



دانشگاه گورگان و منابع طبیعی گران

نشریه پژوهش‌های حفاظت آب و خاک  
جلد بیست و یکم، شماره ششم، ۱۳۹۳  
<http://jwsc.gau.ac.ir>

## مقایسه عملکرد دو روش برنامه‌ریزی بیان ژن و شبکه عصبی مصنوعی به منظور تخمین ضریب یکنواختی توزیع آب در آبیاری بارانی

\* زیبا قزلباش<sup>۱</sup>، مهدی ذاکری‌نیا<sup>۲</sup>، ابوطالب هزارجریبی<sup>۳</sup> و امیراحمد دهقانی<sup>۳</sup>

<sup>۱</sup> دانشجوی کارشناسی ارشد گروه آبیاری و زهکشی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان،

<sup>۲</sup> استادیار گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان،

<sup>۳</sup> دانشیار گروه مهندسی آب، دانشگاه علوم کشاورزی و منابع طبیعی گرگان

تاریخ دریافت: ۹۲/۱۱/۱۹؛ تاریخ پذیرش: ۹۳/۶/۴

### چکیده

یکنواختی توزیع آب (CU) یک پارامتر مهم فنی در طراحی سیستم‌های آبیاری می‌باشد و مقدار آن تأثیر مهمی بر کیفیت و بازده سرمایه‌گذاری در پروژه‌های آبیاری دارد. اندازه‌گیری CU در آبیاری بارانی ثابت از روی نتایج یک آبیاش منفرد با توجه به در نظر گرفتن هم‌پوشانی آبیاش‌های مجاور و در مقادیر مختلف فشار کارکرد آبیاش (P)، ارتفاع پایه آبیاش ( $H_f$ )، فاصله آبیاش‌ها روی لوله‌های جانبی ( $S_1$ ) و فاصله لوله‌های جانبی از یکدیگر ( $S_m$ ) امری زمان‌بر می‌باشد. در این پژوهش، برای آبیاش‌های مدل AQ-۲۰ و KA-۶ در ۴ تیمار فشارکارکرد (۲، ۳، ۵/۲، ۳ و ۵/۳ اتمسفر)، ۱۶ تیمار فواصل آبیاش‌ها ( $S_1 \times S_m$ ) شامل (۹×۱۸، ۱۲×۱۸، ۱۵×۱۸، ۱۸×۱۸، ۹×۹، ۱۲×۹، ۱۵×۹، ۱۸×۹، ۲×۱۸، ۳×۱۸، ۴×۱۸، ۵×۱۸، ۶×۱۸، ۷×۱۸، ۸×۱۸، ۹×۱۸، ۱۰×۱۸، ۱۱×۱۸، ۱۲×۱۸، ۱۳×۱۸، ۱۴×۱۸، ۱۵×۱۸، ۱۶×۱۸، ۱۷×۱۸، ۱۸×۱۸، ۱۹×۱۸، ۲۰×۱۸، ۲۱×۱۸، ۲۲×۱۸، ۲۳×۱۸، ۲۴×۱۸، ۲۵×۱۸، ۲۶×۱۸، ۲۷×۱۸، ۲۸×۱۸، ۲۹×۱۸، ۳۰×۱۸، ۳۱×۱۸، ۳۲×۱۸، ۳۳×۱۸، ۳۴×۱۸، ۳۵×۱۸، ۳۶×۱۸، ۳۷×۱۸، ۳۸×۱۸، ۳۹×۱۸، ۴۰×۱۸، ۴۱×۱۸، ۴۲×۱۸، ۴۳×۱۸، ۴۴×۱۸، ۴۵×۱۸، ۴۶×۱۸، ۴۷×۱۸، ۴۸×۱۸، ۴۹×۱۸، ۵۰×۱۸، ۵۱×۱۸، ۵۲×۱۸، ۵۳×۱۸، ۵۴×۱۸، ۵۵×۱۸، ۵۶×۱۸، ۵۷×۱۸، ۵۸×۱۸، ۵۹×۱۸، ۶۰×۱۸) تیمار آرایش آبیاش‌ها (مربعی، مستطیلی و مثلثی) در شرایط باد آرام (۹۰، ۱۲۰ و ۱۵۰ سانتی‌متر) و ۳ تیمار آرایش آبیاش‌ها (مربعی، مستطیلی و مثلثی) در شرایط باد آرام (۲-۰ متر بر ثانیه) در ایستگاه تحقیقات پنبه هاشم‌آباد گرگان اندازه‌گیری شد. به منظور برآورد CU براساس روش‌های برنامه‌ریزی بیان ژن (GEP) و شبکه عصبی مصنوعی (ANN)،  $H_f$ ،  $P$ ،  $S_1$  و  $S_m$  به‌عنوان پارامترهای ورودی در نظر گرفته شدند با مقایسه آماری نتایج محاسباتی، ریشه میانگین

\* مسئول مکاتبه: [ziba.ghzelbash@gmail.com](mailto:ziba.ghzelbash@gmail.com)

مربعیات خطا (RMSE) برای روش‌های GEP و ANN در آبیاش AQ-۲۰ برابر ۰/۰۶۶ و ۰/۰۶۲ و در آبیاش KA-۶ نیز به ترتیب برابر ۰/۰۶۷ و ۰/۰۶۴ به دست آمد که این امر بیانگر دقت بالا هر دو روش در مدل‌سازی است. از آنجایی که مدل GEP قادر به ارائه رابطه‌ای صریح برای تخمین ضریب یکنواختی است، جنبه کاربردی بیش‌تری دارد.

**واژه‌های کلیدی:** آبیاری تحت فشار، ارزیابی سیستم آبیاری، هوش مصنوعی، یکنواختی توزیع آب

### مقدمه

براساس شاخص فالکن مارک، کشور ایران در آستانه قرار گرفتن بحران آبی قرار دارد. همچنین براساس شاخص سازمان ملل و شاخص مؤسسه بین‌المللی مدیریت آب نیز، ایران در وضعیت بحران شدید آبی قرار دارد. بنا به گزارش مؤسسه بین‌المللی مدیریت آب، ایران برای حفظ وضع موجود خود تا سال ۲۰۲۵ باید بتواند ۱۲۲ درصد به منابع آبی قابل استحصال خود بیفزاید که این مقدار با توجه به امکانات و منابع آب موجود غیرممکن به نظر می‌رسد (احسانی و خالدی، ۲۰۰۳). بنابراین وضعیت موجود آب کشور باید جزء نگرانی‌های کارشناسان و مدیران بوده و برای حل این معضل لازم است تصمیم‌های اساسی اتخاذ شود. با توجه به پایین بودن راندمان آبیاری در کشور، تامین نیاز آبی کامل بخش کشاورزی به منابع آبی بیش‌تری نیازمند است که برای شرایط اقلیمی ایران افزایش منابع آبی مشکل بوده و باید ارتقا بهره‌وری آب را به‌عنوان مهم‌ترین راه مقابله با کم‌آبی در نظر گرفت. در این راستا گسترش سیستم‌های آبیاری بارانی از نظر توانمندی زیاد در توزیع آب با راندمان قابل‌توجه، راهکاری مطمئن برای استفاده بهینه از منابع آب می‌باشد (علیزاده، ۲۰۰۹). در سال‌های اخیر در کشور با توجه به توسعه روش‌های آبیاری بارانی، تولید و ساخت وسایل و ابزار مختلف آن نیز رونق یافته است. یکی از وسایلی که با تنوع تولید روبه‌رو بوده و شرکت‌های داخلی نیز انواع آن را شبیه‌سازی و تولید می‌کنند، آبیاش است. با توجه به عدم ارائه مشخصات فنی و هیدرولیکی آبیاش‌های مورد استفاده در آبیاری بارانی لازم است با تغییرات ساده‌ای مانند تغییر فشار سیستم، تغییرات ارتفاع پایه‌های آبیاش، تنظیم فاصله آبیاش‌ها روی لوله‌های جانبی و همچنین فاصله لوله‌های جانبی از یکدیگر (آرایش شبکه)، یکنواختی توزیع آب و عملکرد سیستم آبیاری را بهبود بخشید. روابط مختلفی برای اندازه‌گیری ضریب یکنواختی توزیع آب در سیستم آبیاری بارانی ارائه شده است که از جمله آن‌ها

می‌توان به روش هاوایی (علیزاده، ۲۰۰۹)، ضریب یکنواختی کریستیانسن (ووریس و برنوت، ۱۹۸۶)، ضریب یکنواختی مریام و کلر (۱۹۷۸)، ضریب یکنواختی کارملی (۱۹۹۷) و ضریب یکنواختی هارت و رینولدز (۱۹۶۵) اشاره نمود. دابوس (۱۹۶۲) به روش آماری نشان داد که ضریب یکنواختی توزیع آب کریستیانسن<sup>۱</sup> در مقایسه با دیگر روابط، برای اندازه‌گیری مقدار CU از اعتبار بیش‌تری برخوردار می‌باشد. ضمن این‌که سولومون (۱۹۷۹) و هیرمان (۱۹۸۳) نیز بر عمومی بودن و معمول بودن کاربرد ضریب یکنواختی کریستیانسن تاکید نموده‌اند. بر این اساس ضریب یکنواختی کریستیانسن در بسیاری از مطالعات (همچنین در این پژوهش) مبنای ارزیابی یکنواختی توزیع آب قرار گرفته است. باوی و همکاران (۲۰۰۶) به‌منظور بررسی اثر مقادیر مختلف فشار کارکرد، فواصل و آرایش آبپاش‌ها بر یکنواختی توزیع آب در آبیاری بارانی نشان دادند که با افزایش فشار کارکرد، ضریب یکنواختی توزیع کریستیانسن به‌صورت غیرخطی افزایش می‌یابد (افزایش فشار از ۳۵ متر به ۴۰ متر، ضریب یکنواختی توزیع آب را در مقایسه با افزایش فشار کارکرد از ۴۰ به ۴۵ متر بیش‌تر افزایش می‌دهد). همچنین با افزایش نسبت فواصل آبپاش‌ها به شعاع پاشش، ضریب یکنواختی کاهش یافته و آرایش مربعی و مستطیلی به‌ترتیب حداکثر و حداقل ضریب یکنواختی توزیع آب را به همراه داشته‌اند. فوکویی و همکاران (۱۹۸۰) نشان دادند که حداکثر ضریب یکنواختی توزیع آب در آرایش مثلثی و در فواصل کم‌تر آبپاش‌ها از هم حاصل می‌گردد. آهانکو (۲۰۱۰) میانگین ضریب یکنواختی توزیع آب یک آبپاش جدید را ۸۶ درصد به‌دست آورد. اسی (۲۰۰۹) میانگین ضریب یکنواختی توزیع آب را در فواصل ۱۲ در ۱۲ و ۱۸ در ۱۸ متر به‌ترتیب برابر ۹۱ درصد و ۸۷ درصد به‌دست آورد. مونتر و همکاران (۲۰۰۳) نتیجه گرفتند که فشار کارکرد، اصلی‌ترین عامل سیستمی مؤثر بر توزیع آب در آبیاری بارانی است. کلر و بلینسر (۱۹۹۰) دریافتند در فشار کم، به‌دلیل ریزش بیش‌تر آب در فواصل نزدیک به آبپاش و در فشار بالا، به‌دلیل تولید قطرات ریزتر و حساس‌تر به باد، ضریب یکنواختی کاهش می‌یابد. اندازه‌گیری CU در آبیاری بارانی ثابت از روی نتایج یک آبپاش منفرد با توجه به در نظر گرفتن همپوشانی آبپاش‌های مجاور و در مقادیر مختلف فشار کارکرد آبپاش (P)، ارتفاع پایه آبپاش ( $H_T$ )، فاصله آبپاش‌ها روی لوله‌های جانبی ( $S_I$ ) و فاصله لوله‌های جانبی از یکدیگر ( $S_m$ ) کاری وقت‌گیر می‌باشد و به‌دلیل تخصصی بودن از عهده زارعین و کاربران خارج است. ضمن این‌که مقدار CU

1- Christiansen's Uniformity

به‌دست آمده از هر آبیاش، در مقادیر مختلف فشار کارکرد آبیاش (P)، ارتفاع پایه آبیاش ( $H_r$ )، فاصله آبیاش‌ها روی لوله‌های جانبی ( $S_l$ ) و فاصله لوله‌های جانبی از یکدیگر ( $S_m$ ) تغییر می‌یابد. بنابراین ضروری است در وضعیت‌های مختلف از پارامترهای ذکر شده (که تعداد آزمایش‌ها را نیز به تعداد بسیار زیاد افزایش می‌دهد)، مقدار CU اندازه‌گیری شود تا شرایط مناسب برای حصول حداکثر CU از هر آبیاش برای توصیه به زارعین مهیا شود. به همین دلیل استفاده از روشی که بتواند مقادیر CU را با دقتی قابل قبول، محاسبه‌های کم‌تر و در زمانی کوتاه‌تر در شرایط مختلفی از فشار کارکرد، ارتفاع پایه آبیاش و آرایش آبیاش‌ها تخمین بزند، ضروری به‌نظر می‌رسد. در سال‌های اخیر روش‌های مبتنی بر هوش مصنوعی به خوبی به‌عنوان یک راهکار جایگزین برای غلبه بر مشکلات روش‌های سنتی ارتقا یافته‌اند. تجربه نشان داده است که پیاده‌سازی ساختارهای محاسباتی سیستم بیولوژیکی، می‌تواند منجر به ایجاد الگوهای محاسباتی بهتری برای مسایل مبهم و پیچیده شود. شبکه عصبی مصنوعی<sup>۱</sup> یک نوع سیستم هوشمند مصنوعی است که از روی سلول‌های عصبی موجودات زنده شبیه‌سازی شده و در یادگیری، پردازش و به‌خاطر سپاری اطلاعات، روش مغز انسان را تقلید می‌کند (کرینس و همکاران، ۱۹۹۳). هزارجریبی و همکاران (۲۰۱۰) از روش الگوریتم ژنتیک<sup>۲</sup> برای برآورد ضریب یکنواختی توزیع آب در آبیاری بارانی، در مقادیر مختلف فشار کارکرد، ارتفاع پایه آبیاش، فاصله آبیاش‌ها روی لوله جانبی و فاصله لوله‌های جانبی از یکدیگر استفاده کردند و کارایی بالای این روش را در مدل‌سازی تأیید نمودند. آبابایی و وردی‌نژاد (۲۰۱۳) ضریب یکنواختی کریستیانسن را به‌عنوان شاخص عملکرد هیدرولیکی سیستم آبیاری تحت فشار در نظر گرفتند و با استفاده از شبکه عصبی مصنوعی مقادیر این شاخص را به‌صورت تابعی از ترکیب‌های مختلف فشار ورودی، تعداد و فاصله خروجی‌ها، ضریب زبری، قطر داخلی و دبی اسمی خروجی‌ها محاسبه نمودند. نتایج نشان داد که مدل شبکه عصبی مصنوعی قادر است با کم‌ترین خطا، مقادیر ضریب یکنواختی لوله‌های جانبی آبیاری تحت فشار را با استفاده از مشخصات فیزیکی و هیدرولیکی آن برآورد کند.

1- Artificial Neural Network (ANN)

2- Genetic Algorithm (GA)

برنامه‌ریزی ژنتیک<sup>۱</sup> و برنامه‌ریزی بیان ژن<sup>۲</sup> از جدیدترین الگوریتم‌های فراکاوشی هستند که به دلیل سهولت کاربرد و دقت بالا در تقریب معادلات غیرخطی و پیچیده ریاضی، مورد توجه پژوهشگران قرار گرفته‌اند. از مزایای عمده این مدل‌ها، کاربرد آن در شرایطی است که ارتباط موجود بین متغیرهای مسئله به خوبی شناخته شده نباشد، حل ریاضی مرسوم وجود نداشته باشد یا حل تحلیلی را ایجاب کند (بنزاف و همکاران، ۱۹۹۸). آیتک و کیشی (۲۰۰۸) با مطالعه در مورد پدیده حمل رسوب در آبراهه‌ها روش برنامه‌ریزی ژنتیک را به‌عنوان یک رهیافت مناسب برای شبیه‌سازی بار معلق معرفی کردند. تراوره و گاوان (۲۰۱۲) از مدل برنامه‌ریزی بیان ژن برای تخمین تبخیر و تعرق در منطقه‌ای در آفریقا استفاده کردند و دقت این مدل را قابل قبول گزارش نمودند.

با بررسی منابع و مطالعات انجام شده، مشخص گردید تاکنون پژوهشی در خصوص به‌کارگیری روش برنامه‌ریزی بیان ژن در تخمین ضریب یکنواختی توزیع آب در آبیاری بارانی، انجام نگرفته است. بنابراین این پژوهش با هدف بررسی عملکرد برنامه‌ریزی بیان ژن برای برآورد ضریب یکنواختی، انجام گردید و نتایج حاصله با عملکرد شبکه عصبی مصنوعی مورد مقایسه قرار گرفت.

### مواد و روش‌ها

**جمع‌آوری داده‌های طرح:** این طرح در ایستگاه تحقیقات کشاورزی هاشم‌آباد شهر گرگان وابسته به مؤسسه تحقیقات پنبه کشور، واقع در عرض جغرافیایی ۳۶ درجه و ۵۱ دقیقه شمالی و طول جغرافیایی ۵۴ درجه و ۱۶ دقیقه شرقی انجام شد. در این پژوهش از یک موتور پمپ لیستر گازوئیلی برای تأمین فشار استفاده گردید. به لوله رانش پمپ یاده شده یک لوله فرعی به طول ۷۲ متر از جنس آلومینیوم به قطر ۳ اینچ متصل شد. بر روی این لوله که انتها آن با یک در پوش انتهایی مسدود شده بود، آبپاش‌های مورد مطالعه (آبپاش AQUA مدل AQ-۲۰ دو نازل، دو طرفه و تمام دور ساخت کشور ایتالیا و همچنین آبپاش AKONA مدل KA-۶ دو نازل، یک طرفه و تمام دور ساخت کشور ترکیه) به فاصله ۱۸ متری انتها لوله بر روی پایه آبپاش نصب گردید. برای تنظیم و کنترل فشار کارکرد آبپاش از شیر فلکه‌ای که بر روی لوله رانش پمپ قرار داشت، استفاده گردید. در ضمن آب مازاد بر نیاز آبپاش و در حال جریان در لوله فرعی، از طریق آبپاش‌هایی که در انتها لوله فرعی و در فاصله

- 
- 1- Genetic Programming (GP)
  - 2- Gene Expression Programming (GEP)

۳۵ متری از آبیاش مورد مطالعه قرار داده شده بودند، خارج می‌شد. در نتیجه آب خروجی از آبیاش‌های انتهایی هیچ‌گونه هم‌پوشانی با محدوده پاشش آبیاش مورد مطالعه ایجاد نمی‌کرد. در این پژوهش برای تعیین شدت پاشش از لیوان‌های آلومینیومی لبه تیز به قطر  $10/68$  سانتی‌متر و یک شبکه مربعی شکل به ابعاد  $3 \times 3$  متر در اطراف آبیاش تحت مطالعه استفاده گردید. با توجه به حداکثر شعاع پاشش آبیاش در تیمارهای فشار مورد نظر، تعداد  $144$  قوطی در یک شبکه مربعی شکل تا فاصله  $18$  متر در اطراف آبیاش چیده شد. بنابراین لیوان‌های جمع‌کننده آب در  $12$  ردیف به موازات لوله فرعی قرار گرفتند به گونه‌ای که فاصله لیوان‌ها روی ردیف‌ها و همچنین فاصله ردیف‌ها از هم  $3$  متر در نظر گرفته شد. به این ترتیب هر لیوان در مرکز یک شبکه  $3 \times 3$  متری قرار گرفت. برای تعیین حجم آب داخل لیوان‌ها از یک استوانه مدرج استفاده شد. دبی آبیاش نیز به طریق حجمی و زمان تعیین شد. از زمان روشن شدن موتور تا ثابت شدن دبی و تنظیم فشار آبیاش از طریق شیر فلکه لوله رانش، سطلی بر روی آبیاش قرار داده شده و به محض ثابت شدن فشار، سطل از روی آبیاش برداشته و به مدت تقریبی  $1/5 - 1$  ساعت آزمایش ادامه یافت. با توجه به نزدیکی محل آزمایش به ایستگاه هواشناسی هاشم‌آباد گرگان ( $200$  متری) از آمار باد این ایستگاه استفاده گردید. در این پروژه فشار نازل در نقطه‌ای که جت آب در نازل اصلی (نازل بزرگ‌تر) فشرده می‌شود از طریق یک فشارسنج همراه با یک لوله پیتو اندازه‌گیری شد. بعد از  $1/5 - 1$  ساعت پاشش آب در داخل لیوان‌ها، پمپ خاموش و حجم آب داخل هر لیوان قرائت گردید. سپس حجم آب داخل هر لیوان با توجه به قطر لبه بالایی لیوان به عمق معادل تبدیل شد و در نهایت با فرض یکسان بودن آبیاش‌ها و لوله‌های فرعی و مشابه‌سازی عمق آب داخل لیوان‌ها در حالت‌های مختلف  $S_1$  و  $S_m$ ، ضریب یکنواختی توزیع آب کریستیانسن برای تیمارهای مختلف ارتفاع پایه آبیاش و فشار کارکرد آبیاش اندازه‌گیری گردید. لازم به ذکر است که برای منظور نمودن اثر تبخیر بر عمق آب داخل لیوان‌ها تعداد  $4$  لیوان شامل  $10$ ،  $25$ ،  $50$  و  $80$  میلی‌متر آب در هر نوبت آزمایش در مجاورت طرح قرار داده شد و در صورت تبخیر، مقدار آب تبخیر شده با توجه به عمق آب باقی‌مانده در این لیوان‌ها و لیوان‌های تحت آزمایش به لیوان‌های تحت آزمایش اضافه گردید (فرزادمنش،  $2012$ ). در این پژوهش مقدار CU در  $4$  تیمار فشار کارکرد،  $16$  تیمار فواصل آبیاش‌ها،  $4$  تیمار ارتفاع پایه آبیاش و  $3$  تیمار آرایش آبیاش‌ها (مربعی، مستطیلی و مثلثی) اندازه‌گیری گردید. تیمارهای مختلف فشار کارکرد، فواصل آبیاش‌ها، ارتفاع آبیاش‌ها در جدول ۱ نشان داده شده است.

## زیبا قزلباش و همکاران

جدول ۱- تیمارهای مختلف فشار کارکرد، ارتفاع پایه آبیاش و فواصل آبیاش‌ها.

فشار کارکرد آبیاش (اتمسفر)	آرایش شبکه آبیاش‌ها (متر)	ارتفاع پایه آبیاش (سانتی‌متر)
۲	۱۸×۹، ۱۸×۱۲، ۱۸×۱۵، ۱۸×۱۸	۶۰
۲/۵	۱۵×۱۸، ۱۵×۱۵، ۱۵×۱۲، ۱۵×۹	۹۰
۳	۱۲×۱۸، ۱۲×۱۵، ۱۲×۱۲، ۱۲×۹	۱۲۰
۳/۵	۹×۱۸، ۹×۱۵، ۹×۱۲، ۹×۹	۱۵۰

برای اندازه‌گیری ضریب یکنواختی کریستیانسن (ووریس و برنوت، ۱۹۸۶) از رابطه ۱ استفاده شد که در این رابطه،  $x_i$ : عمق آب معادل جمع شده در هر لیوان،  $x_{mean}$ : میانگین عمق آب معادل جمع شده در لیوان‌ها و  $n$ : تعداد کل لیوان‌ها است.


$$CU = 1 - \sum_{i=1}^n \frac{x_i - x_{mean}}{n \times x_{mean}} \quad (1)$$

**آماده‌سازی داده‌ها:** وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. برای دوری از چنین شرایطی و همچنین به منظور یکسان کردن ارزش داده‌ها برای شبکه، عمل استانداردسازی صورت می‌گیرد. این کار مانع از کوچک شدن بیش از حد وزن‌ها و سبب جلوگیری از اشباع زود هنگام نرون‌ها می‌گردد. برای استانداردسازی داده‌های مورد استفاده از رابطه ۲ استفاده شد که در این رابطه  $x$ : داده مشاهده‌ای،  $x_n$ : داده استاندارد شده،  $x_{max}$ ،  $x_{min}$  و  $x_{mean}$  به ترتیب معرف داده‌های مشاهده‌ای میانگین، حداقل و حداکثر است.

$$X_n = 0.5 \times \left( \frac{x - x_{mean}}{x_{max} - x_{min}} \right) + 0.5 \quad (2)$$

**مدل شبکه عصبی مصنوعی:** از دیدگاه ریاضی یک شبکه عصبی به عنوان یک تقریب‌گر محسوب می‌گردد و توانایی آن در تقریب بین الگوهای یک مسئله باعث می‌شود تا بتواند مسایلی با پیچیدگی

زیاد مانند شناسایی الگو، تفکیک الگو، نگاشت غیرخطی<sup>۱</sup>، حافظه انجمنی<sup>۲</sup>، خودسازمان‌دهی و کنترل را انجام دهد. شکل ۱ شمایی کلی از یک شبکه عصبی مصنوعی را نشان می‌دهد. با توجه به این شکل هر شبکه از یک لایه ورودی، یک یا چند لایه میانی (پنهان) و یک لایه خروجی تشکیل شده است. هر لایه از تعدادی نرون تشکیل شده است. هر نرون اطلاعات را از یک سری ورودی گرفته و پس از پردازش به خروجی تحویل می‌دهد و خروجی این نرون به‌عنوان ورودی بعدی مورد استفاده قرار می‌گیرد. تعداد نرون‌ها در لایه‌های ورودی و خروجی متناسب با ماهیت مسأله‌ای که شبکه برای آن استفاده می‌شود، تعیین می‌شود. حال آن‌که تعداد نرون‌های موجود در لایه پنهان و همچنین تعداد این لایه‌ها با سعی و خطا در جهت کاهش مقدار خطا توسط طراح مشخص می‌گردد. نرون‌های هر لایه به وسیله وزن‌هایی به نرون‌های لایه بعدی متصل می‌شوند. این وزن‌ها و مقادیر ثابتی که با آن‌ها جمع می‌شود را در اصطلاح بایاس<sup>۳</sup> می‌نامند که طی فرآیند آموزش شبکه مرتباً تغییر می‌کنند تا زمانی که به بهترین حالت خود برسند.




شکل ۱- ساختار ساده یک مدل شبکه پرسپترون سه لایه.

برای انتقال خروجی‌های هر لایه به لایه‌های بعدی از توابع انتقال<sup>۴</sup> استفاده می‌شود. تابع انتقال در واقع به‌عنوان یک تقویت‌کننده غیرخطی برای نرون محسوب می‌شود. این تابع می‌تواند به‌صورت تابع

- 1- Nonlinear Mapping
- 2- Associative Memory
- 3- Bias
- 4- Transfer Functions



سیگموئیدی، خطی، آستانه‌ای، تانژانت هیپربولیک و یا گوسی باشد که بسته به نوع شبکه و الگوریتم آموزش به کار گرفته شده، تعیین می‌شود (کریپنس و همکاران، ۱۹۹۳). برای شبیه‌سازی شبکه عصبی از جعبه ابزار Neural Network برنامه MATLAB 7.1 استفاده گردید. به منظور آموزش شبکه عصبی بایاس‌ها، از مقادیر پیش فرض نرم‌افزار استفاده شد. در مدل شبکه عصبی از مدل شبکه‌های عصبی پرسپترون چندلایه<sup>۱</sup> و از میان روش‌های مختلف آموزش از روش الگوریتم پس‌انتشار خطا<sup>۲</sup>، به دلیل همگرایی سریع‌تر در آموزش شبکه استفاده شد. همچنین در ساختار شبکه آن، طراحی بهینه با سعی و خطا در انتخاب تابع انتقالی، تعداد لایه‌های پنهان و تعداد نرون در لایه پنهان تا حصول بهترین آرایش شبکه صورت گرفت. به منظور مدل‌سازی شبکه به شکل تصادفی، ۶۰ درصد از داده‌ها برای آموزش، ۱۰ درصد برای صحت‌سنجی و ۳۰ درصد برای آزمون شبکه انتخاب گردید.




شکل ۲- ساختار شبکه عصبی مورد استفاده در برنامه MATLAB.

برنامه‌ریزی بیان ژن: برنامه‌ریزی بیان ژن توسط فریرا (۱۹۹۹) ارایه شد (فریرا، ۲۰۰۱). در این برنامه، 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. اولین مرحله در الگوریتم مدل، تولید جمعیت اولیه از راه‌حل‌ها است. این امر می‌تواند به وسیله فرآیند تصادفی و یا در نظر گرفتن اطلاعات ورودی درباره مسأله، انجام شود سپس کروموزوم‌ها به صورت بیان درختی اظهار شده و توسط تابع برازش ارزیابی می‌گردند. در صورت

- 1- Multi Layer Perceptron
- 2- Back Propagation Algorithm

دست‌یابی به راه‌حل مطلوب و یا رسیدن نسل‌ها به تعداد معین، تکامل متوقف شده و بهترین راه‌حل ارابه می‌شود. اگر شرایط توقف یافت نشود، نخبه‌گزینی انجام می‌شود و باقی راه‌حل‌ها به فرآیندی گزینشی واگذار می‌شوند. این فرآیند برای چندین نسل تکرار می‌شود و با پیش رفتن نسل به جلو کیفیت جمعیت نیز به‌طور نسبی بهبود می‌یابد (فریرا، ۲۰۰۶). در برنامه‌ریزی بیان ژن از عملگرهای مختلفی مانند جهش و ترکیب استفاده می‌شود. این مدل، از روش معروف چرخ رولت، برای انتخاب افراد استفاده می‌کند. هدف عملگر جهش، بهسازی تصادفی، داخل کروموزوم‌های معینی است. خصوصیت این عملگر آن است که برای جلوگیری از ایجاد افراد معیوب از نظر قواعد، برخی عملیات بدون نقص را اجرا می‌نماید. در این مدل از ترکیب تک‌نقطه‌ای، دو نقطه‌ای و ژنی استفاده می‌شود. از آنجایی‌که ترکیب دو نقطه‌ای قادر است نواحی کدگذاری نشده داخل کروموزوم‌ها را به مراتب بیشتری روشن و خاموش کند، مطلوب‌تر است. از دیگر عملگرهای مورد استفاده می‌توان عملگر ترانزش را نام برد. در این روش پدیده‌های مختلف با استفاده از مجموعه‌ای از توابع و ترمینال‌ها، مدل‌سازی می‌شوند. مجموعه توابع، معمولاً شامل توابع اصلی حسابی، مثلثاتی و یا توابع تعریف شده توسط کاربر هستند که معتقد است، می‌توانند برای تفسیر مدل مناسب باشند. مجموعه ترمینال‌ها، از مقادیر ثابت و متغیرهای مستقل مسأله تشکیل شده‌اند (فریرا، ۲۰۰۱). در این پژوهش برای به‌کارگیری مدل برنامه‌ریزی بیان ژن از نرم‌افزار GeneXpro 4.0 استفاده گردید. لازم به ذکر است که همه پارامترهای بالا با سعی و خطا تا دست‌یابی به حداکثر ضریب همبستگی مدل (R) توسط کاربر انتخاب می‌شود.



شکل ۳- شمایی از درختان تجزیه مورد استفاده در برنامه‌ریزی بیان ژن.

در این پژوهش، مدل‌های گوناگون برنامه‌ریزی بیان ژن با همان ترکیبات ورودی مدل شبکه عصبی ایجاد شدند. اولین گام در بررسی مدل، انتخاب تابع برازش مناسب است. هدف از انتخاب تابع برازش، یافتن راه‌حلی است که برای تمامی موارد با حداقل خطای ممکن عمل کند. نتایج انتخاب اولیه تابع برازش نشان داد که استفاده از تابع برازش ریشه نسبی مربعات خطا<sup>۱</sup> در مقایسه با سایر توابع، عملکرد بهتری دارد. همچنین از بین توابع پیوند شامل جمع و ضرب، تابع پیوند جمع عملکرد بهتری در مقایسه با تابع پیوند ضرب دارد و گام آخر انتخاب عملگرهای اصلی برای ساخت درخت تجزیه و توابع ریاضی مناسب برای تفسیر مدل می‌باشد.

**معیارهای ارزیابی:** یکی از معمول‌ترین شاخص‌های آماری که برای ارزیابی مدل مورد استفاده قرار می‌گیرد ضریب همبستگی پیرسون (R) می‌باشد، بیان ریاضی این شاخص در رابطه ۳ ارائه شده است. با این حال باید توجه داشت که ضریب همبستگی نمی‌تواند به تنهایی شاخص مناسبی برای ارزیابی مدل باشد. زیرا ممکن است در یک مدل فرضی مقادیر پیش‌بینی و مشاهده‌شده دارای اختلافی فاحش باشند ولی این اشتباهات به گونه‌ای باشد که از یک روند یکنواخت پیروی نماید. بنابراین اگرچه ضریب همبستگی به خوبی نشان‌دهنده میزان هماهنگی روند تغییرات مقادیر مشاهده شده نسبت به مقادیر پیش‌بینی شده می‌باشد اما گویای تطابق آن‌ها نیست (قربانی‌دشتکی و همکاران، ۲۰۰۹). لگات و مکاب (۱۹۹۹) بیان کردند که شاخص ضریب همبستگی به تنهایی به عنوان معیاری برای بررسی عملکرد مدل مورد استفاده قرار نمی‌گیرد. بنابراین به منظور سنجش کارایی مدل‌های مورد بحث در برآورد پارامتر خروجی مدل‌سازی، از چندین شاخص آماری شامل ریشه میانگین مربعات خطا (رابطه ۴)، میانگین قدر مطلق خطا (رابطه ۵)، شاخص ناش - ساتکلایف (رابطه ۶)، انحراف مدل (رابطه ۷) و قابلیت اعتماد مدل (رابطه ۸) استفاده شد.

$$R = \sqrt{1 - \frac{\sum_{i=1}^n (x_i - y_i)^2}{\sum_{i=1}^n (x_i - x_{mean})^2}} \quad (3)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2} \quad (4)$$

1- Root Relative Squared Error (RRSE)

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - x_i| \quad (5)$$

$$NASH = 1 - \frac{\sum_{i=1}^n (y_i - x_i)^2}{\sum_{i=1}^n (x_i - x_{mean})^2} \quad (6)$$

$$MB = \frac{\sum_{i=1}^n (y_i - x_i)}{\sum_{i=1}^n x_i} \quad (7)$$

$$MC = \frac{\sum_{i=1}^n (y_i - x_{mean})^2}{\sum_{i=1}^n (x_i - x_{mean})^2} \quad (8)$$

که در آن‌ها،  $x_i$ : داده‌های اندازه‌گیری شده،  $y_i$ : داده‌های شبیه‌سازی شده،  $x_{mean}$  و  $y_{mean}$  به ترتیب میانگین داده‌های اندازه‌گیری شده، شبیه‌سازی شده و  $n$ : تعداد مشاهدات می‌باشند.

## نتایج و بحث

ارزیابی آماری داده‌ها: در این پژوهش برای هر دو نوع آبیاش به‌طور جداگانه تعداد ۵۲۰ داده یکنواختی به روش نام‌برده برداشت و محاسبه شد سپس برای ارزیابی عملکرد دو نوع آبیاش در برآورد CU با استفاده از نرم‌افزار SPSS 16.0، آزمون t-student برای مقایسه میانگین‌ها و آزمون Levene برای مقایسه واریانس‌ها انجام شد.

جدول ۲- نتایج آزمون مقایسه میانگین و برابری واریانس‌ها.

واریانس	آزمون Levene		آزمون t-student				
	آماره آزمون	سطح معنی‌داری	درجه آزادی	آماره آزمون	سطح معنی‌داری	اختلاف میانگین	خطای معیار
برابر	۰/۱۳۹	۰/۷۱۰*	۱۰۱۸	-۰/۱۰۵	۰/۹۱۶*	-۰/۰۰۰۶	۰/۰۰۵۸
نا برابر			۱۰۱۸	-۰/۱۰۵	۰/۹۱۶	-۰/۰۰۰۶	۰/۰۰۵۸

\* معنی‌دار در سطح احتمال ۵ درصد.

با توجه به نتایج ذکر شده در جدول ۲ در سطح اطمینان ۹۵ درصد، تفاوت معنی‌داری بین یکنواختی‌های به‌دست آمده توسط دو نوع آبیاش وجود نداشت و عملکرد آبیاش‌ها از این نظر همسان بود. نتایج مدل برنامه‌ریزی بیان ژن: به‌طور خلاصه پارامترهای استفاده شده در هر بار اجرای مدل برنامه‌ریزی بیان ژن در جدول ۳ ارائه شده است.

جدول ۳- مقادیر پارامترهای به‌کار گرفته شده در برنامه‌ریزی بیان ژن.

تعداد کروموزوم‌ها	۳۰	نرخ برگشت	۰/۱	نرخ ترکیب تک‌نقطه‌ای	۰/۳
طول هر راس	۸	نرخ ترانهش ژنی	۰/۱	نرخ ترکیب دو نقطه‌ای	۰/۳
تعداد ژن‌ها	۵	نرخ جهش	۰/۰۴	نرخ ترکیب ژنی	۰/۱

در این پژوهش، عملکرد مدل به‌ازای مجموعه‌ای معین از توابع، مورد بررسی قرار گرفت. با توجه به جدول ۴، در آبیاش AQ-۲۰ تابع  $F_2$  و در آبیاش KA-۶ تابع  $F_4$  دارای بیش‌ترین مقادیر ضریب همبستگی در مراحل آموزش و آزمون بودند. از دیگر قابلیت‌های مدل برنامه‌ریزی بیان ژن نسبت به سایر مدل‌های هوشمند، ارائه معادله ریاضی بهینه بین متغیر وابسته و سایر متغیرهای مستقل می‌باشد که این مسأله برای پیش‌بینی‌های آتی اهمیت به‌سزایی دارد. معادله ارائه شده توسط مدل برنامه‌ریزی بیان ژن برای تخمین ضریب یکنواختی به‌ازای ورودی‌های مدل  $(P, Hr, S_1, S_m)$ ، برای آبیاش‌های AQ-۲۰ و KA-۶ به‌ترتیب در رابطه‌های ۹ و ۱۰ ارائه شده است.

$$CU = (H_f - ((s_l - 0.14)s_l)^2)^{0.33} - H_f + e^{\left(\frac{91.45H_r}{9.75H_r + p \times s_l}\right)} \quad (9)$$

$$+ \frac{H_r(H_r - p)}{2H_r + p} + \frac{H_r \times p}{(\sqrt{p + s_l})(H_r + s_m)} + e^{(-16.77H_r(\lambda/3s_l(H_r + s_l)))}$$

$$CU = s_m^0 \times H_r^{0.33} (s_m - s_l) + e^{(H_r - s_l - p - 0.95)} + \frac{0.075 - 0.0008H_r}{s_m \times s_l} \quad (10)$$

$$+ e^{\left(\frac{-7.5 - \log s_m + \frac{s_l}{s_m}}{s_m}\right)} - e^{\left(\frac{-175.7 - \frac{p}{H_r}}{H_r}\right)}$$

جدول ۴- نتایج نهایی اجرای مدل برنامه‌ریزی بیان ژن به‌ازای الگوهای مختلف ورودی.

آپاش ۶-KA		آپاش ۲۰-AQ		مدل ریاضی	تابع
R		R			
آزمون	آموزش	آزمون	آموزش		
۰/۲۶	۰/۵۴	۰/۳۵	۰/۵۷	+ - × /	F <sub>۱</sub>
۰/۶۲	۰/۶۵	۰/۷۹	۰/۷۵	+ - × /, $\sqrt[3]{\quad}$ , $\sqrt{\quad}$ , $x^2$ , $x^3$ , $e^x$	F <sub>۲</sub>
۰/۲۲	۰/۶۱	۰/۲۹	۰/۶۴	+ - × /, $e^x$ , $x^2$ , $x^3$ , $\sin x$ , $\cos x$	F <sub>۳</sub>
۰/۷۲	۰/۷	۰/۵۹	۰/۷۱	+ - × /, $\sqrt[3]{\quad}$ , $\sqrt{\quad}$ , $x^2$ , $x^3$ , $e^x$ , $\log x$	F <sub>۴</sub>

نتایج مدل شبکه عصبی مصنوعی: برای تعیین بهترین ساختار شبکه عصبی شبکه پرسپترون چند لایه با توجه به عمومیت استفاده و توصیه پژوهشگران از این شبکه، با تعداد لایه‌ها و نرون‌های پنهان مختلف مورد ارزیابی قرار گرفت. نتایج آماره‌های ارزیابی برای چند نمونه از سعی و خطاهای انجام شده در جدول ۵ ارائه شده است. نتایج نشان می‌دهد که برای هر دو نوع آپاش شبکه N<sub>۳</sub> به‌عنوان بهترین آرایش شبکه می‌باشد که در آن از تابع سیگموئیدی تانژانت به‌عنوان تابع انتقالی برتر در لایه خروجی و پنهان و تعداد ۲۰ نرون در لایه پنهان استفاده شده است.

به‌منظور مقایسه دو روش شبکه عصبی مصنوعی و برنامه‌ریزی بیان ژن آماره‌های مختلفی محاسبه و در جدول ۶ ارائه شده است. نتایج بیانگر آن است که در آپاش ۲۰-AQ مدل برنامه‌ریزی بیان ژن با آماره‌های R, RMSE, MAE و NASH به‌ترتیب برابر ۰/۷۶، ۰/۰۶، ۰/۰۵ و ۰/۵۷۵ عملکرد بهتری نسبت به مدل شبکه عصبی مصنوعی داشت در حالی که در آپاش ۶-KA مدل شبکه عصبی مصنوعی با آماره‌های R, RMSE, MAE و NASH به‌ترتیب برابر ۰/۷۳، ۰/۰۶۴، ۰/۰۵۳ و ۰/۵۴۲ دقت بیش‌تری نسبت به مدل برنامه‌ریزی بیان ژن از خود نشان داد. علاوه‌بر این مقادیر قابل‌قبول انحراف مدل و قابلیت اعتماد مدل (مقادیر نزدیک به صفر MB و نزدیک به ۰/۵ MC) بیانگر اختلاف بسیار جزئی بین نتایج مدل‌سازی و توفیق هر دو مدل برنامه‌ریزی بیان ژن و شبکه عصبی مصنوعی در برآورد ضریب یکنواختی توزیع آب است اما با توجه به این‌که استفاده از مدل برنامه‌ریزی بیان ژن منتج به استخراج روابط کاربردی برای تخمین ضریب یکنواختی می‌گردد، به‌کارگیری این روش توصیه می‌شود.

## زیبا قزلباش و همکاران

جدول ۵- نتایج کلی آموزش و آزمون ساختارهای مختلف شبکه پرسپترون چند لایه.


شبکه	تابع انتقال	تعداد لایه‌ها	تعداد نرون در لایه پنهان	آپاش AQ-۲۰		آپاش KA-۶	
				آموزش	آزمون	آموزش	آزمون
N۱	TANSIG	۱	۱۰	۰/۷۹	۰/۶۵	۰/۷۶	۰/۶۳
N۲	TANSIG	۲	۳۰	۰/۷۱	۰/۶۴	۰/۷۲	۰/۵۶
N۳	TANSIG	۳	۲۰	۰/۸۴	۰/۸	۰/۸	۰/۷
N۴	TANSIG	۳	۱۰	۰/۷۸	۰/۶۲	۰/۷۱	۰/۶۵
N۵	TANSIG	۱۰	۴۰	۰/۴۶	۰/۳۸	۰/۴۹	۰/۲۷
N۶	TANSIG	۵	۱۰	۰/۶۲	۰/۵۹	۰/۵۳	۰/۴۹
N۷	PURELIN	۳	۲۰	۰/۴۵	۰/۳۷	۰/۳۸	۰/۳۱
N۸	PURELIN	۵	۱۰	۰/۳۸	۰/۲۶	۰/۴۸	۰/۳۶
N۹	PURELIN	۴	۲۰	۰/۵۹	۰/۴۳	۰/۶۱	۰/۵۷
N۱۰	LOGSIG	۳	۱۰	۰/۷	۰/۶۴	۰/۶۸	۰/۵۹
N۱۱	LOGSIG	۲	۲۰	۰/۷۸	۰/۶۱	۰/۷۳	۰/۶۴
N۱۲	LOGSIG	۵	۵۰	۰/۶۶	۰/۵۲	۰/۶۴	۰/۵۱

جدول ۶- مقادیر پارامترهای آماری مدل‌های شبکه عصبی مصنوعی و برنامه‌ریزی بیان ژن به تفکیک نوع آپاش.


نوع آپاش	مدل	R	RMSE	MAE	NASH	MC	MB
AQ-۲۰	ANN	۰/۷۴	۰/۰۶۲	۰/۰۵۲	۰/۵۴۸	۰/۶۶۱	-۰/۰۰۷۹
	GEP	۰/۷۶	۰/۰۶	۰/۰۵	۰/۵۷۵	۰/۵۶۶	۰/۰۰۰۳
KA-۶	ANN	۰/۷۳	۰/۰۶۴	۰/۰۵۳	۰/۵۴۲	۰/۵۵۱	۰/۰۱۵
	GEP	۰/۷	۰/۰۶۷	۰/۰۵۶	۰/۴۹۲	۰/۴۲۳	۰/۰۰۷۵

برای مقایسه بهتر هر دو روش، در شکل‌های ۴ و ۵ ضریب یکنواختی اندازه‌گیری شده و ضریب یکنواختی تخمین‌زده شده توسط مدل‌های شبکه عصبی مصنوعی و برنامه‌ریزی بیان ژن در مراحل آموزش و آزمون مدل‌ها، به تفکیک نوع آپاش ارایه شده است. بررسی شکل‌ها نشان می‌دهد که خطا در این مراحل کم بود و نتایج این مدل‌ها تقریباً به‌طور قرینه پیرامون خط ۱:۱ توزیع شده‌اند. علاوه‌بر این در هر دو مدل برنامه‌ریزی بیان ژن و شبکه عصبی مصنوعی، در مقادیر بالای یکنواختی بهبود پراکنش نقاط نسبت به مقادیر پایین یکنواختی بسیار مشهود است هر چند برتری نسبی در این نقاط با

مدل شبکه عصبی مصنوعی می‌باشد. این نتایج را به گونه‌ای می‌توان از جدول ۶ نیز استنباط کرد. به عبارت دیگر در یکنواختی‌های بالا نتایج هر دو مدل برنامه‌ریزی بیان ژن و شبکه عصبی مصنوعی تقریباً یکسان بود اما در یکنواختی‌های کم، مدل شبکه عصبی مصنوعی بهتر عمل نمود.



شکل ۴- نمودار پراکندگی داده‌های نرمال مشاهداتی و محاسباتی آپاش KA-۶ در بهینه‌ترین حالت اجرای مدل‌های برنامه‌ریزی بیان ژن و شبکه عصبی مصنوعی.



شکل ۵- نمودار پراکندگی داده‌های نرمال مشاهداتی و محاسباتی آپاش AQ-۲۰ در بهینه‌ترین حالت اجرای مدل‌های برنامه‌ریزی بیان ژن و شبکه عصبی مصنوعی.



### نتیجه گیری کلی

اختلاف جزئی بین نتایج مدل سازی دو روش برنامه ریزی بیان ژن و شبکه عصبی مصنوعی و نتایج آماره های ارزیابی مدل، نشان دهنده توفیق نسبی هر دو مدل در برآورد ضریب یکنواختی توزیع آب است اما با توجه به قابلیت مدل برنامه ریزی بیان ژن در استخراج رابطه ریاضی بهینه نسبت به سایر مدل های هوشمند، جنبه کاربردی این مدل بیش تر است. حداکثر بودن توان  $p$  در رابطه های ۹ و ۱۰، نتایج پژوهش مونته کارلو و همکاران (۲۰۰۳)، مبنی بر این که فشار کارکرد اصلی ترین عامل سیستمی مؤثر بر توزیع آب در آبیاری بارانی است را تأیید می کند. نمای کوچک ارتفاع پایه آبیاش ( $H_f$ )، بیانگر عدم تأثیر محسوس افزایش ارتفاع پایه آبیاش از (۶۰ به ۱۵۰ سانتی متر)، بر یکنواختی توزیع آب است. این نتیجه با نتایج پژوهش هزارجریبی و همکاران (۲۰۱۰) مطابقت دارد. با توجه به این که هر نوع آبیاش پروفیل پاششی خاص خود را دارد که به اندازه نازل و فشار کارکرد وابسته است، بنابراین لازم به ذکر است که نتایج به دست آمده از این پژوهش تنها در مورد آبیاش های مورد بحث (آبیاش AQUA مدل ۲۰- AQ ساخت کشور ایتالیا و همچنین آبیاش AKONA مدل ۶- KA ساخت کشور ترکیه) قابل استفاده بوده و ضمن امتناع از تعمیم آن به دیگر آبیاش ها باید برای هر نوع آبیاش رابطه ای جداگانه استخراج شود.

### منابع

1. Ababayi, B., and Verdinejad, V. 2013. Estimating the hydraulic performance of pressurized irrigation systems using artificial neural network and nonparametric regression models. *J. Soil Water*. 27: 4. 769-779. (In Persian)
2. Ahaneku, I.E. 2010. Performance evaluation of portable sprinkler irrigation system in Ilorin, Nigeria. *Ind. J. Sci. Technol*. 3: 7. 857-853.
3. Alizadeh, A. 2009. *Irrigation System Design (volume 2)*. Imam Reza University of Mashhad Press, 370p. (In Persian)
4. Aytok, A., and Kisi, O. 2008. A genetic programming approach to suspended sediment modeling. *J. Hydrol*. 351: 288-298.
5. Banzhaf, W., Nordin, P., Keller, P.E., and Francone, F.D. 1998. *Genetic programming*. Morgan Kaufmann, San Francisco. CA. 512p.
6. Bavi, A., Kashkouli, H., Vaelizade, M., and Broumandnasab, S. 2006. Evaluation of the weather and hydraulic parameters on water distribution uniformity in sprinkler irrigation at omidiye region. Conference on management of irrigation and drainage networks. Shahid Chamran University Ahvaz: 2-4 May 2006 (In Persian). Retrieved from: <http://www.civilica.com/paper.idncol-096.html>.

7. Dabbous, B. 1962. A study of sprinkler uniformity evaluation method. Thesis submitted to Utah, State University at Logan, Utah, in partial fulfillment of the requirements for the degree of Master of Science, Utah 84322.
8. Ehsani, M., and Khaledi, H. 2003. Recognition and improving water productivity in agriculture to water and food security in the country. 11<sup>th</sup> Conference of Iranian the National Committee on Irrigation and Drainage. Tehran: 16-17 November 2003. 1: 274-257. (In Persian)
9. Farzadmanesh, S. 2012. Estimation of the water distribution in sprinkler irrigation by using genetic algorithm method. A thesis submitted in partial fulfillment of the requirements for the degree of Master of Science in Irrigation and Drainage Engineering. Gorgan University of Agriculture Science and Natural Resources. (In Persian)
10. Ferreira, C. 2001. Gene expression programming a new adaptive algorithm for solving problems. *Complex Systems*. 13: 2. 87-129.
11. Ferreira, C. 2006. Gene expression programming: mathematical modeling by an artificial intelligence 2nd ed. Springer-Verlag, Germany.
12. Fukui, Y., Nakanishi, K., and Okamura, S. 1980. Computer evaluation of sprinkler irrigation uniformity. *Irrigation Science*. 2: 1. 23-32.
13. Ghorbani Dashtaki, S., Homaei, M., Mahdian, M.H., and Kouchakzadeh, M. 2009. Site-Dependence Performance of Infiltration Models. *Water Resource Manage*. DOI: 10.1007/s11269-009-9408-3.
14. Hart, W.E., and Reynolds, W.N. 1965. Analytical design-sprinkler system. *Transactions, American Society of Agricultural Engineers*. 1: 83-89.
15. Heerman, D.F. 1983. Design and operation of farm irrigation system. *American Society of Agricultural Engineers*. 18: 591-598.
16. Hezarjaribi, A., Dehghani, A.A., Hesam, M., and Sharifan, H. 2010. Estimation of the water distribution in sprinkler irrigation by using genetic algorithm method. *J. Soil Water Cons*. 18: 4. 129-140. (In Persian)
17. Karayiannis, N.B., and Venetsanopoulos, A.N. 1993. *Artificial Neural Network: Learning Algorithms, Performance Evaluation and Application*. Kluwer Academic Publisher, Boston.
18. Karmeli, D. 1997. Estimating sprinkler distribution pattern using ear regression. *Transactions American Society of Agricultural Engineers*. 21: 4. 682-685.
19. Keller, J., and Bliesner, R.D. 1990. *Sprinkler and trickle irrigation*. Van Nostrand Reinhold, New York, NY, USA. 652p.
20. Legates, D.R., and McCabe, G.J. 1999. Evaluating the use of goodness of fit measures in hydrologic and hydro climatic model validation. *Water Resources Research*. 35: 1. 233-241.
21. Merriam, J.I., and Keller, J. 1978. *Farm irrigation system evaluation*. Logan, Utah: Agricultural and Irrigation Engineering Department, Utah state University. 271p.

22. Montero, J., Tarjuelo, J.M., and Carrion, P. 2003. Sprinkler droplet size distribution measured with an optical spectro pluviometer. *Irrigation Science*. 22: 47-56.
23. OSEI, F.K.B. 2009. Evaluation of sprinkler irrigation system for improved maize seed production for farmers in Ghana. A Thesis for Master of Science. March: [http:// dspace.knust.edu.gh/dspace/bitstream 123456789/1939/1/fulltxt.pdf](http://dspace.knust.edu.gh/dspace/bitstream/123456789/1939/1/fulltxt.pdf).
24. Solomon, K. 1979. Variability of sprinkler coefficient of uniformity test results. *Transactions American Society of Agriculture Engineers*, 22: 1078-1080.
25. Traore, S., and Guven, A. 2012. Regional specific numerical models of evapotranspiration using gene-expression programming interface in Sahel. *Water Resources Management*, DOI: 10.1007/s11269-012-0149-3.
26. Vories, E.D., and Bernuth, R.D. 1986. Single nozzle sprinkler performance in wind. *Transactions American Society of Agriculture Engineers*. 29: 1325-1330.



Gorgan University of Agricultural  
Sciences and Natural Resources

*J. of Water and Soil Conservation, Vol. 21(6), 2015*  
<http://jwsc.gau.ac.ir>

## **Performance comparison of gene expression programming and artificial neural network methods to estimate water distribution uniformity in sprinkler irrigation**

**\*Z. Ghezelbash<sup>1</sup>, M. Zakerinia<sup>2</sup>, A. Hezarjaribi<sup>3</sup> and A.A. Dehghani<sup>3</sup>**

<sup>1</sup>M.Sc. Student, Dept. of Irrigation and Drainage, Gorgan University of Agricultural Sciences and Natural Resources, <sup>2</sup>Assistant Prof., Dept. of Water Engineering, Gorgan University of Agricultural Sciences and Natural Resources, <sup>3</sup>Associate Prof., Dept. of Water Engineering, Gorgan University of Agricultural Sciences and Natural Resources

Received: 02/08/2014; Accepted: 08/26/2014

### **Abstract**

Uniformity of sprinkler irrigation is an important technical parameter in the design of sprinkler irrigation systems and its value has a significant impact on the quality and the efficiency of investment in irrigation projects. With sprinkler irrigation, determining CU from a single sprinkler is time consuming due to the overlap of adjacent sprinklers and in different amounts of operating pressures ( $P$ ), riser heads ( $H_r$ ), sprinkler spacing on laterals ( $S_l$ ) and the distance between laterals ( $S_m$ ). In this research, CU quantities of two model sprinklers (AQ-20 and KA-6) were measured in slow wind velocity (0-2 m/s), at Hashemabad cotton research station of Gorgan city under 4 different operating pressures (2, 2.5, 3 and 3.5 at), 16 distances of sprinklers (including  $9 \times 18$ ,  $12 \times 18$ ,  $15 \times 18$ ,  $18 \times 18$ ,  $9 \times 15$ ,  $12 \times 15$ ,  $15 \times 15$ ,  $18 \times 15$ ,  $9 \times 12$ ,  $12 \times 2$ ,  $15 \times 12$ ,  $18 \times 12$ ,  $9 \times 9$ ,  $9 \times 12$ ,  $9 \times 15$ ,  $9 \times 18$ ), 4 riser heads (60, 90, 120 and 150 cm) and 3 arrangements of sprinklers (square, rectangular and triangular). For estimating CU based on gene expression programming (GEP) and artificial neural network (ANN) methods  $P$ ,  $H_r$ ,  $S_l$  and  $S_m$  were selected as the input variables. By statistical comparison of results, root mean square error (RMSE) for AQ-20 sprinkler in GEP and ANN methods were obtained as 0.06 and 0.062 and for KA-6 sprinkler as 0.067 and 0.064, respectively. The results indicate the high accuracy of the two methods for modeling since GEP is capable of estimating an explicit equation for estimating CU, it incorporates a more practical feature.

**Keywords:** Artificial intelligence, Irrigation system evaluation, Pressurized irrigation, Water distribution uniformity

---

\* Corresponding Author; Email: [ziba.ghezelbash@gmail.com](mailto:ziba.ghezelbash@gmail.com)