



## مقایسه روش‌های شبکه عصبی بیزین، شبکه عصبی مصنوعی و برنامه‌ریزی بیان ژن در تحلیل کیفیت آب رودخانه‌ها (مطالعه موردی: رودخانه بالخلوچای)

محمدعلی قربانی<sup>۱</sup> و رضا دهقانی<sup>۲</sup>

۱- دانشیار، دانشگاه تبریز، (نویسنده مسئول: ghorbani@tabrizu.ac.ir)

۲- دانش‌آموخته کارشناسی ارشد، دانشگاه تبریز  
تاریخ دریافت: ۹۳/۱۰/۵ تاریخ پذیرش: ۹۴/۲/۲۷

### چکیده

میزان کل مواد جامد محلول (TDS) عامل مهمی در مهندسی رودخانه و به‌ویژه مطالعه کیفیت آب رودخانه‌ها می‌باشد. در این تحقیق جهت تحلیل میزان مواد جامد محلول در آب رودخانه بالخلوچای واقع در استان اردبیل از متغیرهای کیفیت شامل بی کربنات، کلرید، سولفات، کلسیم، منیزیم، سدیم و دبی جریان در مقیاس زمانی ماهانه طی دوره آماری (۱۳۵۵-۱۳۸۸) بعنوان ورودی مدل شبکه عصبی بیزین استفاده گردید و نتایج آن با مدل‌های شبکه عصبی مصنوعی و برنامه‌ریزی بیان ژن، مقایسه شد. معیارهای ضریب همبستگی، ریشه دوم میانگین مربعات خطا و ضریب نش ساتکلیف برای ارزیابی و نیز مقایسه عملکرد مدل‌ها مورد استفاده قرار گرفت. نتایج حاصله نشان داد که هرچند سه مدل مورد بررسی با دقت قابل قبولی توانسته‌اند به تخمین میزان مواد جامد محلول در آب بپردازند، لیکن مدل شبکه عصبی بیزین با بیشترین ضریب همبستگی (۰/۹۶۶)، کمترین ریشه دوم یا جذر میانگین مربعات خطا (۰/۰۹۴ mg/lit) و نیز معیار نش ساتکلیف (۰/۹۹۸) در مرحله صحت سنجی در اولویت قرار گرفت. در مجموع نتایج بیان‌گر برتری مدل شبکه عصبی بیزین در تخمین مقادیر کمینه و بیشینه‌ی مواد جامد محلول در آب می‌باشد.

واژه‌های کلیدی: اردبیل، تخمین، کل مواد جامد محلول، مدل

### مقدمه

توسعه روزافزون فعالیت‌های کشاورزی و صنعتی و افزایش حجم فاضلاب‌های شهری موجب آلودگی رودخانه‌ها شده است، به‌نحوی که کیفیت این منابع حیاتی آب را مورد مخاطره جدی قرار داده است. همچنین مصرفی‌رویه مواد شیمیایی در کشاورزی، باعث افزایش شدت آلودگی منابع آب شهرها و روستاها که به اندازه کافی آلوده شده‌اند، می‌شود. کل مواد جامد محلول<sup>۱</sup> یا TDS در آب برابر مجموع غلظت همه یون‌های موجود در آب می‌باشد. تخمین و ارزیابی کیفیت آب و TDS به‌منظور حفاظت منابع آب، بررسی و جلوگیری از آلودگی آن‌ها بسیار حائز اهمیت می‌باشد (۵). با شناخت کافی از متغیرهای کیفی می‌توان از یک مدل مناسب بهره‌گیری کرد و به شبیه‌سازی کیفی و اقدامات مدیریتی پرداخت. اگرچه مدل‌ها دارای محدودیت‌های خاصی می‌باشند ولی نقش مهمی در کنترل، پیش‌بینی و مدیریت منابع آب دارند. شناخت کامل پدیده‌های کیفی آب و آشنایی با نقاط ضعف و قوت مدل‌ها و مقایسه کارایی آن‌ها لازمه استفاده از این مدل‌ها می‌باشد. بنابراین می‌توان با به‌کارگیری مدلی مناسب و شناخت کافی از متغیرهای کیفیت آب، مؤثرترین آن‌ها از جمله TDS را مدل‌سازی نمود و مبنای اقدامات مدیریتی قرار داد. از آنجایی که کیفیت آب رودخانه‌ها از مشخصه‌های مختلفی که رفتار پیچیده و غیرخطی دارند تأثیر می‌پذیرند مدل‌های ریاضی ممکن است عملکرد خوبی نداشته باشند (۴). امروزه سیستم‌های هوشمند به‌طور گسترده برای پیش‌بینی پدیده‌های غیرخطی مورد استفاده قرار می‌گیرد، که روش شبکه عصبی بیزین (BNN)، برنامه‌ریزی بیان ژن (GEP)<sup>۳</sup>

و شبکه‌های عصبی مصنوعی (ANN)<sup>۴</sup> از جمله‌ی این روش‌ها بشمار می‌روند. شبکه‌های عصبی بیزین یکی از مدل‌های مبتنی بر شبکه‌های عصبی در مدل کردن مسائل غیرخطی و پیچیده از طریق الگوریتم‌های خاص و روش‌های آماری است. با استفاده از این روش می‌توان به مدل کردن روابط علت و معلولی یک فرآیند، آنالیز وضعیت موجود و تخمین وضعیت آینده یک سیستم پرداخت (۱۸). برنامه‌ریزی ژن یک تکنیک برنامه‌ریزی خودکار است که راه‌حل مسئله را با استفاده از برنامه‌ریزی کامپیوتر ارائه کرده و عضوی از خانواده الگوریتم تکاملی می‌باشد (۱۲). شبکه‌های عصبی مصنوعی نیز با الهام از سیستم پردازش اطلاعات مغز طراحی شده و توانایی آن در تقریب الگوهای یک مساله سبب افزایش دامنه کاربرد این شبکه‌ها شده است (۱). در سال‌های اخیر استفاده از روش‌های هوشمند در مطالعات کیفیت و کمی رودخانه‌ها مورد توجه محققین قرار گرفته است، که از جمله می‌توان به موارد ذیل اشاره نمود: در پژوهشی جهت شبیه‌سازی کیفیت آب رودخانه کرخه با استفاده از شبکه‌های عصبی مصنوعی، متغیرهای روز سال، دبی، اشل سطح آب و دمای آب به‌عنوان ورودی مدل در تخمین پارامترهای هدایت الکتریکی، نسبت جذب سدیم و کل املاح محلول مورد بررسی قرار گرفت که نتایج گویای توانایی بالای شبکه عصبی مصنوعی بود (۲۱). در پژوهشی دیگر از برنامه‌ریزی بیان ژن به‌منظور بررسی تغییرات داده‌های کیفیت آب زیرزمینی در دشت برخورد اصفهان استفاده شد که نتایج همبستگی قابل قبول نوسانات سطح آب زیرزمینی با کل املاح محلول را نشان داد (۱۲). تحلیل ارتباط متغیرهای کیفیت با دبی رودخانه نشان داده که مدل

1- Total Dissolved Solids  
3- Gene Expression Programming

2- Bayesian Neural Network  
4- Artificial Neural Network


عصبی مصنوعی بر اساس متغیرهایی همچون بی کربنات، کلرید، سولفات، کلسیم، منیزیم، سدیم و دبی جریان در مقیاس زمانی ماهانه می‌باشد.

### مواد و روش‌ها

#### منطقه مورد مطالعه و داده‌ها

بالخلوچای یکی از مهم‌ترین و پرآب‌ترین رودخانه‌های منطقه مشکین‌شهر، دشت مغان و اردبیل است که به رود مرزی ارس می‌ریزد. رودخانه بالخلوچای از به هم پیوستن دو رودخانه دمانه‌های شمال غربی کوهستان تالش و دمانه‌های شمال شرقی کوه‌های بزغوش به وجود می‌آید. طول این رودخانه ۱۰۸ کیلومتر است. که این رودخانه از شمال تا شمال شرقی مشکین‌شهر امتداد دارد و در طول جغرافیایی  $30^{\circ} 47'$  و عرض جغرافیایی  $45^{\circ} 37'$  واقع گردیده است. در شکل ۱ موقعیت جغرافیایی منطقه مورد مطالعه نشان داده شده است. در این تحقیق داده‌های متغیرهای کمی و کیفیت در مقیاس زمانی ماهانه شامل بی کربنات ( $\text{HCO}_3$ )، کلرید (Cl)، سولفات ( $\text{SO}_4$ )، کلسیم (Ca)، منیزیم (Mg)، سدیم (Na) و غلظت کل املاح محلول در آب (TDS)، همگی برحسب میلی‌گرم بر لیتر (mg/lit) و دبی جریان (Q) برحسب  $\text{lit/s}$  مربوط به ایستگاه رودخانه بالخلوچای از سال ۱۳۵۵ تا ۱۳۸۸ استفاده شد. این رودخانه، فاقد داده‌های مفقود بوده و آزمون تصادفی بودن داده‌ها قبل از تحلیل و مدل‌سازی انجام گرفت.

برنامه‌ریزی بیان ژن با عملگرهای اصلی ریاضی عملکرد قابل قبولی دارد (۳). از سوی دیگر مدل شبکه عصبی را جهت تخمین میزان غلظت اکسیژن محلول و اکسیژن خواهی بیوشیمیایی بر اساس ۱۱ پارامتر کیفیت ماهانه آب در ایستگاه‌های مختلف هند بررسی شد که نتایج تطبیق خوب مدل شبکه عصبی مصنوعی با مقادیر اندازه‌گیری شده و مورد انتظار برای غلظت‌های رودخانه را نشان داد (۱۸). در پژوهشی دیگر 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 متغیرهای کیفیت دارد (۱۷). همچنین شبکه عصبی پرسپترون چندلایه برای تخمین شاخص کیفیت آب در رودخانه کینتا واقع در مالزی استفاده کردند. نتایج نشان داد که مدل شبکه عصبی می‌تواند جایگزین مناسبی برای محاسبات طولانی شاخص کیفیت آب باشد (۹). در مجموع با توجه به پژوهش‌های انجام شده و ذکر این نکته که رودخانه بالخلوچای یکی از مهم‌ترین رودخانه‌های استان اردبیل و مهم‌ترین منبع تأمین‌کننده آب بخش‌های مختلف نواحی مجاور خود می‌باشد، اهمیت مدل‌سازی کیفیت آب این رودخانه و اقدامات مدیریتی جهت بهبود کیفیت آب آن بیش‌ازپیش ضروری است. لذا هدف از این تحقیق تخمین کل مواد جامد محلول این رودخانه با استفاده از مدل شبکه‌های عصبی بیزین، برنامه‌ریزی بیان ژن و شبکه‌های



شکل ۱- منطقه مورد مطالعه  
Figure 1. Study area

### شبکه‌های عصبی بیزین<sup>۱</sup>

یا آینده یک سیستم دست یابد. همچنین یک روش سازگار و انعطاف‌پذیر برای مدل کردن موقعیت‌های غیرقطعی و یک مدل گرافیکی مبتنی بر ادراک مستقیم از اندرکنش میان علل و معلول‌های مختلف ارائه می‌نماید. همچنین یک روش بسیار مفید در مدل کردن موقعیت‌های نامطمئن و غیرقطعی بر اساس روابط علت و معلولی است. در شبکه‌های عصبی یکی از روش‌های دستیابی مؤثر به پارامترهای بهینه، استفاده از تنظیم بیزین است که به‌طور اتوماتیک مقادیری

این روش یکی از روش‌های سیستم پشتیبان تصمیم‌گیری می‌باشد که ابزار قدرتمندی در مدل کردن روابط علی و معلولی در قالب شبکه‌ای از احتمالات است. نکته بسیار مهم در مورد روش شبکه عصبی بیزین این است که این روش به اطلاعات دقیق و تاریخچه کامل یک واقعیت نیاز ندارد بلکه می‌تواند با استفاده از اطلاعات ناقص و غیردقیق نیز به نتایج بسیار قانع‌کننده‌ای در زمینه تخمین وضعیت فعلی

$$P(w | D, \alpha, \beta, M) = \frac{\exp(-F(w))}{Z_F(\alpha, \beta)} \quad (b-4)$$

اگر معادله‌های ۴-ا و ۴-ب باهم در فرمول ۳ جایگذاری شوند آنگاه خواهیم داشت.

$$P(D | \alpha, \beta, M) = \frac{Z_F(\alpha, \beta)}{Z_w(\alpha) Z_D(\beta)} \quad (5)$$

$$Z_F(\alpha, \beta) =$$

$$(2\pi)^{\frac{N}{2}} \det^{-\frac{1}{2}}(H) \exp(-F(w^{MP}))$$

که  $Z_D(\beta) = (\frac{\pi}{\beta})^{\frac{N}{2}}$  و  $Z_w(\alpha) = (\frac{\pi}{\alpha})^{\frac{N}{2}}$  و  $H$  ماتریس Hessian تابع هدف  $F$  می‌باشد. در معادله ۵ روش‌های لگاریتم و مشتق‌گیری به ترتیب بکار گرفته شده است با فرض اینکه معادله تفاضلی تابع برابر صفر قرار گیرد

مقدار  $P(\alpha, \beta | D, M)$  به بیشینه شده و احتمال اولیه وزن‌ها مینیمم می‌شود. سپس  $\alpha$  و  $\beta$  بصورت زیر بیان می‌شوند (۱۶).

$$\alpha^{MP} = \frac{\gamma}{2E_w w^{MP}} \quad (6)$$

$$\beta^{MP} = \frac{n-\gamma}{2E_D w^{MP}} \quad (7)$$

$$(8)$$

$$\gamma = N - \alpha^{MP} \text{trace}^{-1} H^{MP}$$

که در آن  $n$  تعداد نمونه،  $N$  مقدار کل متغیرهای شبکه،  $\gamma$  تعداد متغیرهای مؤثر که نسبتاً اثر بیشتری در کاهش میزان خطای توابع دارند. در ابتدا  $\alpha$  و  $\beta$  بر طبق الگوریتم لاونبرگ مارکواریت فرض می‌شود و تابع هدف  $F(w)$  با آموزش شبکه منظم بیزین به کمترین مقدار خود می‌رسد.  $\alpha$  و  $\beta$  بر طبق معادلات ۶، ۷ و ۸ به‌روزرسانی شده و سپس مقادیر بهینه توزیع اولیه بدست می‌آید و حداقل مقدار جدید  $F(w)$  محاسبه می‌گردد و در نهایت آموزش شبکه آنقدر تکرار می‌شود تا به همگرایی برسد (۸). نمونه‌ای از ساختار شبکه سه لایه‌ای متشکل از یک لایه ورودی، یک لایه مخفی و یک لایه خروجی در شکل ۲ نشان داده شده است.

مناسب برای پارامترهای تابع قرار می‌دهد. روش تنظیم بیزین می‌تواند جهت بهبود توانایی شبکه عصبی و آموزش تابع هدف  $F$  که بصورت زیر نشان داده شده است استفاده شود (۱۶).

$$F = \alpha E_w + \beta E_D \quad (1)$$

که در آن  $E_w$  مجموع مربعات وزن‌های شبکه و  $E_D$  مجموع مربعات باقی‌مانده بین پاسخ شبکه و تابع هدف می‌باشد.  $\alpha$  و  $\beta$  نیز متغیرهای تابع هدف می‌باشند (متغیرهای تنظیم). که هر یک از این پارامترها به آموزش شبکه در کاهش باقی‌مانده خروجی‌ها یا حجم شبکه بستگی دارد. نکته اساسی روش تنظیم این است که متغیرهای تابع هدف را چگونه از طریق داده‌های آماری بیزین انتخاب و بهینه نماید. بطوریکه اگر  $\alpha$  و  $\beta$  بعنوان متغیرهای تصادفی در نظر گرفته شوند قانون بیزین بصورت فرمول زیر تعریف می‌شود (۱۶).

$$P(\alpha, \beta | D, M) = \frac{P(D | \alpha, \beta, M) P(\alpha, \beta | M)}{P(D | M)} \quad (2)$$

در فرمول بالا  $D$  داده‌های آموزش،  $M$  مدل شبکه و  $w$  وزن شبکه می‌باشد. بر طبق قانون بیزین اگر  $\alpha$  و  $\beta$  از توزیع یکنواخت پیروی نمایند در این صورت احتمال زمانی  $P(D | \alpha, \beta, M)$  ماکزیمم می‌شود که احتمال توزیع اولیه  $\alpha$  و  $\beta$  در معادله ۲ حداکثر به مقدار ماکزیمم خواهد رسید. با فرض اینکه باقی‌مانده‌ها و وزن‌ها متغیرهای تصادفی باشند و بر اساس قانون بیزین معادله ۳ بصورت زیر می‌باشد.

$$P(w | D, \alpha, \beta, M) = \frac{P(D | w, \beta, M) P(w | \alpha, M)}{P(D | \alpha, \beta, M)} \quad (3)$$


در صورتیکه فرض شود باقی‌مانده‌ها و وزن‌ها از توزیع گوسین پیروی کرده داریم:

$$P(D | w, \beta, M) = \frac{\exp(-\beta E_D)}{Z_D(\beta)} \quad (4)$$

$$(a-4)$$

$$P(w | \alpha, M) = \frac{\exp(-\alpha E_w)}{Z_w(\alpha)}$$

برای اطمینان از اینکه  $P(D | \alpha, \beta, M)$  به عنوان فاکتور تنظیم در معادله ۳ گردد معادله ۴-ب بصورت زیر می‌باشد.



شکل ۲- نمای کلی یک شبکه عصبی بیزین سه لایه

Figure 2. A three-layer Bayesian neural network overview


### برنامه‌ریزی بیان ژن<sup>۱</sup>

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 و ساختارهای شاخه‌ای با اندازه‌ها و اشکال متفاوت، مشابه با درختان تجزیه در برنامه‌ریزی ژنتیک، ترکیب می‌شوند. از آنجایی که در این روش تمام ساختارهای شاخه‌ای با اندازه اشکال متفاوت، در کروموزوم‌های خطی با طول ثابت کدگذاری می‌شوند، معادل این است که در این روش فنوتیپ و ژنوتیپ از هم جدا می‌شوند و سیستم می‌تواند از تمام مزایای تکاملی به سبب وجود آنها بهره‌مند شود. اکنون باوجود اینکه فنوتیپ در GEP، همان نوع از ساختارهای شاخه‌ای مورد استفاده در GP را شامل می‌شود، اما ساختارهای شاخه‌ای که به‌وسیله GEP استنتاج می‌شوند (که بیان درختی نیز نامیده می‌شود) مبین تمامی ژنوم‌های مستقل هستند. به‌طور خلاصه می‌توان گفت در GEP به‌سازی‌ها در یک ساختار خطی اتفاق افتاده و سپس به‌صورت ساختار درختی بیان می‌شود و این موجب می‌شود تنها ژنوم اصلاح‌شده به نسل بعد منتقل‌شده و نیازی به ساختارهای سنگین برای تکثیر و جهش وجود نداشته باشد (۶). در این روش پدیده‌های مختلف با استفاده از مجموعه‌ای از توابع و مجموعه‌ای از ترمینال‌ها، مدل‌سازی می‌شوند. مجموعه توابع، معمولاً شامل توابع اصلی حسابی  $\{+, -, \times, /\}$ ، توابع مثلثاتی یا هر نوع تابع ریاضی دیگر  $\{x^2, \exp, \log, \sin, \cos, \dots\}$  و یا توابع تعریف‌شده توسط کاربر است که معتقد است، می‌توانند برای تفسیر مدل مناسب باشند. مجموعه ترمینال‌ها، از مقادیر ثابت و متغیرهای مستقل مساله تشکیل شده‌اند (۶). برای به‌کارگیری روش برنامه‌ریزی بیان ژن از نرم‌افزار GenXproTools 4.0 استفاده گردید (۱۰).

### شبکه عصبی مصنوعی<sup>۱</sup>

شبکه‌های عصبی مصنوعی با الهام از سیستم پردازش اطلاعات مغز طراحی و به عرصه ظهور رسیده‌اند که به کمک فرآیند یادگیری و با استفاده از پردازشگرهایی به نام نرون تلاش می‌کند با شناخت روابط ذاتی بین داده‌ها، نگاشتی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارائه دهد. لایه یا لایه‌های مخفی، اطلاعات دریافت شده از

لایه ورودی را پردازش کرده و در اختیار لایه خروجی قرار می‌دهند. با توجه به ساختار شبکه عصبی مصنوعی، ویژگی‌های عمده آن سرعت بالای پردازش، توانایی یادگیری الگو، توانایی تعمیم الگو پس از یادگیری، انعطاف‌پذیری در برابر خطاهای ناخواسته و عدم ایجاد اختلال قابل‌توجه در صورت بروز اشکال در بخشی از اتصال‌ها به دلیل توزیع وزن‌های شبکه است. نخستین کاربرد عملی شبکه‌های عصبی مصنوعی با معرفی شبکه‌های پرسپترون چندلایه<sup>۲</sup> انجام گرفت. برای آموزش این شبکه معمولاً از الگوریتم پس انتشار (BP) استفاده می‌شود که اساس این الگوریتم بر پایه قانون یادگیری اصلاح خطا می‌باشد که از دو مسیر اصلی رفت و برگشت تشکیل می‌شود. تنظیم پارامترها در شبکه پرسپترون چندلایه توسط سیگنال خطا و سیگنال ورودی صورت می‌گیرد. تعیین تعداد لایه‌ها و نرون‌های موجود در آنها از مهمترین مسائل در شبیه‌سازی با شبکه عصبی مصنوعی است. رایج‌ترین توابع محرک استفاده‌شده در شبکه‌های انتشار برگشتی را توابع محرک سیگموئید و تانژانت هیپربولیک ذکر کردند (۲۰). در طی آموزش شبکه MLP به کمک الگوریتم یادگیری BP، ابتدا محاسبات از ورودی به‌سوی خروجی شبکه انجام می‌شود، سپس مقادیر خطای محاسبه‌شده به لایه‌های قبل انتشار می‌یابد. در ابتدا محاسبه خروجی به‌صورت لایه به لایه انجام می‌شود و خروجی هر لایه، ورودی لایه بعدی خواهد بود که مراحل آموزش به کمک این الگوریتم عبارتند از: (الف) اختصاص ماتریس وزن به هریک از اتصالات، (ب) انتخاب بردار ورودی و خروجی متناسب با آن، (پ) محاسبه خروجی نرون در هر لایه و در نتیجه محاسبه خروجی نرون‌ها در لایه خروجی، (ت) بهنگام سازی وزن‌ها به روش انتشار خطای شبکه به لایه‌های قبل که خطای یادشده ناشی از اختلاف بین خروجی واقعی و خروجی محاسبه‌شده است، (ث) ارزیابی عملکرد شبکه آموزش‌دیده به کمک برخی شاخص‌های تعریف‌شده مانند جذر میانگین مربعات خطا (MSE)، سرانجام برگشت به مرحله (پ) یا پایان آموزش (۱۳۲). نمونه‌ای از ساختار شبکه سه لایه‌ای متشکل از یک لایه ورودی، یک لایه مخفی، و یک لایه خروجی در شکل ۳ نشان داده شده است.



شکل ۳- نمای کلی یک شبکه عصبی مصنوعی سه لایه  
Figure 3. A three-layer artificial neural network overview

خطا (RMSE)<sup>۵</sup> و ضریب نشساتکلیف (NS)<sup>۶</sup> طبق روابط زیر صورت گرفت. بهترین مقدار برای این سه معیار به ترتیب یک، صفر و یک می‌باشد.

### معیارهای ارزیابی

در این تحقیق ارزیابی دقت و قابلیت روش‌ها با استفاده از نمایه‌های ضریب همبستگی (CC)<sup>۴</sup>، ریشه میانگین مربعات

1- Artificial Neural Network  
4- Correlation coefficient

2- Bayesian Neural Network  
5- Root mean square error

3- Back propagation  
6- Nash Sutcliff

$$CC = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad -1 \leq R \leq 1 \quad (9)$$

$$(10)$$

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

$$NS = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{y})^2} \quad -\infty \leq NS \leq 1 \quad (11)$$

ماهانه استفاده گردید. متغیرهای بی کربنات ( $HCO_3$ )، کلرید ( $Cl$ )، سولفات ( $SO_4$ )، کلسیم ( $Ca$ )، منیزیم ( $Mg$ )، سدیم ( $Na$ ) و دیبی جریان ( $Q$ ) بعنوان ورودی و میزان مواد جامد محلول در آب ( $TDS$ ) بعنوان پارامتر خروجی مدل‌ها بکار برده شد. در ادامه نتایج مدل‌های مورد استفاده ارائه می‌گردد. در این پژوهش ۸۰ درصد از داده‌ها (۱۱۰۸ رکورد)، به منظور آموزش و ۲۰ درصد مابقی (۲۹۷ رکورد)، برای صحت سنجی انتخاب گردید. با توجه به نمونه برداری در زمان‌های مختلف، داده‌های مورد استفاده ماهیتاً دارای رفتار تصادفی بوده و انتخاب بازه زمانی خاص خودبخود در همزمان‌ها در فرایند آموزش و صحت سنجی لحاظ گردیده است. در جدول (۱) خصوصیات آماری متغیرهای کمی و کیفیت رودخانه بالخلوچای در بازه زمانی مذکور نشان داده شده است. جدول (۲) نیز ماتریس همبستگی بین کل املاح محلول در آب و متغیرهای ورودی را نشان می‌دهد بر اساس جدول مذکور، بی کربنات و دیبی جریان به ترتیب بیشترین و کمترین همبستگی را با مواد جامد محلول در آب دارند همچنین نتایج معنی‌دار بودن متغیرهای مؤثر بر مواد جامد محلول در آب در سطوح احتمال ۵ و ۱۰ درصد نشان داد. همبستگی تمام پارامترها با  $TDS$ ، در هر دو سطح احتمال، معنی‌دار است.

در روابط بالا،  $y_i$  و  $x_i$  به ترتیب مقادیر مشاهداتی و محاسباتی در گام زمانی  $N$ ، تعداد گام‌های 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 نتایج استفاده شده است. یک نکته مهم در آموزش شبکه‌های عصبی نرمال‌سازی داده‌ها قبل از استفاده در مدل می‌باشد این عمل خصوصاً وقتی دامنه تغییرات ورودی‌ها زیاد باشد کمک شایانی به آموزش بهتر و سریعتر مدل می‌کند. اصولاً وارد کردن داده‌ها بصورت خام باعث کاهش سرعت و دقت شبکه می‌شود (۲۲). برای نرمال‌سازی داده‌های تحقیق از رابطه (۱۲) استفاده شده است: که در آن  $X_n$  مقدار نرمال شده ورودی  $X_i$ ،  $X_{min}$  و  $X_{max}$  به ترتیب حداکثر و حداقل داده‌ها می‌باشد.

$$X_n = 0.1 + 0.8 \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (12)$$

## نتایج و بحث

در این تحقیق به منظور بررسی و مقایسه نتایج مدل‌ها از داده‌های ماهانه ایستگاه رودخانه بالخلوچای در اردیبه‌ل طول دوره آماری از سال ۱۳۵۵ تا ۱۳۸۸ در مقیاس زمانی

جدول ۱- مشخصات آماری متغیرهای کیفیت رودخانه بالخلوچای

Table 1. Statistical properties of qualitative variables for Belkhviachay river

مرحله	پارامتر	واحد	تعداد رکورد	میانگین	مینیمم	ماکزیمم	انحراف معیار	ضریب تغییرات	چولگی
آموزش	$HCO_3$	mg/lit	۱۱۰۸	۲/۹۱	۰/۲۰	۷/۲۰	۱/۳۹	۰/۴۷	۰/۳۹
	$Cl$	mg/lit	۱۱۰۸	۰/۴۰	۰/۰۵	۴/۴۰	۰/۲۹	۰/۷۳	۵/۷۳
	$So_4$	mg/lit	۱۱۰۸	۰/۳۱	۰/۰۱	۴/۴۲	۰/۳۳	۱/۰۵	۳/۴۶
	$Ca$	mg/lit	۱۱۰۸	۱/۹۷	۰/۱۰	۵/۲۰	۰/۸۷	۰/۴۴	۰/۵۱
	$Mg$	mg/lit	۱۱۰۸	۰/۹۵	۰/۰۳	۳/۷۰	۰/۵۹	۰/۶۲	۰/۹۵
	$Na$	mg/lit	۱۱۰۸	۰/۷۱	۰/۰۳	۶/۰۰	۰/۵۷	۰/۸۰	۲/۹۳
	$Q$	lit/s	۱۱۰۸	۱/۶۱	.	۴۰/۶۶	۳/۴۶	۲/۱۴	۴/۵۶
صحت سنجی	$TDS$	mg/lit	۱۱۰۸	۲۳۳/۳۷	.	۶۶۵/۰۰	۱۰۲/۵۵	۰/۴۳	۰/۵۵
	$HCO_3$	mg/lit	۲۷۹	۱/۳۴	۰/۳۵	۴/۴۰	۰/۴۶	۰/۳۴	۱/۴۴
	$Cl$	mg/lit	۲۷۹	۰/۲۰	۰/۰۵	۰/۸۰	۰/۱۰	۰/۵۰	۱/۹۱
	$So_4$	mg/lit	۲۷۹	۰/۱۷	۰/۰۱	۱/۲۰	۰/۱۷	۱/۰۲	۲/۵۲
	$Ca$	mg/lit	۲۷۹	۰/۹۹	۰/۱۰	۳/۴۰	۰/۳۲	۰/۳۳	۱/۸۶
	$Mg$	mg/lit	۲۷۹	۰/۴۴	۰/۰۴	۱/۲۰	۰/۲۳	۰/۵۲	۰/۷۵
	$Na$	mg/lit	۲۷۹	۰/۳۱	۰/۰۲	۱/۶۰	۰/۱۷	۰/۵۳	۲/۷۴
	$Q$	lit/s	۲۷۹	۱/۴۱	.	۲۱۵/۰۰	۱۲/۸۹	۹/۰۸	۱۶/۵۳
	$TDS$	mg/lit	۲۷۹	۱۱۴/۳۹	۵۱/۰۰	۳۴۳/۲۰	۳۳/۱۴	۰/۲۸	۱/۶۴

جدول ۲- ماتریس همبستگی متغیرهای کیفیت رودخانه بالخلوچای

Table 2. Correlation matrix of qualitative variables for Belkhviachay river

TDS	Q	Hco3	Cl	So4	Ca	mg	na	
+۰/۴۸۰	+۰/۰۰۹	-۰/۳۷۰	+۰/۳۴۱	+۰/۱۹۵	+۰/۱۹۲	+۰/۱۴۲	۱/۰۰۰	Na
-۰/۵۷۵	+۰/۰۲۲	-۰/۵۵۶	+۰/۱۵۵	+۰/۱۱۴	+۰/۲۷۸	۱/۰۰۰	+۰/۱۴۲	Mg
+۰/۷۶۶	+۰/۰۳۵	+۰/۷۹۰	+۰/۱۷۶	+۰/۰۵۶	۱/۰۰۰	+۰/۲۷۸	+۰/۱۹۲	Ca
-۰/۱۴۲	-۰/۰۰۲	+۰/۰۳۲	+۰/۰۰۶	۱/۰۰۰	+۰/۰۵۶	+۰/۱۱۴	+۰/۱۹۵	So4
+۰/۲۹۰	+۰/۰۰۹	+۰/۱۶۱	۱/۰۰۰	+۰/۰۰۶	+۰/۱۷۶	+۰/۱۵۵	+۰/۳۴۱	Cl
+۰/۹۰۵	+۰/۰۳۸	۱/۰۰۰	+۰/۱۶۱	+۰/۰۳۲	-۰/۷۹۰	+۰/۵۵۶	+۰/۳۷۰	Hco3
+۰/۰۳۲	۱/۰۰۰	+۰/۰۳۸	+۰/۰۰۹	-۰/۰۰۲	+۰/۰۳۵	+۰/۰۲۲	+۰/۰۰۹	Q
۱/۰۰۰	+۰/۰۳۲	+۰/۹۰۵	+۰/۲۹۰	+۰/۱۴۲	+۰/۷۶۶	+۰/۵۷۵	+۰/۴۸۰	TDS

توجه: ارقام پررنگ نشان‌دهنده معنی‌داری در سطح ۱۰ درصد یا کمتر است.

## نتایج شبکه عصبی بیزین

با ۳ نرون در لایه پنهان اول با بیشترین ضریب همبستگی  $CC=۰/۹۶۶$  و کمترین ریشه میانگین مربعات خطا  $RMSE=۰/۰۹۴\text{mg/lit}$  و  $NS=۰/۹۹۸$  در مرحله صحت سنجی به‌عنوان بهترین مدل در فرآیند شبیه‌سازی انتخاب شد. همان‌طور که در جدول ۴ مشاهده می‌شود شبکه عصبی بیزین بخوبی تعمیم داده‌شده است که توانسته داده‌های بخش صحت سنجی را بخوبی داده‌های بخش آموزش اجرا نماید (۱۶). همان‌طور که در شکل (۴-ب) مشخص است تطابق مقادیر محاسباتی مواد جامد محلول مربوط به مرحله صحت سنجی مدل شبکه عصبی بیزین با مقادیر مشاهداتی وجود دارد. همچنین با توجه به نمودار (۴-الف) قابلیت بالای این مدل در تخمین اکثر مقادیر مشهود است.

بمنظور تخمین میزان مواد جامد محلول در آب از مدل شبکه عصبی بیزین از نوع شبکه پرسپترون چندلایه با تعداد نرون‌های متفاوت استفاده شد. در این شبکه متغیرهای تابع هدف (متغیرهای تنظیم) با استفاده از تقریب گوس نیوتن محاسبه و نتایج آن در جدول ۳ ارائه شد با توجه به جدول ۳ خطای شبکه کاهش‌یافته و به متغیرهای ورودی به شبکه وزن مناسب اختصاص یافت با بهینه نمودن متغیرهای تابع هدف و تأثیر آن در تابع هدف از بیش برارشی آموزش شبکه جلوگیری شد (۱۶). روند کار آموزش شبکه با تعداد نرون‌های کم آغاز و افزودن نرون‌های اضافی تا زمانی ادامه می‌یابد که افزایش نرون‌های بیشتر تأثیری در بهبود خطا نداشته باشد، در این روش با توجه به جدول ۴ مدل شماره ۲ بصورت شبکه‌ای

جدول ۳- مقادیر متغیرهای مورد استفاده در شبکه عصبی بیزین

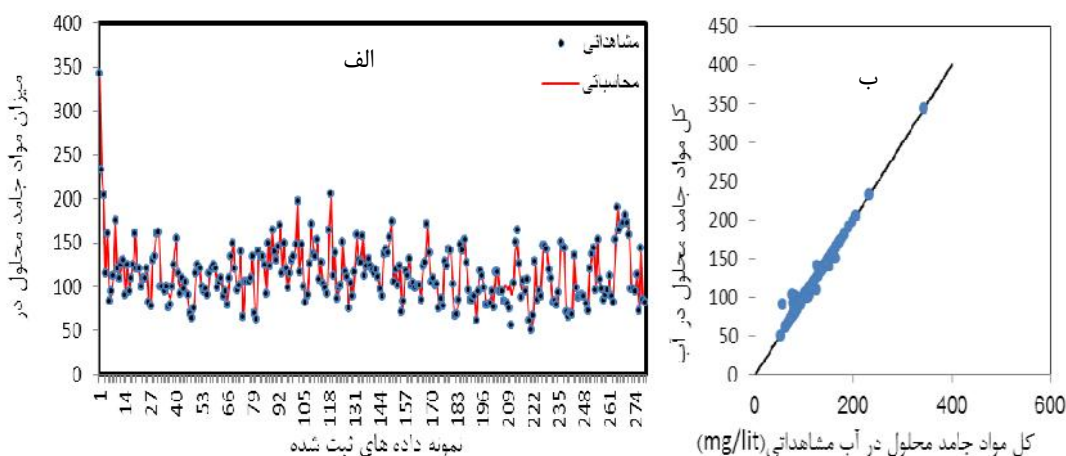
Table 3. The values of variables used in Bayesian neural network

Epoch	Gradient	$\alpha$	$\beta$	$E_w$	$E_D$	پارامتر
۱۰۰۰	$۱۰^{-۱۰}$	۰/۹۹۹۹	$۱/۷۹ \times ۱۰^{-۵}$	۱۶/۴۶۱	۰/۰۰۰۲	

جدول ۴- نتایج حاصل از مدل شبکه‌های عصبی بیزین در مراحل آموزش و صحت سنجی  
Table 4. The results of Bayesian neural network training and validation

شماره	ساختار	تابع محرک		آموزش			صحت سنجی		
		لایه پنهان	لایه خروجی	CC	RMSE (mg/lit)	NS	CC	RMSE (mg/lit)	NS
۱	۷-۳-۱	تانزانته هیپربولیک	خطی	۰/۹۷۶	۰/۰۳۲	۰/۹۷۵	۰/۹۶۴	۰/۰۹۷	۰/۹۹۲
۲	۷-۳-۱	تانزانته هیپربولیک	خطی	۰/۹۷۷	۰/۰۲۶	۰/۹۷۶	۰/۹۶۶	۰/۰۹۴	۰/۹۹۸
۳	۷-۴-۱	تانزانته هیپربولیک	خطی	۰/۹۷۵	۰/۰۳۴	۰/۹۷۴	۰/۹۶۵	۰/۰۹۷	۰/۹۹۴
۴	۷-۵-۱	تانزانته هیپربولیک	خطی	۰/۹۷۶	۰/۰۲۷	۰/۹۷۰	۰/۹۶۵	۰/۰۹۸	۰/۹۸۹
۵	۷-۶-۱	تانزانته هیپربولیک	خطی	۰/۹۷۴	۰/۰۲۹	۰/۹۶۴	۰/۹۶۴	۰/۰۹۶	۰/۹۹۱
۶	۷-۷-۱	تانزانته هیپربولیک	خطی	۰/۹۷۵	۰/۰۳۳	۰/۹۶۶	۰/۹۶۵	۰/۰۹۸	۰/۹۹۳
۷	۷-۸-۱	تانزانته هیپربولیک	خطی	۰/۹۷۲	۰/۰۳۲	۰/۹۷۴	۰/۹۶۵	۰/۰۹۵	۰/۹۹۵
۸	۷-۹-۱	تانزانته هیپربولیک	خطی	۰/۹۷۴	۰/۰۲۸	۰/۹۶۸	۰/۹۶۳	۰/۰۹۶	۰/۹۹۵
۹	۷-۱۱-۱	تانزانته هیپربولیک	خطی	۰/۹۷۵	۰/۰۲۹	۰/۹۷۵	۰/۹۶۴	۰/۰۹۷	۰/۹۹۴
۱۰	۷-۱۳-۱	تانزانته هیپربولیک	خطی	۰/۹۷۰	۰/۰۳۰	۰/۹۶۶	۰/۹۶۵	۰/۰۹۶	۰/۹۸۹
۱۱	۷-۱۴-۱	تانزانته هیپربولیک	خطی	۰/۹۷۶	۰/۰۳۱	۰/۹۷۱	۰/۹۶۵	۰/۰۹۷	۰/۹۹۴





شکل ۴- نمودار حاصل از مقادیر بهینه مدل شبکه عصبی بیزین برای داده‌های ثبت‌شده مرحله صحت سنجی  
الف) مقادیر محاسباتی و مشاهداتی نسبت به زمان ب) نمودار پراکنش میان مقادیر مشاهداتی و محاسباتی  
Figure 4. Diagram of optimal values of Bayesian neural network model for recorded data in validation phase  
A) the observed and computed values over time B) scattered plot of observed and computed values

مطالعات (۱۵،۱۱) صورت گرفته است. روابط نهایی حاصل از سه مجموعه از عملگرهای ریاضی تعریف‌شده برای حوضه بالخلوچای در جدول ۵ میزان تأثیر هریک از متغیرهای ورودی را روی میزان کل مواد جامد محلول نشان می‌دهد، با توجه به این روابط سدید، کلرید و بی کربنات بیشترین تأثیر در تخمین کل مواد جامد محلول را داشته‌اند و دبی جریان با توجه به وزن تأثیر ناچیز در روابط عملگر F3 حذف گردیده است، این امر در میزان همبستگی ضعیف بین Q و TDS کاملاً مشهود است.

$$F1: \{+, -, *, /, \sqrt{\quad}\} \quad (13)$$

$$F2: \{+, -, *, /, \sqrt{\quad}, \text{Exp}, \text{Ln}, 2^{\quad}, 3^{\quad}, \sqrt[3]{\quad}, \text{Sin}, \text{Cos}, \text{Atan}\} \quad (14)$$

$$F3: \{+, -, *, /, \sqrt{\quad}, \text{Exp}, \text{Ln}, 2^{\quad}\} \quad (15)$$

### 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 کل مواد جامد محلول رودخانه بالخلوچای مدنظر قرار گرفت. لذا هر هفت ورودی برای تعیین متغیرهای معنی‌دار استفاده و جهت بررسی بیشتر علاوه بر مجموعه چهار عملگر اصلی (F1)، حالت‌هایی بر اساس عملگرهای ریاضی پیش‌فرض برنامه (F2)، و مجموعه عملگر F3 لحاظ گردیده است. همچنین در این پژوهش جهت ساخت درخت تجزیه و تولید یک جمعیت اولیه از راه‌حلهایی استفاده شد که این راه‌حل‌ها از ترکیب تصادفی مجموعه توابع (عملگرهای ریاضی مورد استفاده در فرمول‌ها) و ترمینال‌ها (متغیرهای مسئله و اعداد ثابت) ایجاد می‌شوند نحوه و دلیل انتخاب این نوع عملگرها با توجه به

جدول ۵- معادلات برنامه‌ریزی بیان ژن برای چهار مجموعه عملگر ریاضی منتخب  
Table 5. Equations for four sets of mathematical operators of gene expression programming

عملگر	معادلات برنامه‌ریزی بیان ژن
F <sub>1</sub>	$TDS = 60.51(SO_4 + HCO_3) + Na(5.04Mg - Na) - (Ca + HCO_3) - 8.69 + Cl^2(Q + Cl)$
F <sub>2</sub>	$TDS = \left(\frac{Na + Cl}{Na}\right) + 61.5SO_4 + Q^{\frac{1}{3}} + (71.31 + Cl)HCO_3 + (Cl + 7.46)^{0.5}(Q + Cl)Cl^2$
F <sub>3</sub>	$TDS = \left(\frac{HCO_3}{Ca}\right)(4.93Cl + 24.3)SO_4 + (4.71Ca - Cl - Mg) - Ca - Na + (HCO_3 + Ca)45.56 + 2Cl$

عملگرها از دقت بیشتری برخوردار بوده است. بنابراین برنامه‌ریزی بیان ژن با عملگر F1 شامل چهار عملگر اصلی ریاضی، باوجود رابطه ساده ریاضی بیشترین دقت را در تخمین کل مواد جامد محلول در رودخانه بالخلوچای داشته است. که با نتایج (۱۲،۳) همخوانی دارد. نمودارهای پراکنش

نتایج حاصل از مدل برنامه‌ریزی بیان ژن با هر سه عملگر در جدول ۶ بیانگر این است که عملگر F1 در هردو مرحله آموزش و صحت سنجی با بیشترین ضریب همبستگی  $CC = 0.950$  و ریشه میانگین مربعات خطا  $RMSE = 0.171 \text{ mg/lit}$  و  $NS = 0.767$  نسبت به سایر

بر نابرابری مقادیر مشاهداتی و محاسباتی بر اساس خط  $(y=x)$  دارد. همچنین لازم به ذکر است با توجه به شکل (۵-الف) این مدل در تخمین برخی مقادیر حداقل و حداکثر مواد جامد محلول در آبضعیف عمل کرده، به طوریکه این مقادیر به ترتیب بیشتر و کمتر از مقدار واقعی آن‌ها (مشاهداتی) تخمین زده است.

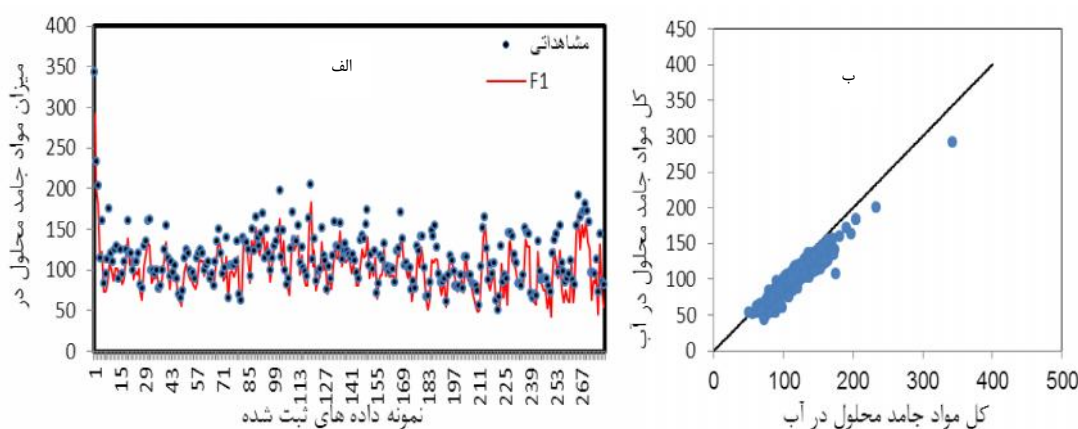
برنامه‌ریزی بیان ژن مربوط به مرحله صحت سنجی در شکل (۵-ب) نشان‌دهنده خط برازش مقادیر محاسباتی با چهار مجموعه عملگر ریاضی با بهترین خط برازش  $y=x$  است. همان‌طور که از این شکل مشخص است مقادیر تخمینی و مشاهداتی به‌غیر از چند نقطه که روی خط نیمساز واقع شده سایر نقاط پایین‌تر از خط برازش قرار دارند که این امر دلالت

جدول ۶- نتایج حاصل از مدل برنامه‌ریزی بیان ژن در مراحل آموزش و صحت سنجی

Table 6. The results of gene expression programming training and validation

عملگر	NS	آموزش RMSE (mg/lit)	CC	صحت سنجی NS	RMSE (mg/lit)	CC
F <sub>1</sub>	۰/۷۳۴	۰/۶۵۳	۰/۹۷۵	۰/۷۶۷	۰/۱۷۱	۰/۹۵۰
F <sub>2</sub>	۰/۸۲۹	۰/۳۰۳	۰/۹۷۴	۰/۸۷۰	۰/۲۷۵	۰/۹۴۶
F <sub>3</sub>	۰/۸۰۳	۰/۰۹۸	۰/۹۶۰	۰/۸۶۵	۰/۲۷۱	۰/۹۴۱

توجه: ارقام پررنگ نشان‌دهنده معنی‌داری در سطح ۱۰ درصد یا کمتر است.



شکل ۵- نمودار حاصل از مقادیر بهینه مدل برنامه‌ریزی بیان ژن برای داده‌های ثبت‌شده مرحله صحت سنجی

(الف) مقادیر محاسباتی و مشاهداتی نسبت به زمان (ب) نمودار پراکنش میان مقادیر مشاهداتی و محاسباتی

Figure 5. Diagram of optimal values of gene expression programming model for recorded data in validation phase  
A) the observed and computed values over time B) scattered plot of observed and computed values

ساختار شماره ۱ با بیشترین ضریب همبستگی  $CC=0.921$  و کمترین ریشه میانگین مربعات خطا  $RMSE=0.352$ mg/lit و  $NS=0.840$  در مرحله صحت سنجی نسبت به سایر ساختارها جهت مدل‌سازی میزان مواد جامد محلول در آب مناسب‌تر خواهد بود. که این نتایج با پژوهش‌های (۲۱،۱۷) همخوانی دارد. در شکل ۶ نمودار بهترین مدل حاصل‌شده برای داده‌های بخش صحت سنجی نشان داده‌شده است. همان‌طور که از شکل (۶-ب) مشخص است مقادیر تخمینی و مشاهداتی به‌غیر از چند نقطه روی خط نیمساز پراکنده شده و این امر دلالت بر برابری مقادیر مشاهداتی و محاسباتی بر اساس خط  $(y=x)$  می‌باشد. در نمودار (۶-الف) نیز تغییرات مقادیر محاسباتی و مشاهداتی نسبت به زمان نشان داده شده است، این شکل نشان می‌دهد که شبکه عصبی مصنوعی در تخمین برخی مقادیر حداقل، حداکثر و میانی عملکرد خوبی نداشته، به‌طوری‌که این مقادیر را بیش‌تر یا کمتر از مقدار واقعی‌شان تخمین زده است.

### نتایج شبکه عصبی مصنوعی

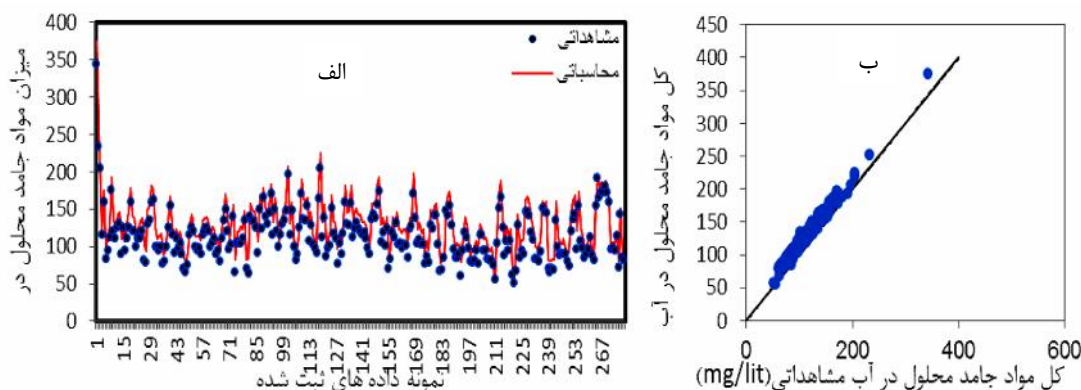
به‌منظور مدل‌سازی میزان مواد جامد محلول در آب در رودخانه بالخلوچای از مدل شبکه عصبی مصنوعی از نوع شبکه پرسپترون چندلایه با لایه پنهان با تعداد نرون‌های متفاوت استفاده شده است. تابع تانژانت هیپربولیک متداول‌ترین شکل از توابع محرک است، که در این تحقیق از آن برای ساخت لایه خروجی شبکه‌های عصبی مصنوعی استفاده گردید. آموزش شبکه‌های پرسپترون چندلایه با استفاده از الگوریتم آموزش پس انتشار خطا بنام الگوریتم لونیبرگ-مارکوارت به دلیل همگرایی سریع‌تر در آموزش شبکه، استفاده شد. همچنین از ترکیبات مختلف توابع محرک در لایه (های) مخفی استفاده گردید. در این پژوهش شبکه‌ای با ۲ نرون در لایه پنهان اول به‌عنوان بهترین شبکه در فرآیند مدل‌سازی حاصل شد. در جدول ۷ نتایج حاصل از مقایسه عملکرد ساختارهای مختلف به‌کاررفته به همراه متغیرهای آماری داده‌های بخش آموزش و صحت سنجی ارائه شده است. همان‌طور که در جدول ۷ مشاهده می‌شود



جدول ۷- نتایج حاصل از مدل شبکه‌های عصبی مصنوعی در مراحل آموزش و صحت سنجی

Table 7. The results of artificial neural network training and validation

شماره	ساختار	تابع محرک		آموزش		صحت سنجی	
		لایه پنهان	لایه خروجی	NS	CC	NS	CC
۱	۷-۲-۱	تانژانت هیپربولیک	خطی	۰/۸۱۴	۰/۲۴۲	۰/۸۴۰	۰/۳۵۲
۲	۷-۳-۱	تانژانت هیپربولیک	خطی	۰/۸۰۸	۰/۶۲۰	۰/۷۶۳	۰/۸۹۱
۳	۷-۴-۱	تانژانت هیپربولیک	خطی	۰/۷۸۲	۰/۶۶۲	۰/۷۴۷	۰/۹۰۱
۴	۷-۵-۱	تانژانت هیپربولیک	خطی	۰/۶۳۲	۰/۳۰۹	۰/۸۳۷	۰/۸۴۸
۵	۷-۶-۱	تانژانت هیپربولیک	خطی	۰/۷۴۶	۰/۴۳۶	۰/۷۹۸	۰/۸۹۱
۶	۷-۸-۱	تانژانت هیپربولیک	خطی	۰/۷۳۶	۰/۳۲۸	۰/۸۱۲	۰/۷۸۹
۷	۷-۱۰-۱	تانژانت هیپربولیک	خطی	۰/۷۵۴	۰/۲۸۱	۰/۷۸۴	۰/۴۳۸
۸	۷-۱۱-۱	تانژانت هیپربولیک	خطی	۰/۷۹۴	۰/۲۶۸	۰/۸۲۶	۰/۷۱۶
۹	۷-۱۲-۱	تانژانت هیپربولیک	خطی	۰/۷۸۶	۰/۲۵۳	۰/۷۹۳	۰/۵۲۳
۱۰	۷-۱۴-۱	تانژانت هیپربولیک	خطی	۰/۸۰۳	۰/۲۶۵	۰/۸۳۳	۰/۹۳۷
۱۱	۷-۱۶-۱	تانژانت هیپربولیک	خطی	۰/۷۹۹	۰/۳۵۱	۰/۸۲۸	۰/۸۶۶



شکل ۶- نمودار حاصل از مقادیر بهینه مدل شبکه عصبی مصنوعی برای داده‌های ثبت شده مرحله صحت سنجی

الف) مقادیر محاسباتی و مشاهداتی نسبت به زمان ب) نمودار پراکنش میان مقادیر مشاهداتی و محاسباتی

Figure 6. Diagram of optimal values of artificial neural network model for recorded data in validation phase

A) the observed and computed values over time B) scattered plot of observed and computed values

#### 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 مواد جامد محلول در آب رودخانه بالخلوچای را شبیه‌سازی کنند. همانطور که در جدول ۸ مشاهده می‌شود از بین مدل‌های به کاررفته مدل شبکه عصبی بیزین با بیشترین دقت  $CC=0/966$  و کمترین ریشه میانگین مربعات خطا  $RMSE=0/094 \text{ mg/lit}$  و بیشترین ضریب نش-ساتنکلیف  $NS=0/998$  در مرحله صحت سنجی دارا

می‌باشد. مقایسه نتایج مدل شبکه عصبی بیزین با مدل برنامه‌ریزی بیان ژن حاکی از نزدیک بودن نتایج این دو مدل می‌باشد. در شکل ۷ نتایج هر سه مدل نسبت به مقادیر مشاهداتی در طی زمان نشان داده شده که ضعف دو مدل برنامه‌ریزی بیان ژن و شبکه عصبی مصنوعی در تخمین دقیق برخی مقادیر حداقل و حداکثر را نشان می‌دهد، در حالیکه مقادیر میانی در برنامه‌ریزی بیان ژن به خوبی پوشش داده شده است.

جدول ۸- نتایج حاصل از آموزش و صحت سنجی مدل‌های شبکه عصبی بیزین، برنامه‌ریزی بیان ژن و شبکه عصبی مصنوعی

Table 8. The results of Bayesian neural network, gene expression programming and artificial neural network models training and validation

مدل	آموزش		صحت سنجی	
	NS	CC	NS	CC
شبکه عصبی بیزین	۰/۹۷۶	۰/۹۷۷	۰/۹۹۸	۰/۰۹۴
برنامه‌ریزی بیان ژن	۰/۷۳۴	۰/۹۷۵	۰/۷۶۷	۰/۱۷۱
شبکه عصبی مصنوعی	۰/۸۱۴	۰/۲۴۲	۰/۸۴۰	۰/۳۵۲



شکل ۷- نمودار پراکنش و مشاهداتی - محاسباتی مقادیر بهینه مدل شبکه عصبی بیزین، برنامه‌ریزی بیان ژن و شبکه عصبی مصنوعی برای داده‌های ثبت‌شده مرحله صحت سنجی

Figure 7. Diagram scatter plot and observations - computational Bayesian optimal neural network, gene expression programming and artificial neural network models for recorded data validation phase

تنظیم، سبب تسریع در روند همگرایی شبکه، بهینه نمودن وزن‌ها و کاهش خطای شبکه می‌شود. همچنین نتایج نشان داد به دلیل همبستگی پایین پارامتر دبی با مواد جامد محلول در آب تأثیر کمتری در تحلیل این پارامتر دارد که در مدل برنامه‌ریزی بیان ژن با ارائه روابط با توجه به عملگرهای انتخابی، وزن تأثیر هر یک از پارامترها در تخمین TDS را نیز نشان می‌دهد این امر مشهود است و این نتایج با پژوهش‌های (۱۲،۳) همخوانی دارد و میتوان بیان نمود معادله حاصل از برنامه‌ریزی بیان ژن، از ترکیب تصادفی مجموع ترمینال‌ها و توابع بدست می‌آید بنابراین اگر رابطه بین ورودی‌ها و خروجی‌ها خطی باشد ولی عملگرهای  $\sin$ ،  $\cos$  و ... در مجموعه توابع انتخاب شود برنامه‌ریزی بیان ژن در استخراج رابطه از آن عملگرهای انتخابی استفاده می‌کند که این امر باعث کاهش دقت مدل می‌شود که در این پژوهش جهت افزایش دقت مدل عملگرهای  $\sin$ ،  $\cos$  و ... کاربرد ندارد و نیز با توجه به دقت و سادگی، مدل حاصل از چهار عمل اصلی ریاضی جهت تخمین میزان مواد جامد محلول در آب پیشنهاد شد.

در این تحقیق سعی بر آن شد عملکرد مدل‌هایی جهت شبیه‌سازی میزان مواد جامد محلول در آب با استفاده از داده‌های ماهانه ایستگاه رودخانه بالخلوچای در اردبیل مورد ارزیابی قرار گیرد. مدل‌های به کار گرفته‌شده شامل شبکه عصبی بیزین، برنامه‌ریزی بیان ژن و شبکه عصبی مصنوعی می‌باشد. مقادیر مواد جامد محلول در آب مشاهداتی با مواد جامد محلول در آب تخمین زده شده در مدل‌های مذکور (شبکه عصبی بیزین، برنامه‌ریزی بیان ژن و شبکه عصبی مصنوعی)، با استفاده از معیارهای ارزیابی مورد مقایسه قرار گرفت. نتایج تحقیق را می‌توان بصورت زیر خلاصه نمود: با توجه به معیارهای ارزیابی نتیجه شد که هر سه روش موردبررسی، می‌توانند با دقت نسبتاً بالایی میزان مواد جامد محلول در آب را پیش‌بینی نمایند. در این میان، شبکه عصبی بیزین دقت بالایی در تخمین مقادیر کمینه و بیشینه دارد این نتایج با پژوهش‌های (۱۴،۷) مطابقت داشته است. در تبیین این نتایج می‌توان گفت در شبکه‌های عصبی بیزین با اختصاص وزن مناسب به هر یک از متغیرهای ورودی طبق قانون بیز، باعث کاهش میزان خطای شبکه می‌شود. همچنین استفاده از تقریب گوس نیوتن جهت محاسبه متغیرهای

## منابع

1. Dastorani, M.T., Kh. AzimiFashi and A. Talebi. 2011. Estimation of Suspended Sediment Using Artificial Neural Network. Watershed Management Research, 6: 61-74 (In Persian).
2. Dayhoff, J.E. 1990. Neural Network Principles. 1<sup>st</sup> ed., New York: Prentice-Hall International, 621 pp.
3. Dehghani, R. and S. MahmoudiVanalia. 2013. Performance analysis of gene expression programs related to chemical parameters in river flow rate (Case Study: Siminehrood). First International Congress on Science Earth, pp: 111-120 (In Persian).
4. Dogan, E., A. Ates and E. Ceren. 2008. Application of artificial neural networks to estimate wastewater treatment plant inlet biochemical oxygen demand. Environmental Progress & Sustainable Energy, 27: 439-446.
5. Faryadi, S., K. Shahedi and M. Nabatpoor. 2013. Investigation of Water Quality Parameters in Tadjan River using Multivariate Statistical Techniques. Watershed Management Research, 6: 75-92 (In Persian).
6. Ferreira, C. 2001. Gene expression programming: a new adaptive algorithm for solving problems. Complex Systems, 13: 87-129.
7. Fithriasari, K., N. Brodjol, U. Sutikno and H. Kuswanto. 2013. Prediction of Hourly Rainfall using Bayesian Neural Network with Adjusting Procedure. The Third Basic Science International Conference, pp: 1-5.
8. Foresee, F.D. 1997. Gauss-newton approximation to Bayesian regularization International Joint Conference on Neural Network, Houston, pp: 1930-1935.
9. Gazzaz, N.M., M.K. Yusoff, A. ZaharinAris, H. Juahir and M.F. Ramli. 2012. Artificial neural network modeling of the water quality index for Kinta River (Malaysia) using water quality variables as predictors. Journal of Marine Pollution Bulletin, 64: 2409-2420.
10. Ghorbani, M.A., V.P. Singh, M. Kashani and A. Kashani. 2012. Modelling pan evaporation using genetic programming. Journal of Statistics: Advances in Theory and Application, 8: 15-36.
11. Ghorbani, M.A., R. Khatibi, H. Asadi and P. Yousefi. 2012. Inter- Comparison of an Evolutionary Programming Model of Suspended Sediment Time-series whit other Local Model. INTECH. doi. org/10.5772/47801, 255-282.
12. Ghorbani, M.A. and A. Salehi. 2012. Use of the Gene Expression Planning in the study changes in groundwater quality whit fluctuations of the water level on the plains Barkhar in Esfahan. The Sixth National Congress on Civil Engineering Semnan, Iran, pp: 131-141 (In Persian).
13. Khanna, T. 1990. Foundation of neural networks: Addison-Wesley Series in New Horizons in Technology 1<sup>st</sup> ed. New York: Addison-Wesley, 521 pp.
14. Khan, M.S. and P. Coulibaly. 2006. Bayesian neural network for rainfall-runoff modeling, Water Resources Research, 42: 56-67.
15. Khatibi, R., L. Naghipour, M.A. Ghorbani and M.T. Aalami. 2012. Predictability of relative humidity by two artificial intelligence techniques using noisy data from two Californian gauging stations. Neural computing and application, 23: 2241-2252.
16. MacKay, D.J.C. 1992. Bayesian Interpolation, Neural Computation, 4: 415-447.
17. Najah, A., A. Elshafie, O. Karim and O. Jaffar. 2009. Prediction of Johor river water quality parameters using artificial neural networks. European Journal of scientific research, 28: 422-435.
18. Singh, K.P., A. Basant, A. Malik and G. Jain. 2009. Artificial neural network modeling of the river water quality-A Case Study. Journal of Ecological Modeling, 220: 888-895.
19. Tabatabai, S.A. and P. Dashtizadeh. 2008. Introduction to bayesian neural networks and use to the maintenance of bridges. 14<sup>th</sup> Student Conference of Civil Engineering. University of Semnan, pp: 85-93 (In Persian).
20. Tokar, A.S. and P.A. Johnson. 1999. Rainfall-Runoff modeling using artificial neural networks. Journal of Hydrology Engineering, 4: 232-239.
21. Yarmohamadi, A., M. Chitsazan, K. Rangzan and J. Mozafari Zadeh. 2006. The use of artificial neural networks in modeling water quality Karkhe. First Conference on Environmental Engineering, pp: 107-115 (In Persian).
22. Zhu, Y.M., X.X. Lu and Y. Zhou. 2007. Suspended sediment flux modeling with artificial neural network: An example of the Longchuanjiang River in the Upper Yangtze Catchment. Geomorphology, 84: 111-125.

## **Comparison of Bayesianneural Network, Artificial Neural Network Gene Expression Programming in River Water Quality (Case Study: Belkhviachay river)**

**Mohammad Ali Ghorbani<sup>1</sup> and Reza Dehghani<sup>2</sup>**

---

1- Associate Professor, University of Tabriz (Corresponding author: ghorbani@tabrizu.ac.ir)

2- Graduate M.Sc. Student, University of Tabriz

Received: December 26, 2014      Accepted: May 17, 2015

---

### **Abstract**

The amount of total dissolved solids (TDS) is an important factor in stream engineering, especially study of river water quality. This study estimates the TDS amount of Belkhviachayriver in Ardabil Province, using bayesian neural network-, gene smart and artificial neural network. Quality variables include hydrogen carbonate, chloride, sulfate, calcium, magnesium, sodium and inflow (Q) in monthly time scale during the period (1976-2009) as input and TDS were chosen as output parameters. The criteria of correlation coefficient, root mean square error and of Nash Sutcliff coefficientwere used to evaluate and performance compare ofmodels. The results showed that however the models could be used to estimate with reasonable accuracy the amount of dissolved solids in water deal, but regarding to accuracy, bayesian neural network model with the highest correlation (0.966), minimum root mean square error (0.094ppm) and the Nash Sutcliff (0.998) were put in the verification phase. The results showed that the bayesian neural network model to estimate high minimum and maximum values of dissolved solids in water.

**Keywords:** Ardebil, Model, Prediction, Total Dissolved Solids