‌ریزی بیان ژن دارای بیشترین ضریب همبستگی ۰/۹۶۰، کمترین ریشه میانگین مربعات خطا ۰/۱۱۲ ppm، میانگین قدر مطلق خطا ۰/۱۷۱ ppm و نش ساتکلیف ۰/۸۸۰ در مرحله صحت سنجی در اولویت قرار گرفت. در مجموع نتایج نشان داد که مدل برنامه‌ریزی بیان ژن توانایی بالایی در تخمین برخی مقادیر بیشینه و میانی میزان سختی آب زیرزمینی دارد.

واژه‌های کلیدی: برنامه‌ریزی بیان ژن، تخمین، دشت مازندران، شبکه عصبی مصنوعی، سیستم استنتاج فازی-عصبی تطبیقی

۱- مقدمه

بررسی قرار داده و نتایج حاصله بیانگر کارایی مناسب و دقت بالای برنامه‌ریزی ژنتیک در پیش‌بینی جریان ورودی به سد می‌باشد [۳]. در پژوهشی دیگر رحمانی جهت شبیه‌سازی منابع آب زیرزمینی دشت عقیلی از مدل‌های شبکه عصبی مصنوعی و تفاضلات محدود استفاده کرد. مقایسه نتایج نشان داد که شبکه عصبی مصنوعی نسبت به مدل ریاضی با دقت قابل توجهی سطح آب زیرزمینی را پیش‌بینی نموده است [۴]. از سوی دیگر زمانی احمد محمودی از تلفیق مدل شبکه عصبی مصنوعی بهینه شده با الگوریتم ژنتیک و روش زمین آمار برای تخمین تراز سطح ایستابی دشت‌های دزفول، زیدون و رامهرمز استفاده کرد. نتایج این تحقیق نشان داد تلفیق این دو مدل قابلیت بسیار بالایی در تخمین سطح آب زیرزمینی این دشت‌ها دارد [۵]. تمدنی کناری در

یکی از مهم‌ترین منابع تأمین‌کننده آب، سفره‌های آب زیرزمینی می‌باشند که همواره تلاش شده است تا ضمن شناخت توانایی‌های این منابع، میزان مصرف آن‌ها نیز مشخص گردد. کیفیت آب زیرزمینی به اندازه‌ی کمیت آن برای قابل استفاده بودن آن در مصارف مختلف مهم و ضروری است. امروزه سیستم‌های هوشمند همچون شبکه عصبی مصنوعی به طور گسترده برای پیش‌بینی پدیده‌های غیرخطی مورد استفاده قرار می‌گیرد [۱۶]. طی سال‌های اخیر استفاده از مدل‌های هوشمند در مطالعات کیفیت آب زیرزمینی مورد توجه محققین قرار گرفته است، که از جمله می‌توان به موارد ذیل اشاره نمود:

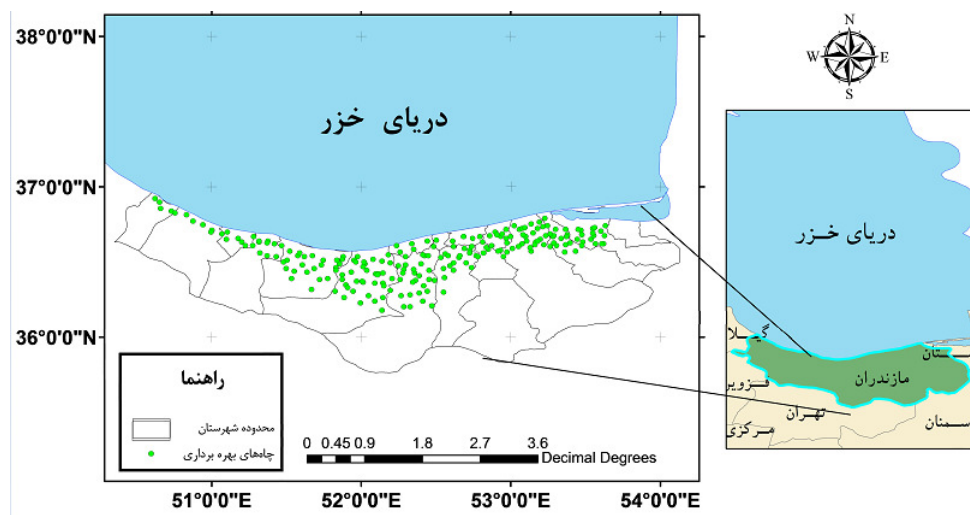
در پژوهشی دربندی و همکاران جریان ورودی به مخزن سد علویان را با استفاده از برنامه‌ریزی بیان ژن مورد

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

مازندران در شمال ایران و در کرانه‌های جنوبی دریای خزر واقع است. این استان با مساحتی بالغ بر ۲۳۷۵۶/۴ کیلومتر مربع ۱/۴۶ درصد مساحت کل کشور را شامل می‌شود. استان مذکور بین ۳۵ درجه و ۴۷ دقیقه تا ۳۸ درجه و ۵ دقیقه عرض شمالی ۵۰ درجه و ۳۲ دقیقه تا ۵۶ درجه و ۱۴ دقیقه طول شرقی از نصف‌النهار گرینویچ قرار گرفته است حد شمالی آن دریای مازندران (دریای خزر) و کشور ترکمنستان حد جنوبی آن استان تهران و استان سمنان حد غربی آن استان گیلان و حد شرقی آن استان خراسان می‌باشد. هوای مازندران معتدل و مرطوب است و بادهایی که از نواحی غربی می‌وزد باعث برودت و سردی هوا گشته و گاهی موجب ریزش برف می‌گردد. میانگین بارندگی سالیانه در نوار ساحلی استان برابر با ۹۷۷ میلی‌متر است. توزیع مکانی آن از غرب به شرق با کاهش همراه است درحالی‌که توزیع زمانی آن وضعیتی کمابیش منظم دارد که حداکثر بارندگی در پائیز و حداقل آن در بهار اتفاق می‌افتد. در شکل ۱ موقعیت جغرافیایی و نقشه حوضه آبریز منطقه مورد مطالعه نشان داده شده است. در این پژوهش داده‌های پارامترهای کیفی در مقیاس زمانی ماهانه شامل هیدروژن کربنات (HCO_3)، کلرید (Cl)، سولفات (So_4)، منیزیم (mg)، کلسیم (ca) و سختی آب (TH) همگی بر حسب ppm و مربوط به پیژومترهای دشت مازندران از سال ۱۳۷۳ تا ۱۳۹۳ که از شرکت آب منطقه‌ای استان مازندران اخذ گردید، استفاده شد. در جدول ۱ خصوصیات آماری پارامترهای کیفی مورد بررسی در بازه زمانی مذکور نشان داده شده است. جدول ۲ نیز ماتریس همبستگی بین میزان سختی آب و پارامترهای ورودی را نشان می‌دهد بر اساس جدول مذکور، کلسیم و منیزیم بیشترین و هیدروژن کربنات کمترین همبستگی را با میزان سختی آب دارند هم‌چنین نتایج معنی‌دار بودن پارامترهای موثر بر میزان شوری آب در سطوح احتمال ۵ و ۱۰ درصد نشان داد، همبستگی تمام پارامترها به جز سولفات و کلرید با TH در هر دو سطح احتمال، معنی‌دار است. از این داده‌ها ۸۰ درصد (۱۹۲ رکورد)، به منظور آموزش مدل‌ها و ۲۰ درصد باقی‌مانده (۴۸ رکورد)، جهت صحت‌سنجی انتخاب گردید.

پژوهشی جهت تخمین میزان شوری آب زیرزمینی دشت نرم‌آب استان گلستان از شبکه عصبی مصنوعی استفاده نمود و نتایج حاصله نشان‌دهنده کارایی مناسب و دقت قابل قبول شبکه‌های عصبی مصنوعی در پیش‌بینی میزان شوری است [۲]. از سوی دیگر غلامی و همکاران دو روش شبکه عصبی مصنوعی و رگرسیون چند متغیره را جهت شبیه‌سازی شوری آب زیرزمینی در سواحل استان مازندران مورد بررسی قرار داده و نشان دادند کارایی روش شبکه عصبی مصنوعی در برآورد شوری آب زیرزمینی بیش‌تر از رگرسیون چند متغیره است [۶]. ماریر و دندی در مطالعه‌ای میزان شوری رودخانه ماری را با استفاده از شبکه عصبی تخمین زدند و به این نتیجه رسیدند که مدل شبکه عصبی و شبکه‌های انتشار برگشتی ابزاری دقیق در تخمین میزان افت کیفیت این رودخانه بوده است [۱۴]. هم‌چنین سینگ و همکاران مدل شبکه عصبی را برای تخمین میزان غلظت اکسیژن محلول و اکسیژن خواهی بیوشیمیایی بر اساس ۱۱ پارامتر کیفی ماهانه آب در ایستگاه‌های مختلف هند توسعه داد. نتایج حاصل از این تحقیق نشان داد مدل شبکه عصبی مصنوعی تطبیق خوبی با مقادیر اندازه‌گیری شده و مورد انتظار برای غلظت‌های رودخانه دارد [۱۸]. در پژوهشی دیگر نجاح و همکاران با استفاده از شبکه‌های عصبی به تخمین مواد جامد محلول، هدایت الکتریکی و کدورت رودخانه جوهور در مالزی پرداختند و نشان دادند که مدل‌های شبکه عصبی توانایی بالایی برای تخمین پارامترهای کیفی دارد [۱۵]. در مجموع با توجه به پژوهش‌های انجام شده و ذکر این نکته که دشت مازندران یکی از مهم‌ترین دشت‌ها در شمال کشور و مهم‌ترین منبع تأمین‌کننده آب بخش‌های مختلف نواحی مجاور خود می‌باشد، اهمیت مدل‌سازی کیفیت آب زیرزمینی این دشت و اقدامات مدیریتی جهت بهبود کیفیت آب آن بسیار ضروری است. لذا هدف از این تحقیق تخمین میزان سختی آب زیرزمینی دشت مازندران با استفاده از برنامه‌ریزی بیان ژن و مقایسه نتایج آن با سایر روش‌های هوشمند همچون شبکه عصبی مصنوعی و سیستم استنتاج فازی-عصبی تطبیقی می‌باشد.



شکل ۱. موقعیت محدوده مطالعاتی

جدول ۱. مشخصات آماری پارامترهای کیفی دشت مازندران

چولگی	ضریب تغییرات	حداکثر	حداقل	میانگین	نمونه تعداد ثبت شده	واحد	پارامتر	مرحله
۱/۴۴۲	۰/۲۶۲	۱/۷۸۰	۱۷/۵۰۰	۳/۲۰۰	۶/۷۹۱	۱۹۲	ppm	HCO ₃
۲/۷۰۱	۱/۳۰۱	۳/۹۳۵	۲۲	۰/۴۰۰	۳/۰۲۴	۱۹۲	ppm	Cl
۱/۹۳۸	۰/۸۲۶	۱/۹۵۰	۱۰	۰/۳۰۰	۲/۳۶۰	۱۹۲	ppm	So ₄
۰/۶۸۰	۰/۳۱۶	۱/۰۲۷	۶/۹۰۰	۱/۲۰۰	۳/۲۵۰	۱۹۲	ppm	Mg
۰/۵۸۰	۰/۲۹۶	۱/۳۷۵	۹/۳۰۰	۱/۶۰۰	۴/۶۴۰	۱۹۲	ppm	Ca
۰/۵۶۵	۰/۲۷۴	۱۰۸/۴۲۵	۸۰۵	۱۶۰	۳۹۵/۵۶۰	۱۹۲	ppm	Th
-۰/۰۲۲	۰/۲۵۷	۱/۷۱۵	۱۰/۵۰۰	۳	۶/۶۵۰	۴۸	ppm	HCO ₃
۳/۲۱۷	۱/۷۳۶	۵/۲۸۰	۲۴/۷۰۰	۰/۴۰۰	۳/۰۴۰	۴۸	ppm	Cl
۱/۱۳۲	۰/۴۷۲	۱/۰۵۰	۵/۹۰۰	۰/۴۰۰	۲/۲۲۰	۴۸	ppm	So ₄
۱/۹۷۳	۰/۳۶۲	۱/۳۲۸	۹/۳۰۰	۱/۸۰۰	۳/۶۶۰	۴۸	ppm	Mg
۰/۲۷۶	۰/۳۶۶	۱/۸۹۰	۹/۲۰۰	۱/۲۰۰	۵/۱۵۰	۴۸	ppm	Ca
۱/۴۶۳	۰/۳۳۳	۱۴۴/۹۳۰	۹۲۵	۲۴۰	۴۳۴/۴۸۰	۴۸	ppm	Th

جدول ۲. ماتریس همبستگی پارامترهای موثر بر سختی آب زیرزمینی

Th	Ca	Mg	Cl	Hco3	So4	
۰/۴۰۴	۰/۳۵۴	۰/۴۱۲	۰/۳۶۸	۰/۰۹۴	۱	So4
۰/۳۸۷	۰/۴۰۶	۰/۳۵۴	۰/۰۷۷	۱	۰/۰۹۴	Hco3
۰/۴۱۲	۰/۳۳۹	۰/۴۲۲	۱	۰/۰۷۷	۰/۳۶۸	Cl
۰/۷۴	۰/۴۹۸	۱	۰/۴۲۲	۰/۳۵۴	۰/۴۱۲	Mg
۰/۷۵۸	۱	۰/۴۹۸	۰/۳۳۹	۰/۴۰۶	۰/۳۵۴	Ca
۱	۰/۷۵۸	۰/۷۴	۰/۴۱۲	۰/۳۸۷	۰/۴۰۴	Th

۲-۲- شبکه عصبی مصنوعی

امروزه شبکه عصبی مصنوعی در مطالعات هیدرولوژی و مدیریت منابع آب کاربرد وسیعی دارد [۱۷]. ساختار شبکه عصبی معمولاً از لایه ورودی، لایه میانی و لایه خروجی تشکیل شده است. لایه ورودی یک لایه انتقال دهنده و وسیله‌ای برای تهیه کردن داده‌ها، لایه خروجی شامل مقادیر پیش‌بینی شده توسط شبکه و لایه میانی یا مخفی که از گره‌های پردازشگر تشکیل شده‌اند، محل پردازش داده‌ها است. نخستین کاربرد عملی شبکه‌های عصبی مصنوعی با معرفی شبکه‌های پرسپترون چند لایه^۱ انجام گرفت. در این شبکه‌ها ثابت شده است که از میان الگوریتم‌های یادگیری، الگوریتم پس انتشار خطا^۲ با ساختار شبکه پیش‌خور^۳ و تعداد سه لایه بطور رضایت بخشی در حل مسائل پیچیده مهندسی، شبیه‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی کاربرد دارد [۱۲، ۱۰، ۱۶]. از رایج ترین توابع محرک استفاده شده در شبکه‌های انتشار برگشتی می‌توان توابع محرک سیگموئید و تانژانت هیپربولیک ذکر کرد [۱۹]. نمونه‌ایی از ساختار شبکه سه لایه‌ای متشکل از یک لایه ورودی، یک لایه مخفی، و یک لایه خروجی در شکل ۲ نشان داده شده است.

۲-۳- برنامه‌ریزی ژنتیک

روش برنامه‌ریزی بیان ژن، در سال ۱۹۹۹ توسط فریرا ارائه شد. این روش ترکیبی از روش‌های برنامه‌ریزی ژنتیک (GP) و الگوریتم ژنتیک بوده (GA) که در آن، کروموزوم‌های خطی و ساده با طول ثابت، مشابه با آنچه که در الگوریتم ژنتیک استفاده می‌شود. در این روش پدیده‌های مختلف با استفاده از مجموعه‌ای از توابع و مجموعه‌ای از ترمینال‌ها، مدل‌سازی می‌شوند. مجموعه توابع، معمولاً شامل توابع اصلی حسابی {+, -, x, /}، توابع مثلثاتی یا هر نوع تابع ریاضی دیگر {√, x2, exp, log, sin, cos, ...} و یا توابع تعریف شده توسط کاربر است که معتقد است، می‌تواند برای تفسیر مدل مناسب باشند. مجموعه ترمینال‌ها، از مقادیر ثابت و متغیرهای مستقل مسأله تشکیل شده‌اند. برای به کارگیری روش برنامه‌ریزی بیان ژن از نرم‌افزار

GenXproTools 4.0 استفاده گردید. جهت کسب اطلاعات بیش‌تر می‌توان به [۱۱] مراجعه نمود.

۲-۴- سیستم استنتاج فازی_عصبی تطبیقی

سامانه استنتاج عصبی-فازی تطبیقی، یک روش نوین در حل مسایل پیچیده‌ای است که یا الگوریتم مشخصی برای حل آن‌ها وجود ندارد و یا استفاده از روش‌های متعارف مستلزم به کارگیری راه حل‌های بسیار طولانی و زمان‌بر می‌باشد. یکی از قابلیت‌های مهم سامانه استنتاج عصبی-فازی تطبیقی درک رفتار غیرخطی یک سیستم می‌باشد. این روش در سال‌های اخیر در مسایل مختلف مدیریت منابع آب و خاک مورد استفاده قرار گرفته است [۱ و ۷].

سیستم فازی - عصبی یک سیستم فازی سوگنو را در یک ساختار عصبی اجرا می‌کند. این سیستم برای فرآیند آموزش با ترکیبی از روش‌های آموزش پس انتشار خطا و کمینه مربعات خطا بهره‌گیری می‌کند. برای یک مدل فازی سوگنو می‌توان یک مجموعه قانون نمونه را با دو قانون اگر - آنگاه فازی به صورت زیر بیان کرد [۹]:

قانون اول: اگر x برابر A_1 و y برابر B_1 باشد آنگاه

$$z_1 = p_1x + q_1y + r_1$$

قانون دوم: اگر x برابر A_2 و y برابر B_2 باشد آنگاه

$$z_2 = p_2x + q_2y + r_2$$

که p_i ، q_i و r_i ($i=1, 2$) پارامترهای خطی تالی مدل سیستم استنتاج فازی_عصبی تطبیقی تاکاگی- سوگنو درجه اول هستند. یک نمونه طراحی شده از مدل تطبیقی عصبی-سیستم استنتاج فازی_عصبی تطبیقی در شکل ۳ آورده شده است.

۲-۵- معیارهای ارزیابی

در این تحقیق ارزیابی دقت و قابلیت مدل‌ها جهت شبیه‌سازی سختی آب زیرزمینی بر اساس مقادیر مشاهداتی و محاسباتی با استفاده از نمایه‌های ضریب همبستگی (CC)، ریشه میانگین مربعات خطا (RMSE)، میانگین قدرمطلق خطا (MAE) و نش ساتکلیف (NS) طبق روابط ۱، ۲، ۳ و ۴ صورت می‌گیرد. بهترین مقدار برای این چهار معیار به ترتیب یک، صفر، صفر و یک می‌باشد.

¹ Multi-Layer Perceptron

² Back Propagation (BP)

³ Feed Forward


در روابط بالا، CC ضریب همبستگی، RMSE ریشه میانگین مربعات خطا بر حسب NS، ppm معیار نش سائکلیف، x_i و y_i به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی i ام، N تعداد گام های زمانی، \bar{x} و \bar{y} نیز به ترتیب میانگین مقادیر مشاهداتی و محاسباتی می‌باشد. علاوه بر معیارهای فوق از نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی- محاسباتی نسبت به زمان نیز جهت مقایسه و تحلیل بیش‌تر استفاده می‌گردد.

$$CC = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad 1 \leq R \leq 1 \quad \text{رابطه ۱}$$


$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad \text{رابطه ۲}$$

$$MAE = \frac{\sum_{i=1}^N |x_i - y_i|}{n} \quad \text{رابطه ۳}$$

$$NS = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{x})^2} \quad \infty \leq NS \leq 1 \quad \text{رابطه ۴}$$



شکل ۲. نمای کلی یک شبکه عصبی مصنوعی سه لایه



شکل ۳. معماری کلی مدل تطبیقی عصبی - سیستم استنتاج فازی عصبی تطبیقی

۳- نتایج و بحث

تصادفی بوده و انتخاب بازه زمانی خاص خود بخود در همه زمان‌ها در فرایند آموزش و صحت‌سنجی لحاظ گردیده است. یک نکته مهم در آموزش شبکه‌های عصبی نرمال‌سازی داده‌ها قبل از استفاده در مدل می‌باشد این عمل خصوصا وقتی دامنه تغییرات ورودی‌ها زیاد باشد کمک شایانی به آموزش بهتر و سریع‌تر مدل می‌کند. اصولا وارد کردن داده‌ها بصورت خام باعث کاهش سرعت و دقت شبکه می‌شود. هم‌چنین جهت تسهیل در آموزش شبکه و نیز تعمیم شبکه برای ورود داده‌ها به شبکه‌های هوش مصنوعی لازم است داده‌های مدنظر در بازه [۱ و ۰] قرار گیرند بنابراین با توجه به پژوهش‌های [۸ و ۲۰] برای نرمال‌سازی داده‌های تحقیق از رابطه ۵ استفاده شده است.

در این تحقیق به منظور بررسی نتایج مدل از داده‌های کیفیت آب زیرزمینی دشت مازندران در طول دوره آماری از سال ۱۳۷۳ تا سال ۱۳۹۳ در مقیاس زمانی ماهانه استفاده گردید. پارامترهای هیدروژن کربنات (HCO3)، کلرید (Cl)، سولفات (So4)، منیزیم (mg) و کلسیم (ca) به عنوان ورودی و سختی آب (TH) به عنوان پارامتر خروجی مدل بکار برده شد. در ادامه نتایج مدل مورد استفاده ارائه می‌گردد. همان‌طور که قبلا نیز اشاره شد ۸۰ درصد از داده‌ها (۱۹۲ رکورد)، به منظور آموزش و ۲۰ درصد مابقی (۴۸ رکورد)، به منظور صحت‌سنجی انتخاب گردید. با توجه به نمونه‌برداری در زمان‌های مختلف، داده‌های مورد استفاده ماهیتا دارای رفتار

گردید. تعداد تکرارهای لازم در فرآیند یادگیری شبکه ۱۰۰۰ در نظر گرفته شده و عملکرد شبکه به کمک معیار میانگین مربعات خطا مورد ارزیابی قرار گرفته است. تعداد نرون‌های موجود در لایه‌های ورودی و خروجی با توجه به ماهیت مساله مورد بررسی مشخص شده، حال آن که تعداد نرون‌های موجود در لایه پنهان با سعی و خطا در جهت کاهش مقدار خطا مشخص گردید. روند کار با تعداد نرون‌های کم آغاز و افزودن نرون‌های اضافی تا زمانی ادامه می‌یابد که افزایش نرون‌های بیش‌تر تاثیری در بهبود خطا نداشته باشد، که شبکه‌ای با ۲ نرون در لایه پنهان اول به عنوان بهترین شبکه در فرآیند مدل‌سازی حاصل شد. در جدول ۳ نتایج حاصل از مقایسه عملکرد ساختارهای مختلف به کار رفته به همراه پارامترهای آماری داده‌های بخش آموزش و صحت‌سنجی ارائه شده است.

$$X_n = 0.1 + 0.8 \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad \text{رابطه ۵}$$

که در آن X_n مقدار نرمال شده ورودی X_i و X_{\max} و X_{\min} به ترتیب حداکثر و حداقل داده‌ها می‌باشد.

۳-۱- نتایج شبکه عصبی مصنوعی

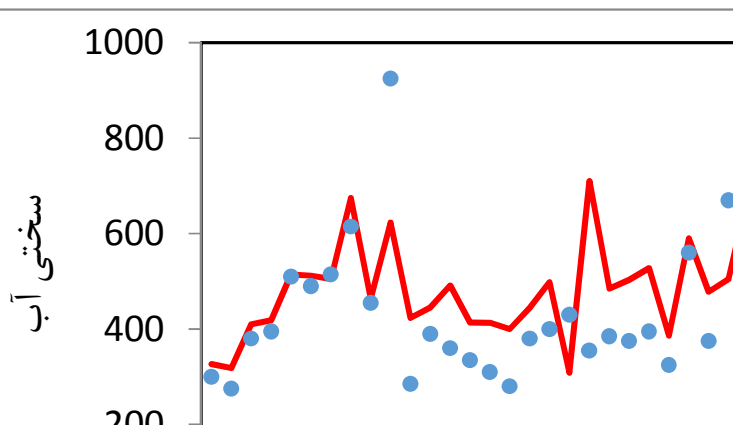
به منظور مدل‌سازی میزان سختی آب زیرزمینی از مدل شبکه عصبی مصنوعی از نوع شبکه پرسپترون چند لایه با تعداد نرون‌های متفاوت استفاده شده است. تابع تانژانت هیپربولیک متداول‌ترین شکل از توابع محرک است، که در این تحقیق از آن برای ساخت لایه خروجی شبکه‌های عصبی مصنوعی استفاده گردید. برای آموزش شبکه‌های پرسپترون چند لایه از الگوریتم آموزش پس انتشار خطا بنام الگوریتم لونیبرگ - مارکواریت به دلیل همگرایی سریع‌تر در آموزش شبکه، استفاده شد. هم‌چنین از ترکیبات مختلف توابع محرک در لایه مخفی استفاده

جدول ۳. ساختار و توابع محرک بهینه در مدل‌سازی شبکه‌های عصبی مصنوعی و شاخص‌های آماری در مراحل آموزش و صحت‌سنجی

شماره	ساختار	تابع محرک		آموزش				صحت سنجی			
		لایه پنهان	لایه خروجی	NS	RMSE (ppm)	MAE (ppm)	CC	NS	RMSE (ppm)	MAE (ppm)	CC
۱	۴-۲-۱	تانژانت هیپربولیک	خطی	۰/۸۱۰	۰/۲۳۶	۰/۱۱۵	۰/۸۵۰	۰/۸۴۶	۰/۳۴۴	۰/۱۶۵	۰/۹۳۰
۲	۴-۳-۱	تانژانت هیپربولیک	خطی	۰/۸۰۹	۰/۶۱۰	۰/۳۰۱	۰/۸۳۰	۰/۷۷۱	۰/۹۵۸	۰/۴۵۶	۰/۹۰۲
۳	۴-۴-۱	تانژانت هیپربولیک	خطی	۰/۷۹۰	۰/۶۵۵	۰/۳۲۴	۰/۸۳۶	۰/۷۴۰	۰/۴۷۰	۰/۲۲۱	۰/۹۱۰
۴	۴-۵-۱	تانژانت هیپربولیک	خطی	۰/۶۳۰	۰/۳۲۰	۰/۱۵۴	۰/۸۴۰	۰/۸۳۰	۰/۴۶۵	۰/۲۱۸	۰/۸۴۹
۵	۴-۶-۱	تانژانت هیپربولیک	خطی	۰/۷۴۲	۰/۴۲۸	۰/۲۲۰	۰/۸۳۶	۰/۷۹۲	۰/۶۶۴	۰/۳۳۶	۰/۸۹۰
۶	۴-۸-۱	تانژانت هیپربولیک	خطی	۰/۷۳۵	۰/۳۱۵	۰/۱۵۴	۰/۸۲۷	۰/۸۲۰	۰/۷۸۵	۰/۳۵۲	۰/۸۹۱
۷	۴-۱۰-۱	تانژانت هیپربولیک	خطی	۰/۷۴۸	۰/۲۸۶	۰/۱۴۲	۰/۸۳۷	۰/۷۸۱	۰/۴۳۵	۰/۲۱۸	۰/۸۲۰
۸	۴-۱۱-۱	تانژانت هیپربولیک	خطی	۰/۷۹۰	۰/۲۶۱	۰/۱۳۵	۰/۸۳۰	۰/۸۳۱	۰/۷۱۰	۰/۳۰۱	۰/۸۸۶
۹	۴-۱۲-۱	تانژانت هیپربولیک	خطی	۰/۷۸۲	۰/۲۵۰	۰/۱۲۰	۰/۸۲۵	۰/۷۹۵	۰/۵۲۰	۰/۲۲۶	۰/۸۹۵
۱۰	۴-۱۴-۱	تانژانت هیپربولیک	خطی	۰/۸۱۴	۰/۲۷۲	۰/۱۴۶	۰/۸۳۵	۰/۸۲۰	۰/۹۳۳	۰/۴۳۸	۰/۸۸۴
۱۱	۴-۱۶-۱	تانژانت هیپربولیک	خطی	۰/۸۰۰	۰/۳۵۵	۰/۱۶۸	۰/۸۳۲	۰/۸۲۷	۰/۸۶۱	۰/۴۰۷	۰/۸۹۵

اکثر نقاط با اختلاف کمی نسبت به مقادیر واقعی تخمین زده شده است. همانطور که در شکل ۴ مشاهده می‌شود مدل شبکه عصبی مصنوعی در تخمین نقاط حداقل عملکرد قابل قبولی نداشته است به گونه‌ای که این مقادیر را با خطای زیادی تخمین زده است و در تبیین آن می‌توان بیان نمود میزان خطای محاسباتی آن ممکن است به دلیل تغییرات ناگهانی شرایط و به دنبال آن وابستگی کم داده‌ها به ماه‌های قبل خود باشد.

همانطور که در جدول ۳ مشاهده می‌شود ساختار شماره ۱ با ضریب نش ساتکلیف $NS = 0/846$ ، جذر میانگین مربع خطا $RMSE = 0/344$ ، میانگین قدر مطلق خطا ppm $MAE = 0/165$ و ضریب همبستگی $CC = 0/930$ در مرحله صحت‌سنجی نسبت به سایر ساختارها جهت مدل‌سازی میزان سختی آب زیرزمینی مناسب‌تر خواهد بود. در شکل ۴ نمودار بهترین مدل حاصل شده برای داده‌های بخش صحت‌سنجی نشان داده شده است. همان طور که از شکل ۴ مشخص است مقادیر تخمینی و در



شکل ۴. نمودار حاصل از مقادیر بهینه محاسباتی و مشاهداتی مدل شبکه عصبی مصنوعی برای داده‌های ثبت شده مرحله صحت‌سنجی

۳-۲- نتایج برنامه‌ریزی بیان ژن

استفاده از برنامه‌ریزی بیان ژن به دلیل توان انتخاب متغیرهای مؤثر در مدل و حذف متغیرهایی با تأثیر کمتر و هم‌چنین توانایی ارائه رابطه صریح جهت تخمین سختی آب زیرزمینی مازندران مدنظر قرار گرفت. لذا هر چهار ورودی برای تعیین متغیرهای معنی‌دار استفاده، و جهت بررسی بیش‌تر علاوه بر مجموعه چهار عملگر اصلی (F1)، حالت‌هایی بر اساس عملگرهای ریاضی پیش فرض برنامه (F2)، و مجموعه عملگر F3 لحاظ گردیده است. نحوه و دلیل انتخاب این نوع عملگرها با توجه به مطالعات [۱۱] و [۱۳] صورت گرفته است.

رابطه ۶ $F1: \{+, -, *, /\}$

رابطه ۷ $F2: \{+, -, *, /, \sqrt{\quad}, \text{Exp}, \text{Ln}, ^2, ^3, \sqrt[3]{\quad}, \text{Sin}, \text{Cos}, \text{Atan}\}$

رابطه ۸ $F3: \{+, -, *, /, \sqrt{\quad}, \text{Exp}, \text{Ln}, ^2\}$

پارامترهای مورد استفاده و نرخ آن‌ها در استخراج مدل‌های تخمین سختی آب با استفاده از روش برنامه‌ریزی بیان ژن که با توجه به پژوهش [۱۱] استخراج گردید، به طور خلاصه در جدول ۴ ارائه گردیده است. روابط نهایی حاصل از سه مجموعه از عملگرهای ریاضی تعریف شده برای دشت مازندران در جدول ۵، میزان تأثیر هریک از پارامترهای ورودی را روی میزان سختی نشان می‌دهد، با توجه به این روابط سدیم، کلرید و هیدروژن کربنات بیش‌ترین تأثیر در تخمین سختی را داشته‌اند.

نتایج حاصل از مدل برنامه‌ریزی بیان ژن با هر سه عملگر در جدول ۶ بیانگر این است که عملگر F1 در هر دو مرحله آموزش و صحت‌سنجی با بیش‌ترین ضریب

همبستگی $CC=0/960$ و ریشه میانگین مربعات خطا $RMSE=0/112$ ppm، میانگین قدر مطلق خطا ppm $MAE = 0/171$ و $NS=0/880$ نسبت به سایر عملگرها از دقت بیش‌تری برخوردار بوده است. بنابراین برنامه‌ریزی بیان ژن با عملگر F1 شامل چهار عملگر اصلی ریاضی، با وجود رابطه ساده ریاضی بیش‌ترین دقت را در تخمین سختی آب زیرزمینی دشت مازندران داشته است. نمودار مقادیر بهینه محاسباتی و مشاهداتی برنامه‌ریزی بیان ژن مربوط به مرحله صحت‌سنجی در شکل ۵ نشان داده شده است. همانطور که از شکل مشخص است مدل برنامه‌ریزی ژن در تخمین اکثر نقاط دقت قابل قبولی داشته است بطوری‌که مقادیر محاسباتی را نزدیک به مقدار مشاهداتی تخمین زده است.

۳-۳- نتایج مدل سیستم استنتاج فازی_عصبی تطبیقی

در این پژوهش برای ایجاد مدل ANFIS، در گام اول ابتدا بهترین ساختار مدل استنتاج فازی تعیین گردید. در نظر گرفتن متغیرهای مختلف و پارامترهای مؤثر دیگر (بررسی و انتخاب روش غیر فازی‌سازی، شکل توابع عضویت، روش استلزام و انبوهش و غیره) بصورت همزمان جهت یافتن بهترین و مناسب‌ترین مدل صورت می‌گیرد. بنابراین جهت دستیابی آسان به دقیق‌ترین مدل، ابتدا با در نظر گرفتن یک متغیر ورودی (هیدروژن کربنات، سولفات، کلسیم، منیزیم) بهترین ساختار مدل فازی را مشخص نموده و سپس تأثیر تعداد و نوع متغیر ورودی، مورد بررسی قرار گرفته است. دقیق‌ترین ساختار مدل استنتاجی بر اساس معیار کارایی و خطا به صورت زیر می‌باشد.

جذر میانگین مربع خطا $RMSE = 0.224$ ppm، میانگین قدر مطلق خطا $MAE = 0.130$ ppm و ضریب همبستگی $CC = 0.850$ در مرحله صحت‌سنجی نسبت به سایر ساختارها جهت مدل‌سازی میزان سختی آب زیرزمینی مناسب‌تر خواهد بود. در شکل ۶ نمودار بهترین مدل حاصل شده برای داده‌های بخش صحت‌سنجی نشان داده شده است. همان‌طور که از شکل ۶ مشخص است مقادیر تخمینی و در اکثر نقاط با اختلاف زیادی نسبت به مقادیر واقعی تخمین زده شده است.

شکل توابع عضویت مثلثی بوده و برای استلزام و انبوهش به ترتیب استفاده از روش‌های حداقل و حداکثر دقیق‌تر می‌باشد. از طرفی روش مرکز جرم برای غیر فازی‌ساز برگزیده شد. همان‌طور که در بالا اشاره گردید پس از انتخاب بهترین مدل استنتاجی جهت تخمین سختی آب زیرزمینی در مقیاس‌های زمانی ماهانه به بررسی اثرات مختلف پارامترهای موثر پرداخته شده است. همان‌طور که در جدول ۷ مشاهده می‌شود مدل سیستم استنتاج فازی_عصبی تطبیقی با ضریب نش ساتکلیف $NS = 0.872$

جدول ۴. مقادیر پارامترهای مورد استفاده با استفاده از روش برنامه‌ریزی بیان ژن

عملگرهای ژنتیکی	تنظیمات کلی
۰/۰۴۴	تعداد کروموزوم ها
۰/۱	اندازه راس
۰/۱	تعداد ژن ها در هر کروموزوم
۰/۱	تعداد جمعیت تولیدی
۰/۳	تابع پیوند
۰/۳	تابع برازش
۰/۱	معیار خطا
۰/۱	نرخ ترانهش ژن
۰/۱	نرخ ترکیب تک نقطه ایی
۰/۳	نرخ ترکیب دو نقطه ایی
۰/۱	نرخ ترکیب ژن
۰/۱	نرخ ترانهش ژن

جدول ۵. معادلات برنامه‌ریزی بیان ژن برای سه مجموعه عملگر ریاضی منتخب


عملگر	معادلات برنامه‌ریزی بیان ژن
F ₁	$TH = 60.51(so_4 + Hco_3) + Na(5.04Mg - Na) - (Ca + Hco_3) - 8.69 + Cl^2(Cl)$
F ₂	$TH = \left(\frac{Na + Cl}{N_2}\right) + 61.55So_4 + (71.31 + Cl)Hco_3 + (Cl + 7.46)^{0.5}(Cl)Cl^2$
F ₃	$TH = \left(\frac{Hco_3}{C_H}\right) (4.93Cl + 24.3)So_4 + (4.71 Ca Cl Mg) - Ca - Na + (Hco_3 + Ca)45.56 + 2Cl$

جدول ۶. نتایج مدل برنامه‌ریزی بیان ژن با استفاده از سه مجموعه عملگر ریاضی منتخب


عملگر	آموزش				صحت سنجی			
	NS	RMSE (ppm)	MAE (ppm)	CC	NS	RMSE (ppm)	MAE (ppm)	CC
F ₁	۰/۸۴۰	۰/۲۲۰	۰/۱۳۲	۰/۹۹۰	۰/۸۸۰	۰/۱۱۲	۰/۱۷۱	۰/۹۶۰
F ₂	۰/۸۳۲	۰/۲۲۵	۰/۱۴۱	۰/۹۸۰	۰/۸۶۰	۰/۲۸۰	۰/۱۸۵	۰/۹۵۰
F ₃	۰/۸۲۰	۰/۲۴۰	۰/۱۵۲	۰/۹۶۵	۰/۸۷۰	۰/۳۴۰	۰/۲۱۰	۰/۹۴۰

جدول ۷. نتایج شاخص‌های آماری در مراحل آموزش و صحت‌سنجی در مدل سیستم استنتاج فازی_عصبی تطبیقی

CC	صحت سنجی			آموزش		
	MAE (ppm)	RMSE (ppm)	NS	MAE (ppm)	RMSE (ppm)	NS
۰/۸۵۰	۰/۱۳۰	۰/۲۲۴	۰/۸۷۲	۰/۱۶۴	۰/۳۲۰	۰/۷۵۰
۰/۶۶۰	۰/۲۲۴	۰/۸۷۲	۰/۶۶۰	۰/۱۶۴	۰/۳۲۰	۰/۷۵۰



شکل ۵. نمودار حاصل از مقادیر بهینه محاسباتی و مشاهداتی مدل برنامه‌ریزی ژن برای داده‌های ثبت شده مرحله صحت‌سنجی



شکل ۶. نمودار حاصل از مقادیر بهینه محاسباتی و مشاهداتی مدل سیستم استنتاج فازی_عصبی تطبیقی برای داده‌های ثبت شده مرحله صحت‌سنجی


مقادیر سختی آب زیرزمینی دارد همانطور که در این شکل مشخص است مدل برنامه‌ریزی بیان ژن اکثر مقادیر را نزدیک به مقدار واقعی تخمین زده است. در نهایت اختلاف مقادیر مشاهداتی میزان سختی آب زیرزمینی و محاسباتی بهینه مدل‌ها به صورت درصدی از میانگین مقادیر مشاهداتی (مقدار خطا)، محاسبه و نمودار آن نسبت به نمونه داده‌های ثبت شده دوره آماری ترسیم گردید (شکل ۸). همانطور که در این شکل دیده می‌شود برای هر سه مدل بیش‌تر خطاها در باند ± 100 درصد قرار گرفته است. که در میان مدل‌های مذکور (شبکه عصبی مصنوعی، سیستم استنتاج فازی_عصبی تطبیقی و برنامه‌ریزی بیان ژن)، برنامه‌ریزی بیان ژن کمترین میزان خطا را داشته است. در مجموع با توجه به دقت و قابلیت تخمین بالا مدل‌های شبکه عصبی مصنوعی، سیستم استنتاج فازی_عصبی تطبیقی و برنامه‌ریزی بیان ژن

۳-۴- مقایسه عملکرد مدل‌ها

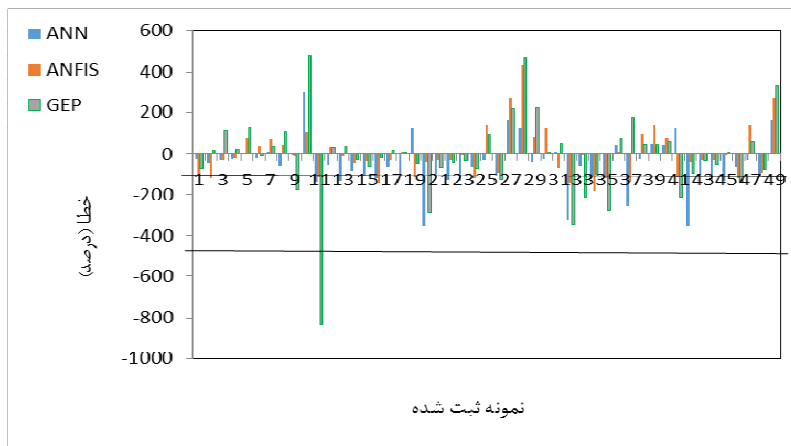
در ادامه با انتخاب جواب بهینه هر کدام از مدل‌ها و مقایسه آن‌ها با یکدیگر مشخص شد، هر سه روش با دقت خوبی می‌توانند میزان سختی آب زیرزمینی را شبیه‌سازی کنند. همانطور که در جدول ۷ مشاهده می‌شود از بین مدل‌های به کار رفته مدل برنامه‌ریزی بیان ژن دارای بیش‌ترین ضریب همبستگی (۰/۹۶۰)، کمترین ریشه میانگین مربعات خطا (۰/۱۱۲ ppm)، میانگین قدر مطلق خطا $MAE = 0/171$ ppm و نش ساتکلیف (۰/۸۸۰) در مرحله صحت‌سنجی در اولویت قرار گرفت. در شکل ۷ نتایج هر سه مدل نسبت به مقادیر مشاهداتی در طی زمان نشان داده شده است. مدل برنامه‌ریزی بیان ژن دقت بالاتری نسبت به مدل شبکه عصبی مصنوعی و سیستم استنتاج فازی_عصبی تطبیقی در تخمین میزان

مصنوعی، سیستم استنتاج فازی_عصبی تطبیقی و برنامه‌ریزی بیان ژن در سطوح احتمال ۵ و ۱۰ درصد نشان داد، مدل برنامه‌ریزی بیان ژن همبستگی معنی‌داری در هر دو سطح احتمال دارد.

همبستگی بین مقادیر مشاهداتی و مقادیر محاسباتی مدل‌های مذکور بررسی شده که به ترتیب ۰/۹۲۱، ۰/۸۵۶ و ۰/۹۵۰ می‌باشد. همچنین نتایج معنی‌دار بودن مقادیر مشاهداتی و محاسباتی مدل‌های شبکه عصبی



شکل ۷. نمودار پراکنش و مشاهداتی - محاسباتی مقادیر بهینه مدل شبکه عصبی مصنوعی، سیستم استنتاج فازی-عصبی تطبیقی و برنامه‌ریزی بیان ژن برای داده‌های ثبت شده مرحله صحت‌سنجی



شکل ۸. نمودار خطای بهینه هر سه مدل به صورت درصدی از میانگین مقادیر مشاهداتی

الف- مدل برنامه‌ریزی بیان ژن دقت بالایی جهت تخمین مقادیر کمینه و میانی داشته و در تخمین مقادیر بیشینه عملکرد ضعیفی داشته و دارای میزان خطای کمتری در تخمین مقادیر مشاهداتی می‌باشد و مدل حاصل از مجموعه عملگر ریاضی یک با وجود رابطه ساده ریاضی دقت قابل قبولی دارد.

ب- مدل سیستم استنتاج فازی_عصبی تطبیقی قابلیت خوبی در تخمین مقادیر میانی داشته در حالی‌که در برآورد مقادیر کمینه و بیشینه دقت پایینی دارد.

ج- مدل شبکه عصبی تطبیقی قابلیت خوبی در تخمین مقادیر کمینه و بیشینه داشته در حالی‌که در برآورد مقادیر میانی دقت پایینی دارد.

۴- نتیجه‌گیری

در این پژوهش سعی بر آن شد عملکرد مدل‌هایی جهت شبیه‌سازی میزان سختی آب زیرزمینی با استفاده از داده‌های ماهانه دشت مازندران مورد ارزیابی قرار گیرد. مدل‌های به کار گرفته شده شامل شبکه عصبی مصنوعی، سیستم استنتاج فازی_عصبی تطبیقی و برنامه‌ریزی بیان ژن می‌باشد. مقادیر میزان سختی آب زیرزمینی مشاهداتی با میزان سختی آب زیرزمینی تخمین زده شده در مدل‌های مذکور (شبکه عصبی، سیستم استنتاج فازی_عصبی تطبیقی و برنامه‌ریزی بیان ژن)، با استفاده از معیارهای ارزیابی مورد مقایسه قرار گرفت. نتایج تحقیق را می‌توان بصورت زیر خلاصه نمود:

[۸] وانگ، لی، ترجمه تشنه لب، م، صفاریور، ن، افیونی، د (۱۳۸۶) سیستم‌های فازی و کنترل فازی. تهران: دانشگاه صنعتی خواجه نصیرالدین توسی.

- [9] Aqil, M., Kita, I., Yano, A., Nishiyama, S (2007) Analysis and prediction of flow from local source in a river basin using a Neuro-fuzzy modeling tool. *J. Environ. Manage.* 85(1): 215–223.
- [10] ASCE Task Committee on Application of Artificial Neural Networks in Hydrology (2000) *Artificial Neural Networks in Hydrology. I: Preliminary Concepts. J. Hydrol. Eng.*, 5(2): 115–123.
- [11] Ghorbani, M, A., Singh, V, P., Kashani, M., Kashani, A (2012) Modelling pan evaporation using genetic programming. *Journal of Statistics: Advances in Theory and Application*, vol.1-23.
- [12] Hornik, K (1988) Multilayer feed-forward networks are universal approximators. *Neural Networks* 2 (5): 359–366.
- [13] Khatibi, R., Naghipour, L., Ghorbani, M, A., Aalami, M, T (2012) Predictability of relative humidity by two artificial intelligence techniques using noisy data from two Californian gauging stations. *Neural computing and application*, vol. 643-941.
- [14] Maier, H, R., Dandy, G, C (1996) The use of artificial neural networks for the prediction of water quality parameters. *Water Resources Research*, 32(4), 1013-1022.
- [15] Najah, A., Elshafie, A., Karim, O., Jaffar, O (2009) Prediction of Johor river water quality parameters using artificial neural networks. *European Journal of scientific research*. 28: 422-435
- [16] Nourani, V., Kisi, Ö., Komasi, M (2011) Two hybrid artificial intelligence approaches for modeling rainfall-runoff process. *Journal of Hydrology*. 402 (1–2): 41–59.
- [17] Nourani, V., Alami, M, T., Aminfar, M, H (2009) A combined neural-wavelet model for prediction of Ligvanchai watershed precipitation. *Engineering Applications of Artificial Intelligence*. 22(2):466–472.
- [18] Singh, K, P., Basant, A., Malik, A., Jain, G (2009) Artificial neural network modeling of the river water quality-A Case Study. *Journal of Ecological Modeling*. 220: 888-895.
- [19] Tokar, A, s., Johnson, P, A (1999) Rainfall-Runoff modeling using artificial neural
- [20] Zhu, Y, M., Lu, X, X., Zhou, Y (2007) Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjiang River in the Upper Yangtze Catchment. *Geomorphology*, 84: 111-125.

د- مقادیر محاسباتی نسبت به مشاهداتی مدل برنامه‌ریزی بیان ژن نسبت به سایر مدل‌ها در سطوح معنی‌دار همبستگی دارد.

در مجموع نتایج تحقیق نشان داد که روش برنامه‌ریزی بیان ژن دارای دقت بالایی در تخمین سختی آب می‌باشد. همان‌طور که در نتایج تحقیقات [۱۳ و ۱۱] این امر به اثبات رسیده است. هم‌چنین این تحقیق نشان می‌دهد که استفاده از مدل‌های برنامه‌ریزی بیان ژن، سیستم استنتاج فازی_عصبی تطبیقی و شبکه عصبی مصنوعی می‌تواند در زمینه پیش‌بینی میزان سختی آب استفاده شود.

منابع

- [۱] احمدی، ف، آیشم، س، خلیلی، ک، بهمنش، ج (۱۳۹۴) کاربرد سیستم‌های استنتاج عصبی - فازی تطبیقی و برنامه‌ریزی ژنتیک برای برآورد تاخیر تعرق ماهانه در شمال غرب ایران. نشریه پژوهش آب در کشاورزی. ۲۹(۲).
- [۲] تمدنی کناری، س (۱۳۹۱) پیش‌بینی هوشمند شوری آب زیرزمینی با استفاده از شبکه عصبی مصنوعی. دومین کنفرانس برنامه‌ریزی و مدیریت محیط زیست.
- [۳] دربندی، ص، عباسپور، ا، شعبی نوبریان، م، ر (۱۳۹۰) پیش‌بینی جریان ورودی به مخزن سد علویان با استفاده از برنامه‌ریزی ژنتیک. پنجمین کنفرانس سراسری آبخیزداری و مدیریت منابع آب و خاک کشور.
- [۴] رحمانی، غ، ر (۱۳۹۳) شبیه‌سازی منابع آب زیرزمینی دشت عقیلی با استفاده از شبکه‌های عصبی مصنوعی و مقایسه آن با نتایج مدل ریاضی تفاضلات محدود. پایان نامه کارشناسی ارشد، دانشگاه شهید چمران اهواز.
- [۵] زمانی احمد محمودی، ر (۱۳۹۱) بررسی کاربرد روش ترکیبی زمین آمار و شبکه‌های عصبی بهینه شده با الگوریتم ژنتیک در میان‌یابی سطح آب زیرزمینی دشت. پایان‌نامه کارشناسی ارشد، دانشگاه شهید چمران اهواز، گروه مهندسی منابع آب.
- [۶] غلامی، و، درخشان، ش، درواری، ز (۱۳۹۱) بررسی روش رگرسیون چند متغیره و شبکه عصبی مصنوعی در شبیه سازی شوری آب زیرزمینی سواحل استان مازندران. نشریه پژوهش آب در کشاورزی. جلد ۲۶. شماره ۳.
- [۷] نحوی نیا، م، ج، لیاقت، ع، پارسی نژاد، م (۱۳۸۹) کاربرد مدل‌های تجربی و آماری در پیش‌بینی میزان نفوذ آب در آبیاری جویچه‌ای. نشریه آب و خاک. ۲۴(۴). ۷۸۰.

Comparison of Anfis, Artificial neural network, and Gene expression programming to estimate the amount of water hardness (Case study: Mazandaran Plain)

R. Dehghani^{1*}, A. Pourhaghi² and M. Kheiraey³

1- Master in Water Resources, University of Tabriz

2- PhD student of Water Resources, University of Shahid Chamran, Ahvaz

3- Master of water structures, University of Shahid Chamran, Ahvaz

* reza.dehghani67@yahoo.com

Received: 2014/9/2 Accepted: 2015/10/26

Abstract

Rate of water hardness is an important factor in hydrogeology, particularly in groundwater quality researches. In recent decades, the artificial intelligence systems such as artificial neural networks have many applications in various sciences, including management of water resources. In this study, estimated rate of groundwater hardness in Mazandaran plain, using Gene expression programming have been studied and the results is compared with other intelligent methods such as artificial neural network and Anfis. For this purpose the hydrogen carbonate, chloride, sulfate, magnesium and calcium monthly time scale of the period (1994-2014) was selected as inputs and water hardness as output. Standard deviation of the correlation coefficient, root mean square error, and coefficient of Nash Sutcliff were used to assess various methods. The results showed that Gene expression programming model has the maximum correlation coefficient 0.960, minimum root mean square error 0.112, mean absolute error 0.171 coefficient of Nash Sutcliff 0.880 was in the verification phase. In overall, the results showed that the Gene expression programming model has high performance in estimating some maximum and intermediate values of groundwater hardness.

Keywords: Gene expression programming, estimating, Mazandaran Plain, ANN, Anfis