

استخراج معادلات بهینه فرسایش خاک در آبیاری جویچه‌ای با استفاده از بهینه‌سازی پارتو و برنامه‌ریزی بیان چندژنی

حسین ریاحی مدوار^{۱*}، فاطمه سروش^۲

تاریخ دریافت: ۱۳۹۷/۰۹/۰۷ تاریخ پذیرش: ۱۳۹۸/۰۳/۱۸

چکیده

هدر رفت خاک از جمله پارامترهای مهم در طراحی و بهره‌برداری بهینه در سیستم‌های آبیاری جویچه‌ای است. طراحی آبیاری جویچه‌ای اغلب براساس مفاهیم هیدولیکی انجام می‌شود و به دلیل فقدان معادلات مناسب، تخمین مقدار هدررفت خاک زراعی، شستشوی مواد غذایی و کودی امکان برآورد و کمی‌سازی ندارد. از طرف دیگر اندازه‌گیری آن نیز پرهزینه، دشوار و زمان‌بر می‌باشد. هدف از تحقیق حاضر استفاده از قابلیت‌های محاسبات هوشمند در استخراج معادلات فرسایش خاک در آبیاری جویچه‌ای به روش بهینه‌سازی پارتو و برنامه‌ریزی بیان چندژنی است. بدین منظور یک پایگاه اطلاعاتی از اندازه‌گیری‌های صحرائی مقدار فرسایش خاک در آبیاری جویچه‌ای گردآوری شد و برنامه‌ریزی بیان چندژنی توامان با بهینه‌سازی پارتو و پیش پردازشگر حداکثر عدم تشابه بین الگوهای آموزش و آزمایش، برای استخراج معادلات بهینه استفاده شده است. تعداد ۱۴ مدل با ترکیب ورودی‌های مختلف توسعه یافت و بهترین رابطه در این زمینه ارائه گردید. ارزیابی نتایج شبیه‌سازی‌های صورت گرفته براساس معیارهای آماری R, RMSE, MAE, RAE, NSE بیانگر دقت مطلوب روش پیشنهادی در شناسایی متغیرهای موثر و استخراج فرم صریح معادلات فرسایش خاک در آبیاری جویچه‌ای است و قابلیت کاربرد در مباحث طراحی و بهره‌برداری آبیاری جویچه‌ای را دارد.

واژه‌های کلیدی: برنامه‌ریزی بیان چندژنی، بهینه‌سازی پارتو، فرسایش خاک، آبیاری جویچه‌ای، الگوریتم SSMD

مقدمه

بالادست جویچه موجب جداسازی ذرات خاک و انتقال آنها به پایین دست جویچه گردد. علاوه بر این با کاهش نرخ جریان در طول جویچه، ظرفیت جداسازی و حمل رسوبات کاهش یافته و منجر به ته نشست رسوبات می‌شود (Fernandez-Gomez et al., 2004). در سیستم‌های آبیاری جویچه‌ای انتها باز مقدار زیادی از خاک مزرعه پس از فرسایش توسط جریان رواناب از جویچه یا مزرعه خارج می‌شود (Carter, 1993). از این رو فرسایش ناشی از آبیاری جویچه‌ای در آلودگی غیر نقطه‌ای و کاهش کیفیت آب رودخانه‌ها و دریاچه‌ها مشارکت نموده (Bjorneberg, et al., 1999) و تهدیدی جدی برای بهره‌وری محصول در بسیاری از مناطق است (Carter, 1993). علاوه بر این فرسایش شاخص‌های کیفیت فیزیکی خاک مانند ظرفیت نگهداری آب خاک و پایداری ساختمان خاک را کاهش می‌دهد (Wallace and Terry, 1998). در ایران با وجود گسترش سیستم‌های آبیاری تحت فشار ۸۵ درصد اراضی فاریاب به روش سطحی آبیاری می‌شوند (عباسی و همکاران، ۱۳۹۵). بنابراین توسعه یک روش مناسب برای تخمین تلفات فرسایش در آبیاری جویچه‌ای به منظور تدوین برنامه مدیریت جامع اراضی کشاورزی و حفاظت کیفیت آب‌های سطحی مورد نیاز است. مدل‌سازی می‌تواند ابزاری

فرسایش ناشی از آبیاری در مناطق خشک و نیمه خشک مانند ایران یکی از مهمترین مشکلات در رابطه با کشاورزی پایدار است. فرسایش خاک در سیستم‌های آبیاری سطحی که از سطح خاک برای انتقال و توزیع آب در سطح مزرعه بهره می‌گیرند، قابل توجه می‌باشد (Bjorneberg and Sojka, 2000). فرسایش در سیستم آبیاری سطحی جویچه‌ای که در آن آب در کانال‌های کم عمق جریان پیدا می‌کند، شدیدتر است (Trout and Neibling, 1993). در سیستم آبیاری جویچه‌ای آب از انتهای فوقانی جویچه به آن وارد می‌شود. زمانی که آب در طول جویچه پیش می‌رود، به علت نفوذ آب دبی جریان در طول جویچه کاهش می‌یابد. نرخ جریان ورودی باید به اندازه کافی زیاد باشد تا آب به انتهای جویچه برسد و نیاز آبی گیاهان در طول جویچه را تأمین نماید، بنابراین ممکن است جریان آب در

۱- استادیار گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه ولی عصر (عج) رفسنجان، ایران

۲- استادیار گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه ولی عصر (عج) رفسنجان، ایران

(Email: h.riahi@vru.ac.ir)

* - نویسنده مسئول:

قطره‌چکان‌های سیستم‌های آبیاری قطره‌ای با استفاده از روش برنامه‌نویسی بیان ژن (ریاحی و سیفی، ۱۳۹۵)، طراحی آرایش قطره‌چکان‌های سیستم‌های آبیاری قطره‌ای با استفاده از معادلات تجربی و روش برنامه‌نویسی بیان ژن (عراقی و بایگی، ۱۳۹۶)، برآورد ضریب دبی در سرریزهای لبه تیز(فرودی خور و همکاران، ۱۳۹۶)، بهینه‌سازی آبیاری شیاری با استفاده از الگوریتم جفت‌گیری زنبور عسل (ریحانی و همکاران، ۱۳۹۴)، تحلیل عدم قطعیت خروجی شبکه عصبی مصنوعی در شبیه‌سازی هدایت هیدرولیکی (پوررضا بیلندی و خاشعی، ۱۳۹۴)، پیش‌بینی تبخیر توسط مدل‌های KNN^8 و $M5$ (خلیلی نفت‌چالی و همکاران، ۱۳۹۶)، از جمله مواردی است که نشان‌دهنده کاربرد موفق مدل‌های هوش مصنوعی و محاسباتی در مهندسی آبیاری است. علی‌رغم مطالعات گسترده در زمینه مدل‌سازی فرسایش و رسوب در آبراهه و رودخانه‌ها، مطالعات در زمینه مدل‌سازی فرسایش در آبیاری جویچه‌ای با استفاده از مدل‌های هوش مصنوعی محدود به یک پژوهش می‌گردد که در آن تلفات رسوب در آبیاری جویچه‌ای با استفاده از الگوریتم شبکه عصبی مصنوعی (ANN) و شرایط هیدرولیکی جریان و وضعیت خاک برآورد شده است. نتایج دلالت بر مطلوبیت مدل در برآورد تلفات رسوب در آبیاری جویچه‌ای داشت ولی در این پژوهش معادلات تخمین‌گر ارائه نشده است (King et al., 2015). نتایج مدل‌های هوش مصنوعی در صورت استفاده از پایگاه‌های داده‌ای اندک در مدل‌سازی قابل تعمیم نمی‌باشد. بنابراین استفاده از پایگاه‌های داده‌ای گسترده و انتخاب زیر مجموعه‌های آموزش و آزمون از مسائل مهمی است که باید در مدل‌سازی با این روش‌ها مورد توجه قرار گیرد. در بسیاری از پژوهش‌ها زیرمجموعه‌های آموزش و آزمون به طور تصادفی و با سعی و خطا انتخاب می‌شوند. به هر حال زیرمجموعه آموزش باید مقادیر حدی حداقل/حداکثر را برای استخراج الگوی داده‌ها پوشش دهد. همچنین، بهینه‌سازی معادلات دراستحکام نتایج برآوردها اهمیت زیادی دارد. این مطالعه با تاکید بر سه مفهوم، انتخاب الگوهای بهینه آموزش و آزمایش از پایگاه داده‌ای گسترده، راه حل بهینه پارتو و معادله صریح چندژنی پیش‌بینی هدررفت خاک در آبیاری جویچه‌ای صورت گرفته است. در این مقاله برای نخستین بار روش انتخاب زیرمجموعه‌ها با روش حداکثر عدم تشابه⁹ (SSMD) در ترکیب با برنامه‌ریزی ژنتیک چند ژنی بر اساس بهینه‌سازی پارتو¹⁰ (POMGGP) برای استخراج روابط پیش‌بینی هدررفت خاک در آبیاری جویچه‌ای با استفاده از یک پایگاه داده‌ای وسیع به منظور

موثر برای پیش‌بینی و برنامه‌ریزی برای فرسایش ناشی از آبیاری جویچه‌ای باشد. پیش‌بینی فرسایش در آبیاری جویچه‌ای عمدتاً بر اساس معادلات تجربی فرسایش باران انجام می‌شود در حالی که شرایط فیزیکی مورد استفاده برای تعیین توابع فرسایش جویباری تحت بارش-رواناب با آبیاری جویچه‌ای بسیار متفاوت است (Bjorneberg et al., 2000) و فرایندهای موثر بر فرسایش و رسوب‌گذاری (جدا شدن، انتقال و ته نشست) در آبیاری جویچه‌ای به اندازه کافی توسط معادلات فرسایش جویباری ناشی از باران سنجیده نمی‌شود (Trout and Neibling, 1993; Neibling et al. 1991). مطالعاتی در زمینه ارزیابی مدل‌های فرسایش محور فرسایش جویچه‌ای انجام گردیده است. این مطالعات نشان داده است که مدل فرسایش محور WEPP، بدون تعدیل قابل توجه مقادیر پارامتر فرسایش‌پذیری نمی‌تواند برای پیش‌بینی آبیاری جویچه‌ای به کار رود (Bjorneberg et al., 1999). بنابراین اگرچه مدل‌های فرسایش محور برای درک فرایندهای فرسایش جویچه‌ای اهمیت دارند، مدل‌های موجود نمی‌توانند تلفات فرسایش در آبیاری جویچه‌ای را بهتر از مدل‌های تجربی که تلفات رسوب را به پارامترهای قابل اندازه‌گیری مانند شیب، نرخ جریان و خصوصیات خاک مانند بافت مربوط می‌نمایند، پیش‌بینی نمایند (Trout and Neibling 1993)؛ (Bjorneberg et al., 2010). یک مدل تجربی تلفات خاک در آبیاری سطحی¹ (SISL) توسط سرویس حفاظت منابع طبیعی آیداهو² (NRCS) توسعه یافته است. ارزیابی مدل SISL با استفاده از داده‌های شش مزرعه نشان داد که مدل اثرات نسبی اقدامات حفاظتی را به نسبت خوب نشان می‌دهد، و اختلاف مطلق بین مقادیر اندازه‌گیری شده و پیش‌بینی شده اغلب زیاد بود (Bjorneberg et al., 2007). در سال‌های اخیر مطالعات بسیاری در زمینه استفاده از روش‌های هوش مصنوعی با هدف حل مسائل غیر خطی مهندسی آب انجام شده است. برای نمونه سیستم استنتاج نروفازی³ (ANFIS)، شبکه عصبی مصنوعی⁴ (ANN)، برنامه‌نویسی ژنتیک⁵ (GP)، ماشین بردار پشتیبان⁶ (SVM) و برنامه‌نویسی بیان ژن⁷ (GEP) به عنوان جایگزین روش‌های متداول در حل مسائل مهندسی معرفی شده است (Azamathulla and Ahmad, 2012; Bahramifara et al., 2013; Haddadchi et al. 2013). بررسی کارایی برنامه‌نویسی بیان ژن (GEP) در تخمین ضریب زبری مانینگ در کانال‌های روباز با شکل بستر تلماسه (روشنگر و همکاران، ۱۳۹۷)، طراحی آرایش

- 1- Surface Irrigation Soil Loss
- 2- Natural Resources Conservation Service
- 3- Adaptive Neuro-Fuzzy Inference System
- 4- Artificial Neural Network
- 5- Genetic Programming
- 6- Support Vector Machine
- 7- Gene Expression Programming

8- K-Nearest Neighbors

9- Subset Selection of Maximum Dissimilarity Method (SSMD)

10- Multi-Gene Genetic Programming based on Pareto Optimal solution (POMGGP)

زمان کافی و جزئیات دقیق وجود دارد (Ferreira, و Koza, 1992). در ابتدا کرموزومها از جمعیت اولیه به صورت تصادفی تولید می‌شوند. سپس کرموزومها بیان می‌شوند و با در نظر گرفتن تابع برازش مورد نظر، هزینه هر کرموزوم ارزیابی می‌شود. سپس کرموزومها با در نظر گرفتن هزینه‌شان دوباره تولید یا اصلاح می‌گردند. گام بعدی شامل، فراهم کردن افراد جدید از طریق فرایندهای مشابه از جمله بیان ژنوم، سازگاری با انتخاب محیط و بازتولید با اصلاح، می‌شود. فرایند مذکور تا زمانی که تعداد قابل توجه نسل یا خطای قابل قبول مدل حاصل شود، تکرار می‌گردد (Ferreira, 2006). در این مطالعه GEP برای مجموعه داده‌های رسوب آبیاری جویچه‌ای توسعه داده شد، مدل‌سازی شامل پنج مرحله عمده جهت آماده‌سازی برای استفاده از برنامه‌نویسی بیان ژن است. گام اول انتخاب تابع برازش است. برای این مدل‌سازی فرسایش در آبیاری جویچه‌ای، مطلوبیت (f_i) یک برنامه (i) با روش زیر اندازه‌گیری می‌شود.

$$f_i = \sum_{j=1}^{C_i} (M - |C_{(i,j)} - T_j|) \quad (1)$$

که در آن M دامنه انتخاب، $C_{(i,j)}$ مقدار بازگشتی توسط کرموزوم i برای برازش مورد z و T_j مقدار مشاهده شده برای z مورد برازش می‌باشد. اگر $|C_{(i,j)} - T_j|$ کمتر یا مساوی 0.1 باشد، سپس دقت مساوی صفر و $f_i = f_{\max} = C_i M$ خواهد بود. در این حالت $M = 100$ استفاده می‌شود، بنابراین در $f_{\max} = 1000$ خواهد بود. دومین گام در مدل‌سازی GEP، شامل تعیین توابع ریاضی است که کرموزومها اجازه کاربرد آنها در برنامه‌های خود و معادله نهایی را دارند. هیچ قانون قطعی در انتخاب ترکیب تابع ریاضی وجود ندارد. در این مطالعه چهار توابع ریاضی پایه $\{+, \cdot, /, \times\}$ و توابع ریاضی پیچیده‌تر مانند لگاریتم، نمایی، توانی، ریشه سوم، تانژانت، سینوس، تانژانت هایپربولیک و ... استفاده شدند. گام سوم تعیین معماری کرموزومی است که شامل تعیین طول سر و تعداد ژن‌ها می‌باشد. در مطالعه حاضر برای تعیین این دو پارامتر از روش آزمون و خطا استفاده شد. GEP برای ترکیبات متفاوتی از طول سر و تعداد ژن اجرا گردید. علاوه بر این از آنجایی که جمعیت اولیه در بازه $100-300$ منجر به نتایج قابل قبول می‌گردد (Ferreira, 2001)، جمعیت اولیه ۵۰ در این پژوهش مد نظر قرار گرفت. گام چهارم در روند مدل‌سازی GEP انتخاب تابع پیوند مناسب است. مطالعات اخیر در زمینه کاربرد GEP نشان داده است که افزودن تابع پیوند منجر به دقت بیشتر می‌شود (Ferreira, 2001). در گام آخر مدل‌سازی GEP عملگرهای ژنتیک که GEP در فرایند تولیدمثل به کار می‌برد، تعیین می‌شود. عملگرهای ژنتیک منجر به تنوع نسل‌های تکاملی می‌شوند. برخلاف نرخ جهش که با صحیح و خطا تعیین می‌شود، دیگر عملگرهای

دستیابی به معادلات صریح صورت گرفته است. هدف اصلی تحقیق حاضر استخراج معادلات فرسایش خاک در آبیاری جویچه‌ای با استفاده از بهینه‌سازی پارتوو برنامه‌ریزی بیان چندژنی با ترکیب پیش-پردازشگر حداکثر عدم تشابه SSMD است.

مواد و روش‌ها

بایگانه داده‌های مورد استفاده

فرسایش تحت تاثیر تنش برشی آب، انسجام ذرات خاک و ظرفیت انتقال آبراهه می‌باشد (Trout and Kemper et al., 1985) و در آبیاری جویچه‌ای بستگی به دبی جریان، شیب، بافت خاک، طول جویچه و سطح مقطع جویچه دارد (Fornstrom and Borrelli, 1985). بنابراین در این مطالعه پارامترهای طول (L)، شیب (S_0)، زمان آبیاری (T_{co})، دبی ورودی به جویچه (Q_{in}) از داده‌های چندین آزمایش مزرعه‌ای فرسایش در آبیاری جویچه‌ای (اخوان و همکاران، ۱۳۹۴؛ Fitzsimmons, 1978, Damodhara et al., 2009؛ Araujo, 2014؛ Raiesi Vanani et al., 2017؛ Fornstrom and Borrelli, 1985) برای مدل‌سازی تلفات خاک در آبیاری جویچه‌ای استفاده شد. داده‌ها شامل ۱۰۱۸ آزمایش فرسایش در آبیاری جویچه‌ای می‌باشد که گستره‌ای از شرایط خاک، محصول، وضعیت مزرعه و شرایط هیدرولیکی را در برمی‌گیرد (جدول ۱).

استفاده از برنامه‌ریزی بیان ژن (GEP) در مدل‌سازی فرسایش در آبیاری جویچه‌ای

روش برنامه‌ریزی بیان ژن (GEP)، تعمیمی از برنامه‌نویسی ژنتیک (GP)، یک روش هوش مصنوعی تکاملی است (Ferreira, 2002). GEP مشتمل بر برنامه‌های کامپیوتری نمادین با طول و شکل‌های مختلف می‌باشد که به صورت کرموزوم‌های خطی با اندازه ثابت کدگذاری می‌شوند. در نتیجه اطلاعات کرموزومها به صورت درخت‌های بیان^۱ (ET) رمزگشایی می‌شود، این فرایند ترجمه نامیده می‌شود. فرایند کدگذاری بسیار ساده است، به این ترتیب که ET کرموزومها را از چپ به راست و از بالا به پایین می‌خواند. هر ژن در اولین موقعیت آغاز می‌شود. به هر حال نقطه پایانی همیشه موقعیت آخرین ژن نیست و چارچوب خوانش باز مورد استفاده قرار می‌گیرد (Ferreira, 2002). درخت‌های بیان (ET) برنامه‌های کامپیوتری هستند که به طور معمول با هدف حل یک مشکل خاص توسعه داده شده و بر اساس مطلوبیتشان برای حل یک مسأله انتخاب می‌شوند. تغییرات ژنتیکی متنوع ویژگی‌های جمعیت موجود را کشف می‌کند و در نتیجه به یک مسأله خاص به عنوان راه حل برازش داده می‌شود. این بدان معنی است که راه حل مناسبی برای حل مسأله مورد نظر با

زیرمجموعه آموزشی تعریف شده است که به صورت زیر نمایش داده می‌شود:

$$X = \begin{bmatrix} x_{11} & x_{21} & \dots & x_{p1} \\ x_{12} & x_{22} & \dots & x_{p2} \\ \vdots & \vdots & \dots & \vdots \\ x_{1N} & x_{2N} & \dots & x_{pN} \end{bmatrix} \quad (3)$$

در هر مرحله هدف انتخاب نقاط با فاصله یکنواخت در سطح مورد نظر می‌باشد. اولین نقطه نزدیک به میانگین داده‌ها و دومی در دورترین فاصله از اولین نقطه انتخاب می‌گردد. سومین نقطه اختیار شده در دورترین نقطه از دو نقطه پیشین واقع شده است (Seifi and Riahi, 2018). نقاط آموزشی بعدی با حداکثر کردن فاصله حداقل بین زیرمجموعه آموزشی و نقاطی که در مجموعه داده‌های اولیه باقی مانده‌اند، انتخاب می‌شوند (Rossel and Webster, 2012). اگر مربع فاصله بین i امین و j امین نقطه به صورت D_{ij}^2 تعریف شود و k نقطه قبلاً انتخاب شده باشد ($k < p$)، سپس حداقل فاصله از نقطه k تا N تا k نقطه به صورت زیر تعریف می‌شود:

$$D_{ij}^2 = \|x_i - x_j\|^2 = \sum_{k=1}^p (x_{ki} - x_{kj})^2 \quad (4)$$

$\Delta_i^2(k) = \min(D_{1i}^2, D_{2i}^2, \dots, D_{ki}^2)$ $i \neq m$
نقطه N هنوز در زیرمجموعه آموزشی که پیش از این در آن k نقطه بوده‌اند، نمی‌باشد. نقطه $(k+1)$ ام در زیرمجموعه آموزشی از $N-k$ نقطه دیگر به صورت زیر انتخاب می‌شود:

$$\Delta_{k+1}^2 = \max(\Delta_i^2(k)) \quad i \neq m \quad (5)$$

که نقطه N متعلق به بقیه مجموعه داده‌ها است که دورترین فاصله از نقاط موجود می‌باشد. در این مطالعه به ترتیب ۷۰٪ و ۳۰٪ کل داده‌ها به عنوان زیرمجموعه‌های آموزش و آزمون با تکنیک SSMD انتخاب می‌شوند. مراحل الگوریتم SSMD مورد استفاده در تحقیق حاضر به صورت زیر می‌باشد (Riahi-Madvar and Seifi, 2018):
۱) نرمال‌سازی نقاط درمجموعه داده‌ها، ۲) انتخاب اولین عدد از مجموعه X با حداکثر x_{1N} و قرار دادن آن در زیرمجموعه M به عنوان s_1 ، ۳) انتخاب دومین نقطه از مجموعه داده‌ها با حداکثر فاصله تا s_1 و قرار دادن آن در زیرمجموعه M با عنوان s_2 ، ۴) تکرار مراحل ۲-۳ برای k گام، مجموعه داده‌ای از X $P-k$ داده را در بر می‌گیرد، که زیرمجموعه M شامل k داده می‌باشد. فاصله بین اعضای مجموعه M و بقیه اعضای مجموعه داده‌ای X محاسبه می‌شوند. ۵) تکرار گام ۴ تا زمانی که ۷۰٪ نقاط مجموعه داده‌ای مرجع در M یا $k=M_N$ قرار گیرند و ۶) غیرنرمال‌سازی داده‌های انتخاب شده در مجموعه‌های X و M . در جدول ۱ ویژگی‌های آماری زیرمجموعه‌های انتخاب شده به روش SSMD را نشان می‌دهد. همچنین شکل‌های ۱ و ۲ توزیع زیرمجموعه‌های آموزش و آزمون انتخابی توسط SSMD را نشان می‌دهد. از جدول ۱ و شکل ۱ می‌توان نتیجه گرفت که تکنیک SSMD قادر به پخش مقادیر حدی بین زیرمجموعه‌های آموزش و

ژنتیک به صورت مقایسه اولیه پیشنهادی GEP فرض شد (Ghani et al., 2010 و Azamathulla et al., 2011).

پیش‌پردازش داده‌ها و استخراج الگوهای آموزش و ارزیابی با الگوریتم SSMD

برای پیش‌بینی مناسب، ضروری است که مدل با انتخاب مجموعه آموزشی مناسب به طور مطلوب آموزش و واسنجی شود. مرحله آموزش به مجموعه داده‌هایی که به منظور آموزش استفاده می‌شود، بستگی دارد. هیچ روش منحصر به فردی برای انتخاب مجموعه داده‌های آموزش و آزمون وجود ندارد. در مطالعات پیشین هوش مصنوعی، روش‌های سعی و خطا و اعتبار سنجی متقابل، عموماً در انتخاب زیرمجموعه‌ها به کار گرفته شده است (Riahi et al., 2009; Bozorg-Haddad et al., 2016; Doycheva et al., 2017). در این مطالعه یک الگوریتم قابل اعتماد برای تقسیم داده‌ها به زیرمجموعه‌ها و استخراج مجموعه آموزشی مناسب مورد بررسی قرار گرفت. یکی از عوامل اصلی در انتخاب مجموعه آموزش و آزمون آن است که ویژگی‌های آماری مجموعه‌های آموزش و آزمون باید همگن باشد (Riahi and Seifi, 2018). برای مثال اگر مجموعه داده‌های آموزش شامل مقادیر حدی نباشد، و مجموعه آزمون چندین مقدار حدی داشته باشد، مدل نمی‌تواند به درستی مقادیر حدی را پیش‌بینی نماید و لازم است توزیع مقادیر حدی در هر دو مجموعه یکسان باشد. در غیر اینصورت کاربرد فراگیر مدل‌های آموزش دیده کاهش می‌یابد. برای حل این مسأله روش انتخاب زیر مجموعه با حداکثر عدم تشابه (SSMD) برای کشف الگوی پنهان داده‌ها جهت آموزش و آزمون زیرمجموعه‌ها استفاده می‌شود. روش SSMD قادر به انتخاب مجموعه داده‌های آموزش و آزمون به گونه‌ای است که ویژگی‌های آماری زیرمجموعه‌ها شامل حداکثر، حداقل، میانگین و انحراف معیار داده‌ها ثابت می‌ماند که پیش‌بینی قابل اعتماد مدل را تضمین می‌کند. الگوریتم SSMD به زمینه خاصی از داده‌ها تمرکز نمی‌کند، بلکه الگوهای داده‌های با بیشترین تفاوت را با بقیه در مجموعه داده‌های انتخاب شده دارند (Lajiness and Watson, 2008) تا رفتار کلی مجموعه داده‌ها مشخص گردد. برای حذف اثر مقیاس، پیش از انتخاب، داده‌ها به صورت زیر نرمال می‌شوند (Wang and Huai, 2016).

$$x_n = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

سپس زیرمجموعه‌های ایجاد شده به صورت زیر غیرنرمال می‌شوند:

$$x_i = x_n (x_{\max} - x_{\min}) + x_{\min} \quad (2)$$

پارامتر X مجموعه داده‌ها به صورت $X = (x_1, x_2, \dots, x_p)$ می‌باشد و یک مجموعه $m = 1, 2, \dots, N$ نقطه به عنوان نامزد

مدلسازی می‌باشد. برای یک پایگاه داده‌ای جامع مانند آنچه در این مقاله استفاده شده است، SSMD با گسترش حدود پوششی مجموعه آموزشی، استفاده فراگیر پیش‌بینی‌های انجام شده را تقویت می‌نماید. در جدول ۲ مدل‌های مختلف توسعه یافته و همچنین در جدول ۳ همبستگی بین متغیرهای مختلف نشان داده شده است و مشاهده می‌شود که هم بستگی قوی و مستقیمی بین متغیرهای موثر با مقدار فرسایش خاک در آبیاری جویچه‌ای وجود ندارد و نشان‌دهنده پیچیدگی شرایط حاکم بر پدیده فرسایش در آبیاری جویچه‌ای است و لزوم استفاده از مدل‌های قدرتمند در استخراج روابط پنهان بین متغیر هدف را مشهود می‌سازد.

آزمون می‌باشد که انتخاب زیرمجموعه‌ها بر اساس صحیح و خطا را منتفی نموده و قابلیت کاربرد و اعتبار پیش‌بینی‌ها را بهبود می‌بخشد. شکل ۱ نشان می‌دهد که توزیع زیرمجموعه آموزشی مرزهای پایگاه داده را در برمی‌گیرد و اعضای زیرمجموعه آزمون در محدوده زیرمجموعه آموزش قرار می‌گیرد، بنابراین انتظار می‌رود که مدل‌های آموزش دیده با SSMD بتوانند رفتار داده‌های پرت را تشخیص دهند. بر اساس نتایج شکل‌های ۱ و ۲ تغییرات متغیرها در زیرمجموعه آموزش بزرگتر از زیرمجموعه آزمون می‌باشد که تعمیم مدل‌های برونیاب را افزایش می‌دهد. یکی از قابلیت‌های برجسته SSMD، دربرگرفتن داده‌های حدی در مجموعه آموزشی و عدم حذف آنها از

جدول ۱- ویژگی‌های آماری مجموعه داده‌های الگوهای آموزش و آزمایش حاصله از الگوریتم SSMD

Kurt.	Skew	Max	Third Quartile	Median	First Quartile	Min	S.D.	Mode	Mean	پارامتر مجموعه داده‌ها
۱/۳۵	-۰/۳۲	۱۴/۱۱	۱۳/۲۳	۱۱/۲۹	۹/۰۷	۷/۴۱	۲/۴۴	۷/۵۷	۱۱/۰۲	L (m)
۲۳/۵۰	۴/۳۶	۲/۱۷	۱/۲۲	۱/۲۲	۱/۲۲	۱/۱۲	۰/۱۶	۱/۲۲	۱/۲۵	S (%)
۸/۴۹	-۰/۷۵	۸/۵۹	۴/۷۲	۴/۲۵	۳/۹۶	-۰/۰۰	۰/۶۱	۳/۹	۴/۳۷	I(L/min)
۱/۶۹	-۰/۴۷	۵/۹۲	۴/۹	۴/۹	۳/۴۶	۲/۸۳	۰/۸	۴/۹	۴/۴۲	T (h)
۳/۳۸	-۰/۹۳	۱۷۴/۷۷	۶۱/۰۸	۳۱/۵۱	۸/۹۱	-۰/۰۳	۳۵/۴۹	۰/۱۵	۳۹/۳۴	Qs(kg/ha)
۱/۳۵	-۰/۰۵	۱۴/۱۱	۱۳/۲۳	۱۱/۲۹	۸/۴۶	۷/۴۱	۲/۴	۷/۵۷	۱۰/۸۵	L (m)
۱۸/۶۷	۳/۹	۲/۱۷	۱/۲۲	۱/۲۲	۱/۲۲	۱/۱۲	۰/۱۸	۱/۲۲	۱/۲۶	S (%)
۸/۸۴	-۰/۶۹	۸/۵۹	۴/۷۷	۴/۲	۳/۹۶	-۰/۰۰	۰/۶۵	۰/۰۰	۴/۳۸	I(L/min)
۱/۶۲	-۰/۳۶	۵/۹۲	۴/۹	۴/۹	۳/۴۶	۲/۸۳	۰/۸۳	۴/۹	۴/۳۹	T (h)
۳/۳۵	-۰/۸۸	۱۴۷/۷۷	۶۷/۷۸	۳۹/۵	۱۵/۳	-۰/۰۳	۳۵/۷	۰/۱۵	۴۵/۴۴	Qs(kg/ha)
۱/۵۷	-۰/۰۶	۱۴/۱۱	۱۳/۲۸	۱۳/۱۵	۹/۲۷	۷/۴۱	۲/۴۸	۱۳/۱۵	۱۱/۴۲	L (m)
۵۳/۲	۶/۱	۲/۱۷	۱/۲۲	۱/۲۲	۱/۲۲	۱/۱۲	۰/۱	۱/۲۲	۱/۲۴	S (%)
۴/۳۸	-۰/۸۷	۶/۴۸	۴/۶۲	۴/۳۴	۳/۹۷	۳/۵۳	۰/۵۱	۳/۵۳	۴/۳۴	I(L/min)
۱/۹۶	-۰/۷۹	۵/۵۷	۴/۹	۴/۹	۳/۴۶	۲/۸۳	۰/۷۳	۴/۹	۴/۵	T (h)
۳/۳۹	۱/۱۸	۱۱۸/۴۴	۴۶/۹۵	۱۰/۶۹	۰/۳۰	-۰/۱۰	۳۰/۶۷	۰/۲۴	۲۵/۱۵	Qs(kg/ha)

L: طول جویچه (m); S: شیب متوسط جویچه (%); I: دبی متوسط ورودی به جویچه (Lit/min); T: زمان آبیاری (hr) و Qs: تلفات رسوب (kg/ha)

جدول ۲- ترکیبات مختلف ورودی‌های مدل GEP در استخراج معادلات فرسایش آبیاری جویچه‌ای


شماره مدل	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	M11	M12	M13	M14
پارامترهای ورودی	L	S	I	T	L,S	L,I	L,T	S,I	S,T	I,T	L,S,I	L,S,T	S,I,T	L,S,I,T
پارامتر خروجی	Qs	Qs	Qs	Qs	Qs	Qs	Qs	Qs	Qs	Qs	Qs	Qs	Qs	Qs

نتایج و بحث


در این پژوهش برای استخراج معادلات تخمین مقدار فرسایش خاک در آبیاری جویچه‌ای از مدل GEP با ترکیب ورودی‌های مختلف استفاده شد و طبق جدول ۲ تعداد ۱۴ مدل مختلف توسعه یافت و در نهایت از بین مدل‌های برتر روابط صریحی برای میزان فرسایش در آبیاری جویچه‌ای ارائه شد.

معیارهای ارزیابی نتایج مدل‌ها

ارزیابی مدل‌های پیشنهادی، شامل دقت و تطابق با استفاده از ضوابط ارزیابی میانگین ریشه مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE)، راندمان نش-سانکلیف (NSE)، ضریب تعیین (R2)، شاخص تطابق (d)، شاخص پایداری (PI)، شاخص اطمینان (CI) و خطای مطلق نسبی (RAE) انجام شد (جدول ۴). همچنین برای ارزیابی پیش‌بینی‌های مدل، از مقایسه نموداری استفاده می‌شود.



شکل ۱- توزیع و پوشش زیرمجموعه‌های آموزش و آزمون حاصله از الگوریتم SSMID



شکل ۲- همپوشانی مجموعه‌های آموزش و آزمایش هدررفت خاک در جویچه‌های آبیاری به روش SSMD

جدول ۳- ضرایب همبستگی بین پارامترها

L	S	I	T	Qs	
1.00	0.07	0.41	-0.23	-0.54	L
0.07	1.00	0.10	0.01	-0.06	S
0.41	0.10	1.00	-0.35	-0.31	I
-0.23	0.01	-0.35	1.00	0.19	T
-0.54	-0.06	-0.31	0.19	1.00	Qs

مقادیر بهینه پارامترها و توابع برنامه‌ریزی ژنتیک با شبیه‌سازی-های مختلف تعیین شد و در نهایت برای هر مدل از ۱۴ مدل جدول ۲ براساس تحلیل پارتو بهترین مدل از بین جمعیت نسل‌های مختلف استخراج شد. در جدول ۵ نتایج شاخص‌های آماری مدل‌های مختلف ارائه شده است. طبق نتایج جدول ۵ مشاهده می‌شود که از بین ۴ مدل اول که به ترتیب پارامترهای طول جویچه (L)، شیب طولی (S)، شدت جریان ورودی (I) و زمان (T) را بعنوان تک ورودی دارند تنها مدل اول (M1) نتایج و دقت بهتری در تخمین مقدار فرسایش دارد و موثرترین متغیر طول جویچه و در مرتبه بعدی متغیر شیب و دبی ورودی بر میزان هدررفت خاک در آبیاری جویچه‌ای هستند. همانگونه که در جدول شماره ۳ مشاهده شد همبستگی بین پارامترهای چهارگانه فوق با مقدار فرسایش ناچیز است و بالاترین میزان همبستگی مربوط به پارامتر L با همبستگی معکوس ۰/۵ است. در جدول ۵ نیز مشاهده می‌شود که استفاده از تک متغیرهای S، I، T بعنوان ورودی به مدل GEP باعث افزایش خطای پیش‌بینی شده است. در بهترین مدل تک متغیره M1 مقادیر پارامترهای R، RMSE، MAE، RAE، NSE در مرحله آموزش به ترتیب برابر

۰/۳۸، ۰/۷۷، ۰/۲۲/۲۵، ۲۸/۱۰، ۰/۶۲ و در مرحله آزمایش به ترتیب ۰/۴۱، ۰/۷۵، ۰/۱۹/۱۴، ۲۳/۵۷ و ۰/۶۲ بدست آمده است. بنابراین مدل تک متغیره تابع طول جویچه بعنوان بهترین مدل از بین چهار مدل M1، M2، M3، M4 انتخاب شده است. تعداد ۶ مدل دومتغیره براساس ترکیب پارامترهای ورودی طبق جدول ۲ توسعه یافت (M5-M10) و براساس نتایج در جدول ۵ ملاحظه می‌شود که بهترین نتایج به ترتیب مربوط به مدل‌های M5، M6، M7 است. همانگونه که این نتایج نشان می‌دهد با افزایش تعداد متغیرهای ورودی به مدل GEP دقت نتایج نیز افزایش یافته است. طبق نتایج مدل‌های دومتغیره در جدول ۵ بهترین نتایج مربوط به مدل‌هایی است که متغیر L بعنوان ورودی به مدل معرفی شده است (M5، M6، M7) و کمترین دقت نیز مربوط به مدل‌های مبتنی بر پارامترهای S-I و S-T و T-I است (M8، M9، M10). نکته قابل توجه دیگر در مقایسه نتایج در دو حالت آموزش و آزمون نشان می‌دهد انتخاب الگوهای موثر متغیرهای ورودی با تکنیک SSMD باعث می‌شود که نتایج مدل‌های در مرحله آموزش همواره از درجه مطلوبیت کافی در مقایسه با نتایج مرحله آموزش برخوردار باشد. بنابراین با استفاده از پیش‌پردازشگر SSMD

به ترتیب برابر ۰/۴۳، ۰/۷۴، ۲۱/۴۶، ۲۶/۹۸، ۰/۶۵ و در مرحله آزمایش به ترتیب ۰/۴۳، ۰/۷۵، ۱۹/۰۲، ۲۳/۰۹ و ۰/۷۴ در مدل M12 بعنوان بهترین مدلی که براساس ترکیب سه متغیر آموزش یافته است بدست آمده است. همچنین نتایج مدل M14 که براساس ترکیب هر چهار متغیر ورودی آموزش یافته است نیز در جدول ۵ آمده است و مشاهده می‌شود که نتایج این مدل نیز در مراحل آموزش و آزمایش دارای دقت مطلوبی است. بنابراین طبق نتایج جدول ۵ و براساس مقادیر پارامترهای آماری مشاهده می‌شود که مدل‌های M1، M14، M12، M6، M5 بعنوان مدل‌های برتر برای پیش‌بینی فرسایش خاک در آبیاری جویچه‌ای می‌باشند و مدل M14 از این منظر برتر است.

حساسیت نتایج مدل پیش‌بینی نسبت به محدوده تغییرات داده‌ها کاهش می‌یابد. مشکلات بیش‌برازش که در مدل‌های تخمین‌گر در شرایط محدودیت داده‌ها رخ می‌دهد و برای رفع آن نیاز به حذف مقادیر اکستریم یا گزینش دستی مقادیر حدی در مجموعه آموزش است با استفاده از رویکرد SSMD برطرف می‌شود (Riahi et al., 2009; Riahi and Seifi, 2018). در رویکرد SSMD انتخاب الگوهای آموزش و آزمایش بصورت خودکار انجام می‌شود و تضمین عدم رخداد بیش‌برازش در مرحله آموزش و دقت کم در مرحله آزمون را ایجاد می‌نماید. مدل‌های M11، M12، M13 از نوع مدل‌های سه متغیره هستند و طبق نتایج در جدول ۵ مقادیر پارامترهای آماری پیش‌بینی مدل MAE, RAE, NSE R, RMSE در مرحله آموزش

جدول ۴- معیارهای ارزیابی عملکرد مدل‌های پیش‌بینی


نام	فرمول	دامنه تغییرات	بهینه	نکته
میانگین مربعات خطا، RMSE	$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (O_i - P_i)^2}$	(0, ∞)	•	شبیه خطای MSE می‌باشد، تحت تاثیر حذف داده‌ها قرار نمی‌گیرد. مربع کردن داده‌ها ممکن است موجب انحراف به سمت وقایع بزرگ شود. نتایج RMSE واحد مشابهی با داده‌های اصلی دارد که تفسیر آن را راحت‌تر می‌سازد.
میانگین قدر مطلق خطا، MAE	$MAE = \frac{1}{N} \sum_{i=1}^N O_i - P_i $	(0, ∞)	•	مشابه با RMSE است با این تفاوت که قدر مطلق داده‌ها استفاده می‌شود. این امر از انحراف به سمت وقایع بزرگ را کاهش می‌دهد. اما استفاده از آن در بهینه‌سازی یک عملر غیر یکنواخت می‌سازد
راندمان نش-ساتکیف، NSE	$NSE = 1 - \frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (O_i - \bar{O})^2}$	(-∞, 1)	∧	این روش کارایی مدل را با مدلی که تنها از میانگین داده‌های مشاهداتی استفاده می‌کند، مقایسه می‌کند. مقدار ۱ یک مدل عالی را نشان می‌دهد در حالیکه مقدار صفر نشان می‌دهد که کارایی مدل بهتر از استفاده از میانگین نیست و عدد منفی کارایی بدتر مدل را نشان می‌دهد.
ضریب تعیین، R2	$R^2 = \left(\frac{\sum_{i=1}^N (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^N (O_i - \bar{O})^2} \sqrt{\sum_{i=1}^N (P_i - \bar{P})^2}} \right)^2$	(0, 1)	∧	مقدار مربع ضریب همبستگی پیرسون بین مقادیر اندازه‌گیری و مدل‌سازی شده است. عیب آن فرض خطی بودن مدل می‌باشد و در حقیقت برای مدل‌های با انحراف (افست) ثابت نتایج عالی به همراه دارد.
شاخص تطابق، d	$d = 1 - \frac{\sum_{i=1}^N (P_i - O_i)^2}{\sum_{i=1}^N (P_i - \bar{O} + O_i - \bar{O})^2}$	(0, 1)	∧	این روش مجموع مربعات خطا را با خطای پتانسیل مقایسه می‌نماید. این روش مشابه ضریب تعیین می‌باشد ولی طوری طراحی شده است که در برخورد با اختلاف در میانگین و واریانس مدل‌سازی و مشاهده شده بهتر عمل کند.
شاخص پایداری، PI	$PI = 1 - \frac{\sum_{i=1}^N (O_i - P_i)^2}{\sum_{i=1}^N (O_i - O_{i-1})^2}$	-	-	شاخص پایداری مجموع مربعات خطا را با خطایی که اگر مقدار پیش‌بینی شده به صورت مقدار مشاهداتی پیشین بود، رخ می‌داد؛ مقایسه می‌نماید. مشابه NSE است به جز آنکه مدل با مقدار مشاهداتی پیشین مقایسه می‌شود.
خطای مطلق نسبی، RAE	$RAE = \frac{\sum_{i=1}^N O_i - P_i }{\sum_{i=1}^N O_i - \bar{O} }$	(0, ∞)	•	کل خطای نسبی را با آنچه خطای مدل می‌بود اگر میانگین برای مدل‌سازی استفاده می‌شد، مقایسه می‌نماید. مقادیر کمتر کارایی بهتر را نشان می‌دهد در حالی که مقادیر بیش از یک نشان می‌دهد که مدل با استفاده از میانگین به عنوان پیش‌بینی بهتر عمل کرده است

برای مدل M14 ارایه شده است. طی مرحله بهینه‌سازی پس از اینکه مدل در تمامی نسلها برای جمعیت بهینه‌سازی اجرا شد روند شبیه‌سازی متوقف شده (شکل ۷) و مرحله به‌گزینی براساس تحلیل پارتو طبق شکل ۳ انجام می‌شود. مجموعه معادلات هر مدل براساس




به منظور دستیابی به معادله نهایی پیش‌بینی مقدار فرسایش در آبیاری جویچه‌ای، اقدام به استخراج فرم صریح معادلات براساس تحلیل نتایج پارتو شد. در شکل ۳ الف عبارات بیان ژنی چندگانه و در شکل ۳ ب نتایج بهینه‌سازی پارتو روی جمعیت معادلات تولید شده

نتایج مدل به ترتیب طول جویچه و شیب طولی بستر جویچه و دبی جریان ورودی به جویچه هستند. طبق نتایج در شکل ۵ مشاهده می‌شود که مدل در مقادیر فرسایش کم اندکی بیش تخمینی و در مقادیر فرسایش بالا دارای مقداری کم تخمینی است ولی با اینحال روند کلی حاکم بر فرسایش در آبیاری جویچه‌ای را به خوبی تخمین زده است. البته متغیرهای موثر دیگری از قبیل دانه‌بندی مصالح بستر و بدنه جویچه، بافت خاک، ضرایب چسبندگی خاک، خصوصیات هندسی جویچه و ترکیب شیمیایی خاک می‌تواند بر میزان فرسایش خاک موثر باشد و لازم است که در مطالعات صحرایی اندازه‌گیری این متغیرها نیز لحاظ شود. معادله نهایی بدست آمده در این تحقیق نسبت به نتایج تحقیق (King et al., 2016) هم محدود بزرگتری از مقادیر فرسایش را در بر گرفته است و هم برخلاف نتایج ANN مطالعه ایشان صورت صریح قابل استفاده است. ارجحیت نتایج GEP بر دیگر روشها در تحقیقات قبلی نیز تایید شده است (Zakaria et al., 2012, Chang et al., 2010). علاوه بر این همانگونه که نتایج شکل ۳ نشان می‌دهد استفاده از بهینه‌سازی پارتو منجر به دستیابی به معادله بهینه از بین ۴۰۰ معادله برای ترکیب M14 است که گزینش خودکار شکل و ضرایب را بعد از ۱۰۰ نسل در شکل ۶ الف انجام می‌دهد. توزیع خطای نتایج مدل در شکل ۷ نیز نشان می‌دهد که مدل بخوبی توانسته است الگوی حاکم بر پدیده را شبیه‌سازی نماید و در محدوده مقادیر جدول ۱ از دقت مطلوبی برخوردار است و معادله پیشنهادی را می‌توان در ترکیب با مدل‌های شبیه‌ساز آبیاری سطحی و کیفیت آب در آبیاری جویچه‌ای استفاده نمود و همچنین از آن در بهینه‌سازی طراحی سیستم‌های آبیاری جویچه‌ای با حداقل مقدار فرسایش استفاده نمود. در آبیاری جویچه‌ای تعداد آبیاری‌های قبلی نیز بر میزان فرسایش و درجه مسلح شدن بستر جویچه موثر است که با گذشت زمان باعث کاهش میزان فرسایش از مقدار تخمینی اولیه این معادلات می‌شود. همانگونه که نتایج مطالعات قبلی نشان داده است (اخوان و همکاران، ۱۳۹۴؛ Damodhara et al., 2009, RaeisiVanani et al., 2017) طول جویچه بر مقدار فرسایش موثر است و با افزایش طول جویچه و حرکت در مسیر جویچه میزان فرسایش کاهش می‌یابد که با نتایج تحقیق حاضر همخوانی دارد. خصوصیات نفوذپذیری خاک نیز یکی از متغیرهای موثر بر میزان فرسایش در آبیاری سطحی است که تاکنون مطالعه چندانی روی آن انجام نشده است و می‌تواند در بررسی پدیده فرسایش آبیاری جویچه-ای مدنظر قرار گیرد.

تحلیل پارتو بهینه‌سازی شده و بهترین مدل با بالاترین درجه دقت و کمترین درجه پیچیدگی طبق شکل ۳ ب انتخاب شده است. مجموعه معادلات استخراج شده برای ۵ مدل برتر در جدول ۶ ارایه شده است. همچنین در این جدول عبارات چندزنی مربوط به هر مدل و وزن هر مولفه ژنی نیز آمده است. وزن هر مولفه ژن در جدول ۶ نشان‌دهنده درجه اهمیت عبارت متناظر آن در معادله نهایی است. همانگونه که ستون آخر جدول ۶ روابط هر مدل را نشان می‌دهد در تمامی معادلات بهینه‌یابی شده پارامتر L بعنوان مهمترین و موثرترین پارامتر از بین مجموعه پارامترهای موجود است که در تمامی روابط نهایی نیز وارد شده است. بنابراین مشاهده می‌شود که این مدل دارای توان انتخاب متغیرهای مؤثر بر فرسایش خاک در آبیاری جویچه‌ای و حذف متغیرهایی است که تأثیر کمتری دارند، می‌باشد. دو معادله حاصله از مدل‌های M5, M6 هم از پیچیدگی زیادی برخوردار می‌باشند و همچنین مشابه معادله M1 فقط تابعی از L هستند بنابراین این سه معادله نیز از انتخاب نهایی حذف می‌شوند. از بین دو معادله M12, M14 در جدول ۵ معادله M14 دارای دقت بالاتری است و بنابراین بعنوان معادله برتر و نهایی در برآورد مقدار فرسایش خاک در آبیاری جویچه‌ای پیشنهاد می‌شود. ساختار درختی بیان نمادین معادله نهایی M14 در شکل ۳ الف و تحلیل پارتو آن در شکل ۳ ب ارایه شده است و همچنین مقایسه بین نتایج مراحل مختلف آموزش و آزمایش و کل داده‌های حاصل از معادله ژنتیکی M14 و داده‌های اندازه‌گیری شده در شکل‌های ۴ و ۵ انجام شده است. مقایسه معادلات جدول ۵ نشان می‌دهد که هرچند دقت مدل M14 بهتر از مدل M1 است ولی مدل M14 نیازمند در دسترس بودن اطلاعاتی از قبیل طول جویچه، شدت جریان ورودی و شیب جویچه است بنابراین هرگاه با محدودیت داده روبرو هستیم میتوان از معادله M1 استفاده نمود و برآورد مناسبی از مقدار فرسایش خاک در آبیاری جویچه‌ای داشت و هرگاه اطلاعات دیگر متغیرهای نیز موجود است می‌توان از معادله M11 بعنوان معادله منتخب نهایی استفاده نمود. شایان ذکر است با توجه به اینکه از بین مدل‌های مختلف هوش مصنوعی فقط مدل GEP توان استخراج فرم صریح روابط حاکم بر پدیده را دارد در این تحقیق شبیه‌سازی‌ها فقط به همین روش انجام شده است و از مدل‌های هوشمند دیگر همچون ANFIS, SVR, ANN که اغلب بصورت جعبه سیاه عمل می‌نمایند استفاده نشده است. روند همگرایی برنامه GEP نسبت به نسل‌های مختلف جهش و توسعه برنامه نمادین مربوطه در برآورد رابطه فرسایش در شکل ۶ الف و توزیع خطای کل مقادیر در الگوی آموزش و آزمایش در شکل ۶ ب آمده است. همانگونه که در بالا بحث شد مدل GEP از دقت مطلوبی در برآورد فرسایش آبیاری جویچه‌ای دارد و طبق نتایج موثرترین متغیرها بر



شکل ۳- نتایج مدل عبارات چندژنی در تخمین فرسایش آبیاری جویچه‌ای (الف)- ساختار درختی ب) بهینه‌سازی پارتو معادلات




شکل ۴ - مقایسه نتایج مدل MI4 در پیش‌بینی فرسایش آبیاری جویچه‌ای در مقایسه با مقادیر اندازه‌گیری شده در مراحل الف) آموزش ب) آزمایش و ج) کل داده‌ها

جدول ۵ - نتایج مدل‌های مختلف GEP در مراحل آموزش، آزمون و همه داده‌ها


مدل	الف) آموزش GEP										ب) آزمون GEP										ج) همه داده‌ها									
	CI	NSE	d	RAE	PI	MAE	RMSE	R	CI	NSE	d	RAE	PI	MAE	RMSE	R	CI	NSE	d	RAE	PI	MAE	RMSE	R						
۱	۰/۶۲	۰/۵۵	۰/۷۳	۰/۷۷	۰/۵۵	۲۲/۲۵	۲۸/۱۰	۰/۶۲	۰/۶۸	۰/۳۸	۰/۳۳	۰/۸۱	۰/۷۵	۰/۶۸	۱۹/۱۴	۲۲/۵۷	۰/۷۱	۰/۳۳	۰/۴۱	۰/۳۳	۰/۴۱	۰/۳۳	۲۶/۸۲	۰/۶۶						
۲	۰/۴۷	۰/۳۰	۰/۳۲	۰/۹۵	۰/۱۲	۲۷/۴۵	۳۴/۳۰	۰/۴۷	۰/۲	۰/۰۸	۰/۰۳	۰/۵۲	۰/۱۷	۰/۱۹	۲۹/۹۶	۳۳/۸۷	۰/۳۰	۰/۱۸	۰/۱۲	۰/۱۲	۰/۱۲	۲۸/۲۰	۰/۴۱							
۳	۰/۱۴	۰/۹۹	۰/۴۷	۰/۹۰	۰/۲۷	۲۵/۹۹	۳۲/۹۹	۰/۱۴	۰/۰۷	۰/۱۴	۰/۰۷	۰/۱۱	۰/۲۸	۲۸/۴۳	۳۲/۲۵	۰/۳۳	۰/۰۷	۰/۰۷	۰/۰۷	۰/۰۷	۰/۰۷	۲۶/۲۲	۰/۸۸							
۴	۰/۰۸	۰/۱۴	۰/۳۹	۰/۹۵	۰/۱۵	۲۷/۳۹	۳۴/۱۴	۰/۰۸	۰/۰۳	۰/۰۸	۰/۰۳	۰/۵۰	۰/۲۶	۳۲/۰۵	۳۶/۱۸	۰/۰۶	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۲۸/۷۹	۰/۰۷							
۵	۰/۶۳	۰/۷۲	۰/۷۵	۰/۵۶	۰/۵۶	۲۲/۱۱	۰/۷۲	۰/۳۰	۰/۳۰	۰/۴۰	۰/۳۰	۰/۸۲	۰/۷۵	۱۹/۱۲	۲۲/۷۷	۰/۷۶	۰/۳۳	۰/۴۱	۰/۳۳	۰/۴۱	۰/۳۳	۲۶/۳۳	۰/۶۸							
۶	۰/۶۳	۰/۶۱	۰/۷۵	۰/۵۸	۰/۵۸	۲۱/۸۴	۲۷/۶۱	۰/۳۰	۰/۳۰	۰/۴۰	۰/۳۰	۰/۸۲	۰/۷۵	۱۹/۱۲	۲۲/۷۷	۰/۷۶	۰/۳۳	۰/۴۱	۰/۳۳	۰/۴۱	۰/۳۳	۲۶/۳۳	۰/۶۸							
۷	۰/۵۵	۰/۷۰	۰/۶۸	۰/۸	۰/۴۸	۲۳/۰۹	۲۹/۷۰	۰/۳۰	۰/۳۰	۰/۴۰	۰/۳۰	۰/۸۲	۰/۷۵	۱۹/۱۲	۲۲/۷۷	۰/۷۶	۰/۳۳	۰/۴۱	۰/۳۳	۰/۴۱	۰/۳۳	۲۶/۳۳	۰/۶۸							
۸	۰/۴۷	۰/۵۰	۰/۵۷	۰/۸۵	۰/۳۷	۲۴/۶۹	۳۱/۵۰	۰/۴۷	۰/۱۳	۰/۲۲	۰/۱۳	۰/۶۸	۰/۸۵	۲۲/۰۶	۲۶/۷۷	۰/۶۷	۰/۱۸	۰/۱۲	۰/۱۲	۰/۱۲	۰/۱۲	۲۸/۲۸	۰/۶۶							
۹	۰/۴	۰/۶۹	۰/۳۷	۰/۳۷	۰/۳۷	۲۵/۶۴	۳۲/۶۹	۰/۴	۰/۰۶	۰/۱۶	۰/۰۶	۰/۵۰	۰/۲۶	۳۲/۰۵	۳۶/۱۸	۰/۰۶	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۲۸/۷۹	۰/۰۷							
۱۰	۰/۲۶	۰/۲۵	۰/۳۳	۰/۳۳	۰/۳۳	۲۶/۰۲	۳۳/۲۵	۰/۲۶	۰/۰۶	۰/۱۳	۰/۰۶	۰/۵۰	۰/۲۶	۳۲/۰۵	۳۶/۱۸	۰/۰۶	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۲۸/۷۹	۰/۰۷							
۱۱	۰/۵۸	۰/۰۷	۰/۵۱	۰/۵۱	۰/۵۱	۲۳/۰۶	۲۹/۰۷	۰/۵۸	۰/۰۶	۰/۱۳	۰/۰۶	۰/۵۰	۰/۲۶	۳۲/۰۵	۳۶/۱۸	۰/۰۶	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۲۸/۷۹	۰/۰۷							
۱۲	۰/۶۵	۰/۶۸	۰/۴۳	۰/۴۳	۰/۴۳	۲۱/۴۶	۲۶/۶۸	۰/۶۵	۰/۰۳	۰/۰۳	۰/۰۳	۰/۵۰	۰/۲۶	۳۲/۰۵	۳۶/۱۸	۰/۰۶	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۲۸/۷۹	۰/۰۷							
۱۳	۰/۳	۰/۷۳	۰/۵۶	۰/۵۶	۰/۵۶	۲۷/۷۸	۳۶/۷۳	۰/۳	۰/۰۳	۰/۰۳	۰/۰۳	۰/۵۰	۰/۲۶	۳۲/۰۵	۳۶/۱۸	۰/۰۶	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۲۸/۷۹	۰/۰۷							
۱۴	۰/۶۴	۰/۸۵	۰/۳۳	۰/۳۳	۰/۳۳	۲۱/۹۸	۲۸/۸۵	۰/۶۴	۰/۰۳	۰/۰۳	۰/۰۳	۰/۵۰	۰/۲۶	۳۲/۰۵	۳۶/۱۸	۰/۰۶	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۰/۰۲	۲۸/۷۹	۰/۰۷							

جدول ۶- معادلات بهینه‌استخراج شده GEP در تخمین فرسایش در آبیاری جویچه‌ای و عبارات ژنی چندگانه معادل

معادله بهینه سازی شده	عبارات بیان ژن چندگانه و وزن‌های آنها	وزن ژن‌های چندگانه	شماره مدل
$y = 5.29 \sin(0.237L^2) - 16.8 \sin(1.89L^2) - 8.5L + 0.0743 L^2 \sin(L^2) + 20.2 \sin(L^2)^2 + 129.0$	Bias	129.0	M1
	Gene 1	$5.29 \sin(0.237L^2)$	
	Gene 2	$-16.8 \sin(1.89L^2)$	
	Gene 3	$-8.5L$	
	Gene 4	$20.2 \sin(L^2)^2$	
$y = 8.52e^4 \tan^{-1}(\sin(\sin L)) - 2.48 \sin((L - 1.05)^L) - 6.22 \sin((L - 3.82)^{L/S}) - 49.5L - 8.07e^4 \tanh(\sin(\sin(L))) + 11.2 \sin((L + 2.19)^{L+2.19}) - 4222 \sin(L) - (4.44e^{-16}(6.54e^{14}L - 2.5e^{15})) / \sin(L) + 2.01L^2 + 338$	Gene 5	$0.0743L^2 \sin(L^2)$	M5
	Bias	258	
	Gene 1	$2.01L^2 - (1(0.291L - 1.11)) / \sin(L)$	
	Gene 2	$-6.22 \sin((L - 3.82)^{L/S})$	
	Gene 3	$80.5 - 49.5L$	
	Gene 4	$11.2 \sin((L + 2.19)^{L+2.19})$	
	Gene 5	$-4222 \sin(L)$	
	Gene 6	$-2.48 \sin((L - S)^L)$	
$y = 26.3L + 17 \tanh(\sin(3.63L)) - 8.04 \sin(31.1L) - 0.376L^2 \sin(28.7L) - L^2(1.88 - 0.0958i) + 0.909 \sin(28.7L) (3.63L + L^{1/2} - 1) + 6.78e^{10}$	Gene 7	$-8.07e^4 \tanh(\sin(28.7L))$	M6
	Gene 8	$8.52e^4 \tan^{-1}(\sin(\sin(L)))$	
	Bias	-17.9	
	Gene 1	$-0.376L^2 \sin(28.7L)$	
	Gene 2	$26.3L$	
	Gene 3	$-1.88L^2 - 2$	
	Gene 4	$17 \tanh(\sin(3.63L))$	
	Gene 5	$-8.04 \sin(31.1L)$	
$y = 14.9T - 8.87 \cos(5.18L) - 6.51 \cos(6.58L) - 16.5 \cos(27.6L) - 23 \cos(8L^3) - 12.4 \cos((L + 4.87)^3) - 5.42 \cos((T + 4.99)^3) - 0.0057(L + T + 6.58)^3 + 56.3$	Gene 6	$\sin(28.7L)(3.3L + 0.909L^{1/2} - 0.909)$	M12
	Gene 7	$L^2 0.0958i$	
	Gene 8	$6.78e^{10}$	
	Bias	56.3	
	Gene 1	$-0.0057(L + T + 6.58)^3$	
	Gene 2	$-6.51 \cos(6.58L)$	
	Gene 3	$-12.4 \cos(1.0(L + 4.87)^3)$	
	Gene 4	$-23.0 \cos(8.0L^3)$	
$y = (0.24L) / \sin(L) - 8.29 \sin(L + 7.34) - 15.8L - 230 / (\tanh(L)(L - 1)) + (8.29T) / L + (3.65 \sin(5.32 \times L \times S)) / \sin(L) - (0.33T) / \sin(39.1L) + 258$	Gene 5	$-5.42 \cos(1.0(T + 4.99)^3)$	M14
	Gene 6	$14.9T$	
	Gene 7	$-8.87 \cos(5.18L)$	
	Gene 8	$-16.5 \cos(27.6L)$	
	Bias	258	
	Gene 1	$(8.29T) / L - 8.29 \sin(L + 7.34) - 15.8L$	
	Gene 2	$(3.65 \sin(5.32L \times S)) / \sin(L)$	
	Gene 3	$-(0.33T) / \sin(39.1L)$	
Gene 4	$(0.24L) / \sin(L)$		
Gene 5	$-(230 \coth(L)) / (L - 1)$		



شکل ۵- مقایسه مقادیر پیش‌بینی مدل M14 با مقادیر اندازه‌گیری شده در کل داده‌های تحقیق



شکل ۶- روند همگرایی مدل GEP در دستیابی به معادله نهایی و (ب) توزیع خطای مقادیر پیش‌بینی روی کل داده‌های آموزش و آزمایش

نتیجه‌گیری

در این مقاله با گردآوری پایگاه داده‌ها و اطلاعاتی پیرامون مشخصات جریان و فرسایش خاک در آبیاری سطحی به روش جویچه‌ای مدلی مبتنی بر برنامه نویسی چندبیین ژنی با قابلیت بهینه‌سازی پارتو توسعه یافته است که بهینه‌سازی فرم صریح معادلات و روابط برآورد مقدار فرسایش و هدررفت خاک در آبیاری جویچه‌ای را فراهم می‌سازد. به منظور بهبود دقت نتایج مدل و حذف خطای بیش‌برازش از رویکرد پیش‌پردازش SSMD استفاده شده است که به‌گزینی روی الگوهای حاکم بر داده‌ها انجام داده و مجموعه‌های آموزش و آزمایش را بصورت خودکار انتخاب می‌نماید. در این مطالعه پارامترهای طول (L)، شیب (S0)، زمان آبیاری (Tco)، دبی ورودی به جویچه (Qin) از ۱۰۱۸ مطالعه میدانی گردآوری شد و ۱۴ حالت با تمامی ترکیب‌های ممکن و مختلف از این متغیرهای ورودی توسعه یافت و براساس نتایج بهینه‌سازی پارتو بهترین معادله تخمین‌گر بدست آمد. در بهترین مدل تک متغیره M1 مقادیر پارامترهای R, RMSE, MAE, RAE, NSE در مرحله آموزش به ترتیب برابر ۰/۳۸، ۰/۷۷، ۰/۲۲، ۰/۲۸، ۰/۶۲ و در مرحله آزمایش به ترتیب ۰/۴۱، ۰/۷۵، ۰/۱۹، ۰/۲۳، ۰/۶۲ بدست آمده است. بنابراین مدل تک متغیره تابع طول جویچه بعنوان بهترین مدل از بین چهار مدل‌های تک متغیره انتخاب شده است. در بین مدل‌های سه متغیره مقادیر پارامترهای آماری پیش‌بینی مدل MAE, RAE, R, RMSE, NSE در مرحله آموزش به ترتیب برابر ۰/۴۳، ۰/۷۴، ۰/۲۱، ۰/۲۶، ۰/۶۵ و در مرحله آزمایش به ترتیب ۰/۴۳، ۰/۷۵، ۰/۱۹، ۰/۲۳ و ۰/۷۴ در مدل M12 بعنوان بهترین مدلی که براساس ترکیب سه متغیره آموزش یافته است بدست آمده است. و بهترین نتایج در تمامی مدل‌های مربوط به مدل M14 با هر چهار متغیره ورودی است که مقادیر مقادیر پارامترهای R, RMSE, MAE, RAE, NSE در مرحله آموزش به ترتیب برابر ۰/۳۸، ۰/۷۶، ۰/۲۱، ۰/۲۸، ۰/۶۶ و در مرحله آزمایش به ترتیب ۰/۳۶، ۰/۸۱، ۰/۲۰، ۰/۲۴، ۰/۷۷ بدست آمده است و بعنوان رابطه بهینه‌سازی شده نهایی برای تخمین میزان فرسایش در آبیاری جویچه‌ای پیشنهاد می‌شود. در تمامی معادلات بهینه‌یابی شده پارامتر L بعنوان مهمترین و موثرترین پارامتر از بین مجموعه پارامترهای موجود است که در تمامی روابط نهایی نیز وارد شده است. طبق نتایج مشاهده شد که دقت نتایج بهینه‌سازی، مبتنی بر برنامه نویسی بیان ژن در تخمین مقدار هدررفت خاک در مراحل دوگانه توسعه و ارزیابی مطلوب است و مدل قادر است هم فرم صریح معادلات را استخراج نماید و هم متغیرهای موثر را با تحلیل پارتو همزمان روی درجه پیچیدگی و دقت شناسایی نماید. با توجه به نتایج مطلوب رویکرد پیشنهادی تحقیق حاضر در شبیه‌سازی

فرسایش خاک، می‌توان بیان نمود که با داشتن روابط کاربردی با دقت مناسب این امکان فراهم است تا طراحی سیستم‌های آبیاری جویچه‌های و مشخصات جویچه‌ها به صورتی انجام شود که در زمان بهره‌برداری هدررفت خاک و نتیجتاً هدررفت کود و مواد غذایی کنترل شده و ناچیز گردد. با قطعیت و اطمینان بیشتری بهره‌برداری از آنها انجام داده و راندمان این سیستم‌ها را در مسائل کاربردی به مقادیر تئوری نزدیک نمود. در ادامه تحقیق حاضر و به منظور توسعه هر چه بهتر مجموعه روابط، گردآوری اطلاعات و داده‌هایی از متغیرهای دیگر آبیاری جویچه‌ای همچون مشخصات بافت خاک و ارزیابی تاثیر گذاری آنها بر مقدار فرسایش و هدررفت خاک قابل توصیه است.

منابع

- اخوان، س.، افشار، سروش، ف. ۱۳۹۴. اثر کاربرد پلی‌اکریل‌آمید بر میزان فرسایش خاک در آبیاری جویچه‌ای و جویچه‌اییک در میان. نشریه آبیاری و زهکشی ایران، ۹: ۱۵۲-۱۶۲.
- عراقی، علیرضا، موسوی بایگی، محمد. (۱۳۹۶). برآورد دمای خاک با استفاده از مدل‌های ترکیبی بر پایه تبدیل موجک گسسته. نشریه آبیاری و زهکشی ایران. 876-887, 11(5),
- فرودی خورر، علی، صانعی، مجتبی، اژدری مقدم، مهدی. (۱۳۹۶). مقایسه سامانه استنتاج فازی- عصبی تطبیقی (ANFIS) و سامانه ماشین بردار پشتیبان (SVM) در تخمین میزان ضریب دبی سرریزهای لبه‌تیز. نشریه آبیاری و زهکشی ایران- 11(5), 772, 784.
- پوررضا بیلندی، محسن، خاشعی سیوکی، عباس. (۱۳۹۴). تحلیل عدم قطعیت خروجی شبکه عصبی در شبیه‌سازی هدایت هیدرولیکی اشباع خاک. نشریه آبیاری و زهکشی ایران. 655-664, 9(4),
- خلیلی نفت چالی، آ.، خاشعی سیوکی، ع.، شهیدی، ع. (1396). مقایسه مدل‌های KNN و درخت تصمیم M5 در پیش‌بینی تبخیر و مقایسه آن با مدل‌های تجربی (مطالعه موردی بیرجند). (نشریه آبیاری و زهکشی ایران. 356-366, 11(3),
- روشنگر، ک.، اعملی، م. ت.، ثاقبیان، س. م. ۱۳۹۷. پیش‌بینی ضریب زبری مانینگ در کانال‌های روباز با فرم بستر تلماسه با استفاده از روش الگوریتم تکاملی. نشریه آبیاری و زهکشی ایران، ۱۲: ۴۵۷-۴۴۶.
- ریاحی‌مدوار، ح.، سیفی، ا. ۱۳۹۵. بررسی عملکرد روش برنامه‌نویسی

- runoff and soil erosion for furrow irrigation. *Transactions of the ASAE*. 42. 6: 1733-1742.
- Carter, D.L. 1993. Furrow irrigation erosion lowers soil productivity. *Journal of Irrigation and Drainage*. 119. 6: 964-974.
- Chang, C. K., Azamathulla, H. M., Zakaria, N. A., & Ab Ghani, A. (2012). Appraisal of soft computing techniques in prediction of total bed material load in tropical rivers. *Journal of earth system science*, 121(1), 125-133. <https://doi.org/10.1007/s12040-012-0138-1>
- Chiang, J. L., Tsai, Y. S., 2011. Suspended sediment load estimate using support vector machines in Kaoping river basin. *The International Conference on Consumer Electronics, Communications and Networks*. pp. 1750-1753.
- Mailapalli, D. R., Raghuvanshi, N. S. and Singh, R. 2009. Sediment transport in furrow irrigation. *Irrigation Science*. 27. 6:449-456.
- Ebtehaj, H., Bonakdari, H., Zaji, A. H., Azimi, H. and Sharifi, A. 2015. Gene expression programming to predict the discharge coefficient in rectangular side weirs. *Applied Soft Computing*. 35: 618-628.
- Emamgholizadeh, S. and Karimi-Demneh, R. 2018. The comparison of artificial intelligence models for the estimation of daily suspended sediment load: a case study on Telar and Kasilian Rivers in Iran. *Water Science & Technology: Water Supply*. <https://doi.org/10.2166/ws.2018.062>
- Fernández-Gomez, R., Mateos, L. and Giráldez, J. V. 2004. Furrow irrigation erosion and management. *Irrigation Science*. 23. 3: 123-131.
- Ferreira, C. 2001. Gene expression programming: a new adaptive algorithm for solving problems. *Complex Systems*. 13. 2: 87-129.
- Ferreira, C. 2002. Gene expression programming in problem solving, in: R. Roy, M.Kppen, S. Ovaska, T. Furuhashi, F. Hoffmann (Eds.), *Soft Computing and Industry: Recent Applications*, Springer-Verlag.
- Ferreira, C. 2006. *Gene Expression Programming: Mathematical Modeling by an Artificial Intelligence*, 2nd ed. (Rev.), Springer-Verlag, Berlin, NY, USA.
- Fitzsimmons, D. W. 1978. Evaluation of measures for controlling sediment and nutrient losses from irrigated areas. Rep. No. EPA-600/2-78-138, U.S. EPA, Washington, DC.
- Fornstrom, K. J. and Borrelli, J. 1985. Sediment losses from furrow irrigated croplands in Wyoming. Final Project Rep., Agricultural Engineering Dept., Univ. of Wyoming, Laramie, WY.
- Ghani, A.A., Azamathulla, H. Md. 2010. Gene expression programming for prediction of sediment transport in furrow irrigation. *Journal of Irrigation and Drainage Engineering*. 136(4): 485-491.
- عباسی، ف.، سهراب، ف.، عباسی، ن. ۱۳۹۵. ارزیابی وضعیت راندمان آب آبیاری در ایران. تحقیقات مهندسی سازه‌های آبیاری و زهکشی. ۱۷. ۶۷: ۱۲۸-۱۱۳.
- ندیری، ع.، طاهرخانی، ز.، صادقی اقدم، ف. ۱۳۹۶. پیش‌بینی سطح آب زیرزمینی دشت بستان آباد با استفاده از ترکیب نظارت شده مدل‌های هوش مصنوعی. تحقیقات منابع آب ایران، ۳. ۱۳: ۵۵-۴۳.
- Araujo, D. F. 2014. Measurement of furrow irrigation erosion considering soil and water conservation. Unpublished Ph.D. thesis, Agricultural Sciences Center, Federal University of Ceará, (in Portuguese).
- Azamathulla, H. M. and Ahmad, Z. 2012. Gene-expression programming for transverse mixing coefficient. *Journal of Hydrology*. 434-435: 142-148.
- Azamathulla, H. Md., Ghani, A.A., Leow, C.S., Chang, C.K., Zakaria, N.A. 2011. Gene expression programming for the development of a stage-discharge curve of the Pahang River, *Water Resources Management*. 25. 1: 2901-2916.
- Bahramifar, A., Shirkhani, R. and Mohammadi, M. 2013. An ANFIS-based approach for predicting the manning roughness coefficient in alluvial channels at the bank-full stage. *International Journal of Engineering*. 26. 2: 177-186.
- Baylar, A., Unsal, M. and Ozkan, F. 2011. GEP modeling of oxygen transfer efficiency prediction in aeration cascades. *KSCE Journal of Civil Engineering*. 15. 5: 799-804.
- Bjorneberg, D.L., Kincaid, D.C., Lentz, R.D., Sojka, R.E., and Trout, T.J. 2000. Unique aspects of modeling irrigation-induced soil erosion. *International Journal of Sediment Research*. 15. 2: 245-252.
- Bjorneberg, D.L., Prestwich, C.J. and Evans, R.G. 2007. Evaluating the surface irrigation soil loss (SISL) model. *Applied Engineering in Agriculture*. 23. 4: 485-491.
- Bjorneberg, D.L., Strelkoff, T.S., Clemmens, A.J., and Lee, J. 2010. The current state of predicting furrow irrigation erosion. Proc., 5th Decennial Irrigation Conf., ASABE, St. Joseph, MI.
- Bjorneberg, D.L., Trout, T.J., Sojka, R.E., and Aase, J.K. 1999. Evaluating WEPP-predicted infiltration,

- 6:114–122.
- Roushangar, K., Vojoudi-Mehrabani, F. and Shiri, J. 2018. Modeling river total bed material load discharge using artificial intelligence approaches (based on conceptual inputs). *Journal of Hydrology*. 514: 114- 122.
- Riahi-Madvar, H., Ayyoubzadeh, S. A., Khadangi, E., & Ebadzadeh, M. M. (2009). An expert system for predicting longitudinal dispersion coefficient in natural streams by using ANFIS. *Expert Systems with Applications*, 36(4), 8589-8596. <https://doi.org/10.1016/j.eswa.2008.10.043>
- Riahi-Madvar, H., & Seifi, A. (2018). Uncertainty analysis in bed load transport prediction of gravelbed rivers by ANN and ANFIS. *Arabian Journal of Geosciences*, 11(21), 688. <https://doi.org/10.1007/s12517-018-3968-6>
- Seifi, A., & Riahi-Madvar, H. (2018). Improving one-dimensional pollution dispersion modeling in rivers using ANFIS and ANN-based GA optimized models. *Environmental Science and Pollution Research*, 1-19. <https://doi.org/10.1007/s11356-018-3613-7>
- Strelkoff, T.S., and Bjerneberg, D.L. 2001. Hydraulic modeling of irrigation-induced furrow erosion. In *Sustaining the Global Farm*, ed. D.E. Stott, R.H. Mohtar, and G.C. Steinhardt, 699-705. Selected papers from the Proceedings of the 10th International Soil Conservation Organization Meeting. May 24-29, 1999.
- Trout, T. J., and Neibling, W. H. 1993. Erosion and sedimentation processes on irrigated fields. *Journal of Irrigation and Drainage Engineering*. 119. 6: 947–963.
- USDA NASS (U.S. Department of Agriculture National Agriculture Statistics Service). 2009. Farm and ranch irrigation survey. 2008. Rep. No. AC-07-SS-1, Washington, DC.
- Wallace, A. and Terry R.E. 1998. Soil conditioners, soil quality and soil sustainability. Marcel Dekker, New York, NY, pp. 1–41.
- Zakaria, N. A., Azamathulla, H. M., Chang, C. K., & Ghani, A. A. (2010). Gene expression programming for total bed material load estimation—a case study. *Science of the total environment*, 408(21), 5078-5085. <https://doi.org/10.1016/j.scitotenv.2010.07.048>
- expression programming for sedimenttransport in sewer pipe systems. *Journal of Pipeline Systems Engineering and Practice*. 2. 3: 102–106.
- Haddadchi, A., Movahedi, N., Vahidi, E., Omid, M. H. and Dehghani, A. A. 2013. Evaluation of suspended load transport rate using transport formulas and artificial neural network models (Case study: Chelchay Catchment). *Journal of Hydrodynamics, Ser. B*. 25. 3: 459–470.
- King, B. A., Bjerneberg, D.L., Trout, T.J., Mateos, L., Araujo, D.F., Costa, R.N. 2015. Estimation of furrow irrigation sediment loss using an artificial neural network. *Journal of Irrigation and Drainage Engineering*. 142(1): 10.1061/(ASCE)IR.1943-4774
- Kisi, O., Dailr, A.H., Cimen, M. and Shiri, J., 2012. Suspended sediment modeling using genetic programming and soft computing techniques. *Journal of Hydrology*. 450: 48–58.
- Koza, J.R. 1992. *Genetic Programming: On the Programming of Computers by Means of Natural Selection*, MIT, Cambridge, USA.
- Mech, S.J., Smith, D.D. 1967. Water erosion under irrigation. In: Hagan RM, Haise HR, Edminster TW (eds) *Irrigation of agricultural lands*. Agronomy monograph 11, American Society of Agronomy, Madison, Wis., pp 950–963.
- NRCS (Natural Resources Conservation Society). 2000. Idaho NRCS Agronomy Technical Note No. 32, Rev. 2, June 10, 2000.
- O'Donkor, J. 1978. Physical and management factors affecting sediment loss from surface irrigated fields. M.S. thesis, Univ. of Idaho, Moscow, ID.
- Partal, T., Cigizoglu, H.K., 2008. Estimation and forecasting of daily suspended sediment data using wavelet-neural networks. *Journal of Hydrology*. 358:317–331.
- Raeisi Vanani, H., Soltani Toudeshki, A. R., Shayannejad, M., Ostad Ali Akbari, K., Ramesh, A., Sing, V. P. and Eslamian, S. 2017. Wastewater and magnetized wastewater effects on soil erosion in furrow irrigation. *International Journal of Research Studies in Agricultural Sciences*, 3(8): 1-14.
- Roushangar, K., Mehrabani, F.V. and Shiri, J. 2014. Modeling river total bed material load discharge using artificial intelligence approaches (based on conceptual inputs). *Journal of Hydrology*. 514.

Derivation of Optimal Equations for Soil Erosion in Furrow Irrigation Using Multi-Gene Genetic Programming Based on Pareto Optimal Solution (POMGGP)

H. Riahi-Mdavar^{1*}, F. Soroush²

Received: Nov.27, 2018

Accepted: May.08, 2019

Abstract

Soil loss is one of most important parameters in design and operation of furrow irrigation systems. Design of furrow irrigation systems is often done based on hydraulic concepts. Because of the loss of predictive equations for soil loss, fertilizer runoff, these losses cannot be estimated quantitatively. On the other hand its measuring is expensive, time consuming and difficult. The main aim of this study is to using the ability of intolerance calculation in derivation of soil loss equations for furrow irrigation by using multi Genetic Programming based on Pareto Optimal solution (POMGGP). So, a database of field measurements of soil erosion in furrow irrigation is collected and multi Genetic Programming in combined with Pareto Optimal solution and preprocessing of maximum dissimilarity for train and test sets is used. Fourteen different models for soil loss are developed and the best equation is derived. The results based on statistical indices of R, RMSE, MAE, RAE and NSE has shown that the POMGGP has the ability in finding optimum equation and parameters for furrow irrigation soil loss estimation and can be used in design and operation of furrow irrigation systems.

Keywords: multi Genetic Programming, Pareto optimal solution, soil erosion, furrow irrigation, SMMD algorithm

1- Assistant Professor, Department of Water Engineering, Vali-e-Asr University, Rafsanjan, Iran

2- Assistant Professor, Department of Water Engineering, Vali-e-Asr University, Rafsanjan, Iran

(*- Corresponding Author Email: h.riahi@vru.ac.ir)