

برآورد عملکرد هیدرولیکی سیستم‌های آبیاری تحت فشار با استفاده از مدل‌های شبکه عصبی مصنوعی و رگرسیون ناپارامتری

بهنام آبابایی^{۱*} - وحیدرضا وردی‌نژاد^۲

تاریخ دریافت: ۱۳۹۱/۱۰/۱۸

تاریخ پذیرش: ۱۳۹۲/۵/۲۰

چکیده

در این مطالعه به منظور برآورد شاخص‌های عملکرد هیدرولیکی سیستم آبیاری تحت فشار، جایگزینی مدل‌های هیدرولیکی با استفاده از مدل‌های آماری و شبکه عصبی مصنوعی مورد ارزیابی قرار گرفت. ضریب یکنواختی کریستیانسن به عنوان شاخص عملکرد هیدرولیکی، در نظر گرفته شد و با استفاده از یک الگوریتم، مقادیر این شاخص به صورت تابعی از ترکیب‌های مختلف فشار ورودی، تعداد خروجی‌ها، فاصله خروجی‌ها، ضریب زبری لوله، قطر داخلی، شیب، دبی اسمی خروجی‌ها، فشار کارکرد خروجی‌ها و توان معادله دبی خروجی‌ها محاسبه گردید (۴۳۲۰ ترکیب مختلف). دو مدل شبکه عصبی مصنوعی شامل شبکه پرسپترون چندلایه (MLP) و شبکه رگرسیون تمم‌یافته (GRNN) و نیز روش K نزدیک‌ترین همسایه (KNN) به عنوان یک مدل رگرسیون ناپارامتری برای شبیه‌سازی شاخص عملکرد هیدرولیکی لاترال‌ها مورد آزمون قرار گرفتند. نتایج نشان داد که مدل شبکه عصبی مصنوعی MLP قادر است با کمترین خطا (۳-۲٪) مقادیر ضریب یکنواختی لاترال‌های آبیاری تحت فشار را با استفاده از مشخصات هیدرولیکی و فیزیکی لاترال برآورد نماید. عملکرد مدل GRNN نیز به ویژه در ارتباط با کل داده‌ها در سطح نسبتاً مطلوبی ارزیابی گردید. اما روش KNN علیرغم شبیه‌سازی دقیق متوسط مقادیر CU، قادر به شبیه‌سازی دقیق انحراف استاندارد این مقادیر نبوده و خطای آن در مرحله آزمون بسیار بیشتر از دو مدل دیگر برآورد گردید. در روش KNN، کمترین مقدار شاخص‌های خطا مربوط به رگرسیون ناپارامتری با ۱۰ و ۱۵ همسایه می‌باشد. نتایج این مطالعه نشان داد که امکان ساده‌سازی مدل‌های پیچیده هیدرولیکی با جایگزینی کل یا بخشی از این مدل‌ها با مدل‌های ساده‌تر آماری و شبکه عصبی وجود دارد و این مسئله با توجه به پیچیدگی مدل‌های هیدرولیکی، به ویژه در فرآیند بهینه‌سازی سیستم‌های آبیاری، می‌تواند مورد توجه قرار گیرد.

واژه‌های کلیدی: آبیاری تحت فشار، عملکرد هیدرولیکی، شبکه عصبی مصنوعی، K نزدیک‌ترین همسایه


مقدمه

شبکه‌ای کمک می‌کند تا طراح شبکه، بهترین تصمیم‌گیری را انجام دهد. بنابراین، طراحی یک شبکه توزیع آب یک مسئله پیچیده و شامل تصمیم‌گیری در ارتباط با چیدمان و اندازه لوله‌ها و تصمیم‌گیری در ارتباط با مشخصات سایر اجزاء شبکه می‌باشد (۱۱). در نهایت این مسئله به حصول کمترین هزینه سیستم و در عین حال، تأمین نیاز آبی در مقادیر متفاوت فشار، تبدیل می‌شود. در ارتباط با بهینه‌سازی در طراحی شبکه‌های توزیع آب شهری و روستایی مطالعات مفصلی انجام گرفته است که از آن جمله می‌توان به مطالعات واتاناتادا (۲۸)، شمیر (۲۲)، لانسو و میز (۱۷)، وارما و همکاران (۲۷)، لانگ و ناگاورو (۱۸)، تولسون و همکاران (۲۶) و بابایان و همکاران (۱۰) اشاره کرد. با این حال، مطالعات مرتبط با بهینه‌سازی سیستم‌های آبیاری تحت فشار کمتر مورد توجه قرار گرفته است. از جمله چنین مطالعاتی می‌توان به مطالعه آبابایی و سهرابی (۲) اشاره کرد که در طی آن، با

یک سیستم توزیع آب می‌تواند شامل شبکه لوله‌ها، مخزن، پمپ، شیرها و دیگر اجزاء هیدرولیکی باشد. هدف از طراحی یک سیستم توزیع آب، تأمین آب در شرایط مختلف بهره‌برداری و تقاضا برای مصرف‌کنندگان می‌باشد. به منظور تحلیل رابطه بین اجزاء مختلف چنین سیستمی، سیستم توزیع آب به یک شبکه توزیع آب تبدیل می‌گردد (۳۱). تصمیم‌گیری در انتخاب اجزاء چنین شبکه‌ای مشتمل بر انتخاب از میان گزینه‌های مختلف می‌باشد. بهینه‌سازی در چنین

۱- دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، باشگاه پژوهشگران جوان و نخبگان، تهران، ایران
* نویسنده مسئول: (Email: behnam.ab@gmail.com)
۲- استادیار گروه مهندسی آب، دانشکده کشاورزی، دانشگاه ارومیه، ارومیه، ایران

به شبیه‌سازی دقیق دامنه وسیعی از ارتباطات بین ورودی‌ها و خروجی‌ها می‌باشند. با آموزش شبکه با استفاده از نمونه‌ای از ورودی‌ها و خروجی‌ها، شبکه‌های MLP قادرند ورودی‌های جدید را به خوبی شبیه‌سازی کرده و ارتباط آنها با خروجی‌ها مربوطه را تشخیص دهند. با این حال، شبکه‌های MLP بطور استاتیک عمل کرده، فاقد حافظه بوده و در آنها، بردار ورودی‌ها، رابطه زمانی ورودی‌ها با یکدیگر و با خروجی‌ها را در نظر نمی‌گیرند. شکل ۱ ساختار ساده یک شبکه عصبی MLP را نشان می‌دهد (۱۹).



شکل ۱- ساختار ساده یک مدل شبکه عصبی با ساختار پرسپترون چند لایه

شبکه‌های رگرسیون تعمیم یافته^۴ (GRNNs)، در طبقه‌بندی، جزو دسته شبکه‌های عصبی احتمالاتی^۵ قرار می‌گیرند. استفاده از شبکه‌های احتمالاتی دارای مزایایی می‌باشد. این نوع شبکه‌ها قادرند با تعداد نمونه آموزشی محدود، به سرعت به سمت تابع مورد نظر همگرا شوند که این، خود مزیتی در مقایسه با شبکه‌های عصبی بازخوردی^۶ محسوب می‌شود. برای برآزش دقیق‌تر این نوع شبکه‌ها بر روی اطلاعات، دانش کمی مورد نیاز است و این مسئله، شبکه‌های GRNN را تبدیل به ابزاری بسیار مفید در پیش‌بینی و مقایسه عملکرد سیستم‌های مختلف می‌سازد. یک شبکه رگرسیون تعمیم‌یافته، شامل چهار لایه است: لایه ورودی‌ها، لایه الگو^۷، لایه تجمیع^۸ و لایه خروجی. اولین لایه بطور کامل به لایه الگو متصل است، جاییکه هر واحد، نماینده یک الگوی آموزشی بوده و خروجی آن، فاصله از ورودی ذخیره شده در الگوها می‌باشد. هر واحد در لایه الگو، به دو نرون در لایه تجمیع متصل است: نرون تجمیع S و نرون تجمیع D. نرون S جمع وزنی خروجی‌های الگو را محاسبه می‌کند، در حالیکه نرون D خروجی‌های غیر وزنی نرون‌های الگو را محاسبه می‌کند. وزن بین یک نرون در لایه الگو و نرون S برابر با

استفاده از روش برنامه‌ریزی غیرخطی، یک مدل بهینه‌سازی دو مرحله‌ای برای بهینه‌سازی طراحی و بهره‌برداری از شبکه‌های آبیاری تحت فشار توسعه یافته و مورد ارزیابی قرار گرفت. هزارجریبی و همکاران (۸) نیز با استفاده از الگوریتم ژنتیک، معادله غیرخطی برای برآورد ضریب یکنواختی کریستیانسن ارائه کردند که ورودی‌های آن، فشار کارکرد آبیاش، ارتفاع پایه آبیاش، فاصله آبیاش‌ها روی لاترال و فاصله لاترال‌ها بود. شاخص SRMSE این معادله برابر با ۳/۵۷ و شاخص ضریب تبیین آن برابر با ۰/۹۲ گزارش شده است. از سوی دیگر، یکی از مهمترین مسائل در طراحی سیستم‌های آبیاری تحت فشار، یکنواختی توزیع آب می‌باشد. با این حال، عمده مطالعات مرتبط با این حوزه بر اندازه‌گیری و تحلیل شرایط بهره‌برداری سیستم‌های موجود متمرکز بوده (۱، ۴، ۵، ۶ و ۷) و کمتر به مدل‌سازی و بهینه‌سازی در طراحی این سیستم‌های پرداخته شده است. یکی از دلایلی که چنین مطالعاتی را با مشکل مواجه می‌سازد، پیچیدگی مدل‌های هیدرولیکی در تلفیق با الگوریتم‌های بهینه‌سازی می‌باشد. در این راستا، ساده‌سازی فرآیند بهینه‌سازی به وسیله جایگزینی مدل‌های پیچیده هیدرولیکی با مدل‌های ساده‌تر آماری می‌تواند مورد توجه قرار گیرد. بر این اساس، هدف از این مطالعه، ارزیابی عملکرد مدل‌های شبکه عصبی مصنوعی و روش رگرسیون ناپارامتری در برآورد شاخص‌های عملکرد لاترال‌های سیستم آبیاری تحت فشار و امکان سنجی جایگزینی مدل‌های هیدرولیکی با مدل‌های آماری می‌باشد.

مواد و روش‌ها

شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی^۱ (ANNs) ابزار ریاضی قدرتمندی هستند که با تقلید ساده از سیستم عصبی بیولوژیک ساخته شده‌اند. این شبکه‌ها قدرت انعطاف و تصحیح‌پذیری بالایی در انطباق خود با داده‌های موجود دارند. مهمترین موضوع در این مدل‌ها، انتخاب ورودی‌های مناسب به مدل برای رسیدن به خروجی‌های مد نظر می‌باشد. علاوه بر آن ساختار و نحوه انتخاب ارتباط بین نرون‌ها و وزنی که هر نرون به خود اختصاص خواهد داد از اهمیت بالایی برخوردار است. ساختار یک شبکه عصبی متشکل از تعداد لایه‌ها، تعداد نرون‌ها در هر لایه، نحوه ارتباط لایه‌ها باهم، روش آموزش شبکه و نحوه توزیع پارامترها (وزن‌ها) می‌باشد. شبکه‌های پرسپترون چندلایه^۲ (MLP) از چند لایه تشکیل می‌شوند که هر لایه، ورودی لایه بعدی را (به صورت پیشخور^۳) تولید می‌کند. این شبکه‌ها در سطح وسیع و در حوزه‌های مختلف مورد استفاده قرار گرفته‌اند و قادر

4-Generalized Regression Networks
5-Probabilistic Neural Networks
6-Backpropagation
7-Pattern layer
8-Summation layer

1-Artificial Neural Networks
2-Multi-layer perceptron networks
3-Feed-Forward

برای بی‌بعدسازی هریک از متغیرها، پیش از محاسبه فاصله از رابطه فوق، داده‌ها با استفاده از میانگین و انحراف استاندارد آنها استاندارد می‌شوند. بی‌بعدسازی هریک از متغیرها، باعث می‌شود تا هریک از آنها در انتخاب نزدیک‌ترین همسایه‌ها، نقش یکسانی داشته باشند (۱۵ و ۲۳). پس از تعیین فاصله تمامی نمونه‌ها از نمونه مورد نظر، این مقادیر به صورت صعودی (کوچک به بزرگ) مرتب شده و K نمونه اول انتخاب می‌شوند. اساس روش‌های ناپارامتری مشابه با KNN، ساخت یک سری از اعداد براساس تابع توزیع تجمعی مشروط^۶ تخمین زده شده از داده‌های مشاهده شده می‌باشد. برای تعیین وزن هریک از K نمونه در تعیین متغیر وابسته، روابطی ارائه شده که در این مطالعه، از رابطه زیر استفاده شد:

$$\{t, Xi\} = \begin{cases} \frac{1}{d(k)^P} & k \leq K \\ 0 & k > K \end{cases} \quad (2)$$

که در آن $d(k)$: فاصله محاسبه شده نمونه i از نمونه t و P : پارامتر رابطه می‌باشد. در نهایت پس از استاندارد سازی وزن‌ها (مجموع وزن‌ها برابر با یک)، متغیر وابسته مورد نظر در زمان t از رابطه زیر محاسبه می‌شود.

$$Z_t = \sum_{i=1}^K \alpha(X_t, X_i) Z_i \quad (3)$$

که در آن Z_i مقدار متغیر وابسته در همسایه i می‌باشد. تعیین تعداد همسایه‌ها (K) از اهمیت زیادی برخوردار است. تعداد زیاد K منجر به نرم‌شدن^۷ داده‌ها شده و کم بودن آن نیز می‌تواند به جواب‌های نادرست منجر گردد.

تولید داده

به منظور تولید داده‌های مورد نیاز برای آموزش مدل‌های آماری، از یک الگوریتم کامپیوتری استفاده شد. این الگوریتم، محاسبات هیدرولیکی لاترال‌های آبیاری تحت فشار را به صورت گام به گام انجام داده و شاخص‌های عملکرد آنها را با توجه به فشار و دبی ورودی و مشخصات فیزیکی لاترال (قطر داخلی، شیب و ضریب زبری) و خروجی‌ها (دبی و فشار اسمی و توان معادله دبی) برآورد می‌نماید. برای محاسبه افت هیدرولیکی در قطعات لوله بین خروجی-ها، از معادله هیزن-ویلیامز به شرح رابطه زیر استفاده شد:

$$= 1.22 \times 10^{10} L \left(\frac{Q}{C}\right)^{1.852} D^{-4.871} \quad (4)$$

مقدار خروجی مربوط به ورودی لایه الگو می‌باشد. در مورد نرون D ، این وزن برابر یک است.

لایه خروجی، خروجی مربوط به هر نرون S را به خروجی نرون D تقسیم کرده و خروجی نهایی مربوط به یک بردار ورودی ناشناخته را بدست می‌دهد. عملکرد نرون تجمیع D شامل پارامتری به نام پارامتر گسترش می‌باشد که تعیین مقدار بهینه آن با سعی و خطا امکان‌پذیر است.

رگرسیون ناپارامتری

روش نزدیک‌ترین همسایه^۱ (NN) یکی از ساده‌ترین روش‌های ناپارامتری دسته بندی الگویی^۲ می‌باشد. روش NN را می‌توان به صورت ساده به این صورت تشریح نمود: دسته‌بندی یک الگوی نامشخص و انتخاب کلاسی که نزدیک‌ترین نمونه به آن در آن کلاس واقع شده است. روش KNN^۳ در واقع توسعه یافته روش NN می‌باشد که در آن، بارزترین کلاس در میان K نزدیک‌ترین همسایه‌ها انتخاب می‌شود. اخیراً استفاده از رگرسیون ناپارامتری و به خصوص روش نزدیک‌ترین همسایه (KNN) در مدل‌سازی و تخمین برخی پارامترها در زمینه سنجش از دور (۱۲)، پیش‌بینی ترافیک (۱۴)، تحقیقات مولکولی (۳۰)، خاکشناسی (۲۰) و هیدرولوژی (۹ و ۲۵) مورد استفاده وسیع قرار گرفته است. استفاده از روش KNN در هواشناسی بسیار مورد توجه قرار گرفته است. یانگ (۳۱) از این روش برای تعیین همبستگی بین دما و بارندگی استفاده کرد. بیرسما و بوشاند (۱۱) برای شبیه‌سازی روزانه بارندگی و دما در چند ایستگاه از روش KNN استفاده نمود. راجاگوپالان و لال (۲۱) با استفاده از روش KNN بارندگی روزانه و دیگر متغیرهای هواشناسی را پیش‌بینی کردند. برای مجموعه‌ای از نمونه‌ها به شکل $\{(X_i, Z_i) \mid i = 1, \dots, n\}$ به منظور آموزش (واسنجی) مورد استفاده قرار گیرند؛ X بردار m بعدی از متغیرهای مستقل (ویژگی‌ها یا پردیکتورها^۴) و Z شاخص کلاس (متغیر وابسته) را نشان می‌دهد. به منظور تشخیص همسایه‌ها، لازم است که یک تابع فاصله (یا شباهت^۵) مورد استفاده قرار گیرد. گونه‌های مختلفی از این تابع پیشنهاد شده است (۲۹). از جمله توابع فاصله مرسوم، تابع فاصله اقلیدسی می‌باشد که برای دو نمونه X_i و X_j به صورت زیر بیان می‌شود.

$$d_{t,i} = \sqrt{\sum_{j=1}^m (X_{j,i} - X_{j,t})^2} \quad (1)$$

که $X_{j,i}$ نشان دهنده ویژگی یا پردیکتور j از نمونه i می‌باشد. معمولاً

- 1-Nearest Neighbor
- 2- Pattern Classification
- 3-K-Nearest Neighbors
- 4- Attributes or Predictors
- 5- Distance (or Similarity) Function

- 6-Conditional Cumulative Distribution Function (CDF)
- 7- Smoothing

خروجی‌ها و دبی محاسبه شده برای آن خروجی محاسبه می‌شود. مقدار اولیه این متغیر هیدرولیکی برابر با مجموع دبی اسمی تمامی خروجی‌های موجود بر روی لاترال در نظر گرفته شد. همچنین، از آنجاییکه در سیستم‌های آبیاری قطره‌ای معمولاً از لوله‌های ۱۲ و ۱۶ میلیمتری (قطر خارجی) استفاده می‌شود، همین دو قطر لوله در بین ترکیب‌ها مورد استفاده قرار گرفتند.

جدول ۱- ترکیب‌های مورد استفاده در تحلیل هیدرولیکی*

متغیر هیدرولیکی	واحد	حداقل	حداکثر	فواصل
فشار ورودی به لاترال	متر	۸	۲۰	۴
تعداد خروجی‌ها	---	۳۰	۵۰	۱۰
ضریب زبری لوله	---	۱۳۰	۱۵۰	۱۰
قطر داخلی لوله	میلیمتر	۱۲	۱۴/۲	---
دبی اسمی قطره‌چکان	لیتر در ساعت	۴	۱۶	۴
شیب زمین	متر در متر	-۰/۱	۰/۱	۰/۱

*- فشار اسمی قطره‌چکان‌ها برابر ۱۰ متر، توان معادله دبی برابر ۰/۵

آموزش و ارزیابی مدل‌ها

پیش از آموزش و ارزیابی مدل‌های شبکه عصبی مصنوعی، پیش‌پردازش اطلاعات ورودی و خروجی مدل انجام گرفت. به این ترتیب که با استفاده از متوسط و انحراف استاندارد ورودی‌ها و خروجی‌ها، این مقادیر به داده‌های استاندارد تبدیل شدند. در مدل MLP، به عنوان توابع فعال‌سازی در لایه مخفی و لایه خروجی، به ترتیب توابع هایپربولیک تانجانت سیگموئیدی و تابع خطی به همراه تابع آموزش مارکوورت-لونبرگ مورد استفاده قرار گرفت (۱۹). فرآیند آموزش این دو مدل به ترتیب شامل انتخاب تعداد نرون‌ها در لایه مخفی (در مدل MLP) و انتخاب پارامتر گسترش (در مدل GRNN) می‌باشد. تعداد نرون‌ها بین ۵ تا ۳۰ و مقدار پارامتر گسترش بین ۰/۱ تا ۱ در نظر گرفته شد. برای آموزش مدل MLP، ۶۰ درصد اطلاعات (به صورت تصادفی) و برای ارزیابی و آزمون ۲۰ درصد اطلاعات مورد استفاده قرار گرفت. در ارتباط با مدل GRNN، از آنجاییکه مرحله اعتبارسنجی وجود ندارد، ۸۰ درصد اطلاعات برای آموزش و ۲۰ درصد برای آزمون استفاده شد.

فرآیند ارزیابی روش رگرسیون ناپارامتری به انتخاب تعداد پارامتر K محدود می‌شود. برای محاسبه وزن هریک از همسایه‌ها، از رابطه ۲ استفاده گردید (پارامتر P برابر با ۲ در نظر گرفته شد). ارزیابی رگرسیون ناپارامتری با استفاده از روش اعتبارسنجی متقاطع صورت پذیرفت. به این ترتیب که بصورت تصادفی، ۲۰ درصد از کل داده‌ها حذف شده و با استفاده از الگوریتم KNN مقادیر شاخص‌های عملکرد برای این درصد حذف شده محاسبه شده و با مقادیر حاصل از مدل

که در آن، h_f : تلفات اصطکاکی (متر)، L : طول قطعه لوله (متر)، Q : دبی قطعه لوله (لیتر در ثانیه)، C : ضریب زبری و D : قطر داخلی لوله (میلیمتر) می‌باشد. از بین شاخص‌های عملکرد مرسوم برای ارزیابی یکنواختی توزیع سیستم‌های آبیاری تحت فشار، از شاخص ضریب یکنواختی کریستیانسن^۱ (CU) استفاده شد:

$$CU = 1 - \frac{\sum_{i=1}^n (q_i - \bar{q})}{n\bar{q}} \quad (5)$$

که در آن، CU: ضریب یکنواختی کریستیانسن، q : دبی خروجی از خروجی شماره i (لیتر در ساعت)، n : تعداد خروجی‌ها و \bar{q} : متوسط دبی خروجی‌ها در طول لاترال می‌باشد. دابوس به روش‌های آماری نشان داد که ضریب یکنواختی کریستیانسن در مقایسه با سایر روابط برای اندازه‌گیری مقدار یکنواختی توزیع آب در آبیاری بارانی از اعتبار بیشتری برخوردار است (۱۳). سولومون و هیرمان نیز بر عمومی بودن و معمول بودن کاربرد این شاخص تأکید نموده‌اند. به منظور تحلیل میزان تلفات و کمبود جریان خروجی از هریک از خروجی‌ها، از دو شاخص هیدرولیکی نسبت حجم کمبود^۲ (DVR) و نسبت حجم تلفات^۳ (LVR) نیز به شرح روابط زیر استفاده گردیده است (Q_{in}): جریان ورودی به لاترال و q_a : دبی اسمی خروجی‌ها می‌باشد (۱۶) و (۲۴):

$$VR = \frac{\sum_{i=1}^n (q_a - q_i)}{Q_{in}} \quad \text{for } q_i < q_a \quad (6)$$

$$VR = \frac{\sum_{i=1}^n (q_i - q_a)}{Q_{in}} \quad \text{for } q_i > q_a \quad (7)$$

به منظور استفاده از الگوریتم شبیه‌سازی هیدرولیکی، ۴۳۲۰ ترکیب مختلف از فشار ورودی، تعداد خروجی‌ها، فاصله خروجی‌ها، ضریب زبری لوله، قطر داخلی، شیب، دبی اسمی خروجی‌ها، فشار کارکرد (اسمی) خروجی‌ها و توان معادله دبی خروجی‌ها (x) برای یک سیستم آبیاری قطره‌ای مورد ارزیابی قرار گرفت. جدول ۱، مشخصات ترکیب‌های مورد استفاده را نشان می‌دهد. به منظور کاهش تعداد ترکیب‌ها، فشار اسمی و توان معادله قطره‌چکان‌ها در همه ترکیب‌ها ثابت فرض گردید که البته امکان استفاده از این دو پارامتر نیز به عنوان ورودی‌های مدل‌های آماری وجود دارد. دبی ورودی به لاترال، در یک فرآیند تکراری و بر اساس فشار موجود در محل هریک از

- 1- Christiansen Coefficient of Uniformity
- 2-Deficit Volume Ratio
- 3- Loss Volume Ratio

4-Cross-validation

هیدرولیکی مورد مقایسه قرار گرفت. برای ارزیابی مدل‌ها، از دو شاخص استاندارد شده ریشه میانگین مربع خطاها (SRMSE)^۱ و میانگین خطاهای مطلق (SMAE)^۲ بین سری مشاهداتی و سری‌های مصنوعی را نشان می‌دهد که از روابط ۸ و ۹ محاسبه می‌شوند. در این روابط: O و P به ترتیب مقادیر مشاهداتی و مصنوعی، \bar{O} و \bar{P} میانگین مقادیر مشاهداتی و مصنوعی، n تعداد داده در هر یک از سری‌ها می‌باشند.

$$SRMSE = \left[\frac{\sum_{i=1}^n (P_i - O_i)^2}{n} \right]^{0.5} \times \frac{100}{\bar{O}} \quad (۸)$$

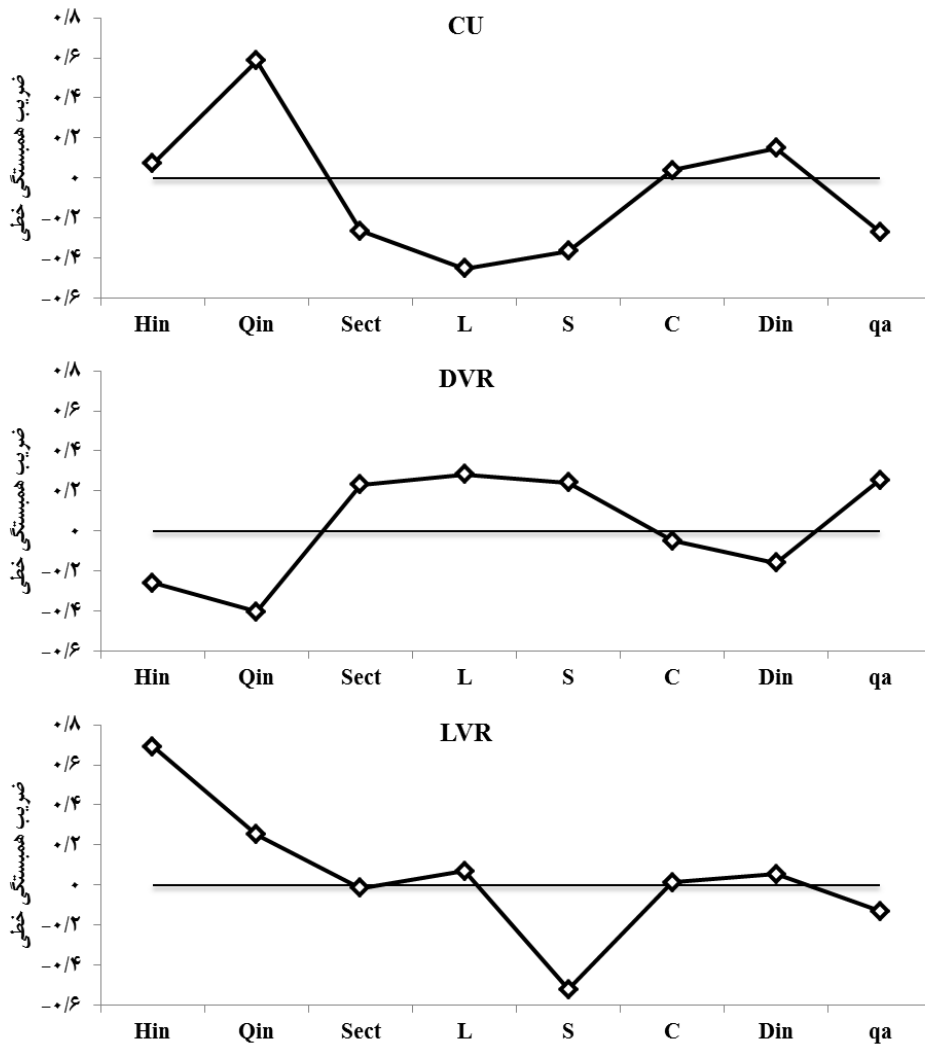
$$SMAE = \frac{\sum_{i=1}^n |P_i - O_i|}{n} \times \frac{100}{\bar{O}} \quad (۹)$$

نتایج و بحث

تحلیل شاخص‌های هیدرولیکی

شکل ۲، ضریب همبستگی خطی بین متغیرهای ورودی و شاخص‌های عملکرد لاترال را نشان می‌دهد. بر اساس آن، مشخص است که افزایش فشار ورودی به لاترال (H_{in})، بطور کلی تأثیر مثبت قابل توجهی بر شاخص CU ندارد. دلیل این مسئله را می‌توان در بخش دوم و سوم این شکل جستجو کرد. شاخص‌های LVR و DVR نشان می‌دهند که افزایش فشار ورودی بطور کلی درصد کمبود جریان در خروجی‌ها را کاهش می‌دهد، اما در مقابل، بطور قابل توجهی موجب افزایش تلفات در ابتدای لاترال می‌گردد.

5-Standardized root mean square error
6-Standardized mean absolute error



شکل ۲- ضریب همبستگی خطی بین متغیرهای ورودی و شاخص های عملکرد لاترال

جریان اضافه از خروجی‌های ابتدایی و در نهایت افزایش تلفات می‌باشد. ضریب زبری لوله‌ها (C) نیز همبستگی قابل توجهی با شاخص‌های عملکرد لاترال از خود نشان نمی‌دهد. هرچند افزایش همبستگی جزئی مثبت بین این متغیر و شاخص CU و همبستگی جزئی منفی بین این متغیر با شاخص DVR قابل توجه است. همانطور که انتظار می‌رفت، افزایش قطر داخلی لوله (Din) باعث افزایش ضریب یکنواختی می‌گردد و این مسئله، در نمودار همبستگی این متغیر هیدرولیکی با شاخص CU مشهود است. با اینحال، افزایش متغیر Din می‌تواند منجر به کاهش کمبود (DVR) و تا حدودی افزایش تلفات (LVR) در طول لاترال گردد. هرچند همبستگی منفی متغیر Din با شاخص DVR بزرگتر از همبستگی مثبت آن با شاخص LVR می‌باشد.

وضعیت مشابهی در ارتباط با جریان ورودی به لاترال (Q_{in}) نیز حاکم است. در ارتباط با طول لاترال (فواصل خروجی‌ها، L و تعداد خروجی‌ها، S_{sect})، افزایش طول لاترال بطور کلی باعث کاهش ضریب یکنواختی (CU) می‌گردد. دلیل این مسئله، افزایش شاخص DVR (درصد کمبود جریان) در لاترال به دلیل عدم امکان انتقال جریان کافی به انتهای لاترال می‌باشد. با این حال، افزایش طول لاترال همبستگی خطی چندانی با میزان تلفات (شاخص LVR) ندارد، هرچند که این همبستگی، یک همبستگی جزئی و مثبت است. تأثیر شیب زمین بر شاخص‌های CU و DVR مشابه تأثیر طول لاترال می‌باشد. با این حال، افزایش شیب همبستگی منفی قابل توجهی با شاخص LVR نشان می‌دهد. دلیل این مسئله، عدم انتقال بخش زیادی از جریان در شیب‌های مثبت به انتهای لاترال و خروج

آزمون منجر نگردیده است.

در ارتباط با روش KNN، کمترین مقدار شاخص SMRSE مربوط به رگرسیون ناپارامتری با ۱۵ همسایه (۲۰/۵ درصد) و کمترین مقدار شاخص SMAE مربوط به انتخاب ۱۰ همسایه (۱۴/۷ درصد) می‌باشد. لازم به یادآوری است که این روش نیز در سه تکرار و در هر تکرار با استفاده از ۲۰ درصد از داده‌ها مورد ارزیابی قرار گرفت. مشخصاً عملکرد این مدل در مقایسه با مدل‌های شبکه عصبی مصنوعی در سطح مطلوبی قرار ندارد. شکل ۴، مقادیر متوسط و انحراف استاندارد ضرائب یکنواختی (CU) محاسبه شده توسط مدل هیدرولیکی (Obs) و برآورد شده (Sim) توسط مدل‌های شبکه عصبی مصنوعی و روش رگرسیون ناپارامتری را برای مرحله آزمون نشان می‌دهد. متوسط (Mean) شاخص CU در دوره آزمون برای مدل شبیه‌ساز برابر با ۲۵ درصد بوده است که بهترین مدل MLP این مقدار را ۲۵ درصد و بهترین مدل‌های GRNN و KNN این مقدار را ۲۶ درصد برآورد نموده‌اند. دلیل عمده برآورد دقیق‌تر متوسط مقادیر CU توسط دو مدل آخر این است که این دو مدل، ماهیتاً قادر به برونیابی مقادیر نبوده و همواره به مقادیری در دامنه مقادیر مرحله آموزش منجر می‌شوند. در مقابل، انحراف استاندارد (S_{id}) مقادیر CU مدل شبیه‌ساز در دوره آزمون برابر با ۵۸ درصد می‌باشد که این مقدار توسط بهترین مدل‌های MLP، GRNN و KNN به ترتیب ۵۸، ۵۶ و ۵۳ درصد برآورد شده‌اند. مشخصاً در بین تمامی مدل‌ها، مدل MLP علاوه بر دارا بودن کمترین مقدار شاخص‌های عملکرد، مقادیر متوسط و انحراف استاندارد ضریب یکنواختی کریستیانسن را با کمترین خطا شبیه‌سازی نموده است. هرچند توجه به این مسئله ضروریست که در برخی موارد و برای مقادیر CU نزدیک به ۱، مدل MLP به مقادیر بزرگتر از یک منجر می‌گردد. هرچند که تجاوز خروجی‌های این مدل از مقدار یک بسیار جزئی و قابل اغماض است. روش KNN علی‌رغم توانایی مطلوب در شبیه‌سازی مقادیر میانگین ضریب یکنواختی، انحراف استاندارد این مقادیر را کمتر از مقدار شبیه‌سازی شده توسط مدل هیدرولیکی برآورد نموده است. در این ارتباط، عملکرد مدل GRNN از مدل MLP ضعیف‌تر و از مدل KNN بهتر بوده است.




نتیجه گیری

در این مطالعه، جایگزینی مدل‌های هیدرولیکی با استفاده از مدل‌های آماری به منظور برآورد شاخص‌های عملکرد هیدرولیکی سیستم‌های آبیاری تحت فشار مورد ارزیابی قرار گرفت.


آخرین متغیر هیدرولیکی مورد بررسی، دبی اسمی خروجی‌های (q_a) می‌باشد. مشخصاً افزایش مقدار q_a باعث افزایش تلفات اصطکاکی و کاهش یکنواختی توزیع آب (کاهش شاخص CU) می‌گردد. با اینحال، نمودارهای همبستگی شکل ۲ نشان می‌دهند که افزایش q_a همبستگی مثبت قابل توجهی با درصد کمبود و همبستگی منفی قابل توجهی با درصد تلفات در طول لاترال دارد. چراکه افزایش دبی اسمی خروجی‌ها و در نتیجه دبی مورد نیاز در ابتدای لاترال، موجب افزایش فشار مورد نیاز در ابتدای لاترال گردیده که این مسئله خود منجر به خروج بخش بیشتری از جریان ورودی به لاترال از خروجی‌های ابتدایی و افزایش درصد کمبود در میانه و ابتدای لاترال می‌گردد. در مقابل، افزایش دبی اسمی خروجی‌ها باعث هدایت بخش بیشتری از جریان به سمت انتهای لاترال و کاهش تلفات در ابتدای لاترال می‌گردد. هرچند که همبستگی متغیر q_a با شاخص DVR بیشتر از شاخص LVR می‌باشد.

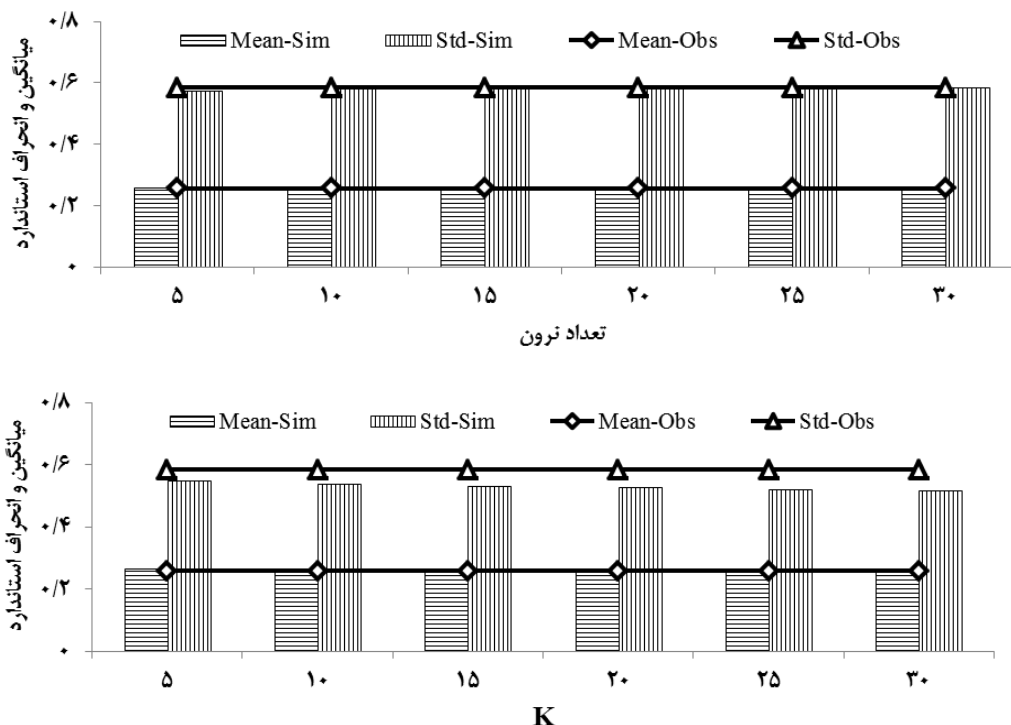
ارزیابی مدل‌های آماری

به منظور ارزیابی مدل‌های شبکه عصبی مصنوعی و روش رگرسیون ناپارامتری، ارزیابی در سه تکرار مختلف و با انتخاب تصادفی مجموعه داده‌های آموزش، اعتبارسنجی و آزمون انجام گرفت. در نهایت، مقادیر شاخص‌های عملکرد مدل به صورت متوسط شاخص‌ها در این سه تکرار محاسبه شدند. شکل ۳، مقادیر متوسط شاخص‌های SRMSE و SMAE را برای مدل‌های شبکه عصبی مصنوعی و رگرسیون ناپارامتری نشان می‌دهد. کمترین خطا در بین تمامی مدل‌ها در مرحله آزمون (Test) و برای کل داده‌ها (All)، مربوط به مدل MLP با تعداد ۲۵ نرون در لایه مخفی می‌باشد. مقادیر شاخص‌های عملکرد این مدل در مرحله آزمون به ترتیب برابر با ۲/۶ و ۲ درصد و برای کل داده‌ها برابر با ۲/۴ و ۱/۹ درصد می‌باشد. این درحالی است که بهترین عملکرد در مرحله آزمون در بین مدل‌های GRNN، مربوط به مدل با مقدار پارامتر گسترش ۰/۵-۰/۶ می‌باشد. مقدار شاخص‌های SRMSE و SMAE مربوط به مقدار پارامتر گسترش برابر با ۰/۵ به ترتیب برابر با ۲۰/۶ و ۱۴/۴ درصد می‌باشد. در ارتباط با کل داده‌ها، بهترین عملکرد مدل‌های GRNN مربوط به مقدار پارامتر گسترش ۰/۳-۰/۴ می‌باشد که شاخص SRMSE مدل اول برابر با ۱۰/۳ درصد و شاخص SMAE مدل دوم برابر با ۳/۵ درصد می‌باشد که در بین تمامی مدل‌های GRNN کمترین مقادیر محسوب می‌شوند. این مسئله نشان می‌دهد که در مرحله آموزش مدل‌های GRNN باید از آموزش بیش از اندازه مدل در ارتباط با داده‌های مرحله آموزش اجتناب نمود. چرا که لزوماً کمترین خطا در مرحله آموزش، به کمترین میزان خطا در مرحله



شکل ۳- شاخص‌های عملکرد مدل‌های MLP و GRNN و روش KNN





شکل ۴- متوسط و انحراف استاندارد شبیه‌سازی شده ضریب یکنواختی کریستیانسن از مدل شبیه‌ساز هیدرولیکی (Obs) در مقابل مقادیر شبیه‌سازی شده (Sim) توسط مدل‌های MLP و GRNN و روش KNN

درصد) مقادیر ضریب یکنواختی لاترال‌های آبیاری تحت فشار را با استفاده از مشخصات هیدرولیکی و فیزیکی لاترال برآورد نماید. عملکرد مدل GRNN نیز به ویژه در ارتباط با کل داده‌ها در سطح نسبتاً مطلوبی ارزیابی گردید. اما روش KNN علیرغم شبیه‌سازی دقیق متوسط مقادیر CU، قادر به شبیه‌سازی دقیق انحراف استاندارد این مقادیر نبوده و خطای آن در مرحله آزمون بسیار بیشتر از دو مدل دیگر برآورد گردید. نتایج این مطالعه نشان داد که امکان ساده‌سازی مدل‌های پیچیده هیدرولیکی با جایگزینی کل یا بخشی از این مدل‌ها با مدل‌های ساده‌تر آماری وجود دارد و این مسئله، به ویژه در فرآیند بهینه‌سازی سیستم‌های آبیاری که پیچیدگی مدل‌های هیدرولیکی و زمان زیاد مورد نیاز این مدل‌ها برای شبیه‌سازی عملکرد هیدرولیکی سیستم جزو پیچیدگی‌های مسئله می‌باشد، می‌تواند مورد توجه قرار گیرد.

پس از طراحی الگوریتم کامپیوتری مدل شبیه‌ساز هیدرولیکی، مقادیر ضریب یکنواختی کریستیانسن بعنوان شاخص عملکرد هیدرولیکی سیستم برای ترکیب‌های مختلف فشار ورودی، تعداد خروجی‌ها، فاصله خروجی‌ها، ضریب زبری لوله، قطر داخلی، شیب، دبی اسمی خروجی‌ها، فشار کارکرد (اسمی) خروجی‌ها و توان معادله دبی خروجی‌ها محاسبه شده و این مقادیر، بعنوان ورودی‌ها و خروجی‌های مدل‌های آماری مورد نظر در مرحله آموزش مورد استفاده قرار گرفتند.

دو مدل شبکه عصبی مصنوعی (شبکه پرسپترون چندلایه و شبکه رگرسیون تعمیم‌یافته) در کنار روش رگرسیون ناپارامتری نزدیکترین همسایه (KNN) برای شبیه‌سازی شاخص عملکرد هیدرولیکی لاترال‌ها مورد آزمون قرار گرفتند. نتایج نشان داد که یک مدل شبکه عصبی مصنوعی MLP قادر است با کمترین خطا (۲-۳)

منابع

- ۱- اکبری م. و رحیم زادگان ر. ۱۳۷۵. اثرات باد و خصوصیات هیدرولیکی سیستم آبیاری بارانی بر یکنواختی توزیع آب. مجموعه مقالات دومین کنگره ملی مسائل آب و خاک کشور، تهران، صص: ۵۴-۶۴
- ۲- آبابایی ب. و سهرابی ت. ۱۳۸۹. تدوین الگوریتم دو مرحله‌ای بهینه‌سازی اقتصادی سیستم‌های آبیاری تحت فشار. مجله آب و خاک (علوم و

- صنایع کشاورزی): ۳۴(۴): ۶۶۸-۶۷۸
- ۳- باوی ع، برومندنسب س. و ناصری ع.ع. ۱۳۸۹. اثر عوامل گیاهی و هیدرولیکی بر ضریب یکنواختی توزیع آب در آبیاری بارانی کلاسیک. فصلنامه مهندسی آب. ۱: ۱-۶
- ۴- برادران هزاوه ف، بهزاد م، برومندنسب س. و محسنی موحد ا. ۱۳۸۵. همایش ملی مدیریت شبکه‌های آبیاری و زهکشی، دانشکده شهید چمران اهواز، اردیبهشت ۱۳۸۵، صص ۱۳-۲۷.
- ۵- رشمائلو م، سهرابی ت.م، آبابایی ب. و رضاردی نژاد و. ۱۳۸۹. ارزیابی عملکرد انواع سیستم های آبیاری بارانی (مطالعه موردی اراضی کشاورزی دشت قزوین). سومین همایش ملی مدیریت شبکه‌های آبیاری و زهکشی، اسفند ۱۳۸۹، اهواز.
- ۶- شیخ‌اسماعیلی ا. ۱۳۸۲. بررسی یکنواختی توزیع آب و تلفات تبخیر و باد در سیستم آبیاری بارانی کلاسیک ثابت با آبپاش متحرک AD-5. پایان‌نامه کارشناسی ارشد. دانشکده کشاورزی، دانشگاه چمران، اهواز.
- ۷- کریمی ا، همایی م، لیاقت ع.م. و معزاردلان م. ۱۳۸۴. یکنواختی توزیع آب و کود در سیستم آبیاری قطره‌ای نواری. پژوهش کشاورزی (آب، خاک و گیاه در کشاورزی): ۵(۲): ۵۳-۶۶
- ۸- هزارجریبی ا، دهقانی ا، حسام م. و شریفان ح. ۱۳۹۰. تخمین یکنواختی توزیع آب در آبیاری بارانی با استفاده از روش بهینه‌سازی الگوریتم ژنتیک. پژوهش‌های حفاظت آب و خاک. ۱۸(۴): ۱۲۹-۱۴۴.
- 9-Araghinejad S., Burn D.H., and Karamouz M. 2006. Long-lead probabilistic forecasting of streamflow using ocean-atmospheric and hydrological predictors, *Water Resour. Res.*, 42, W03431, doi:10.1029/2004WR003853.
- 10-Babayan A., Kapelan Z., Savic D., and Walters G. 2005. Least-cost design of water distribution networks under demand uncertainty. *Journal of Water Resources Planning and Management*, 131(5):375-382.
- 11-Beersma J.J., and Buishand T.A. 2003. Multi-site simulation of daily precipitation and temperature conditional on the atmospheric circulation. *Clim Res.* 25. 121-133.
- 12-Chi M. and Bruzzone L. 2005. An ensemble-driven K-NN approach to ill-posed classification problems. *Pattern Recognition Letters* 27, 301-307.
- 13-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.
- 14-Davis G.A. and Nihan N.L. 1991. Nonparametric regression and short-term free way traffic forecasting. *Journal of Transportation Engineering*, ASCE 117(2), 178-188.
- 15-Harrold T.I., Sharma A. and Sheather S.J. 2003. A nonparametric model for stochastic generation of daily rainfall occurrence. *Water Resour Res.* 39. 1-11.
- 16-Heerman D.F. 1983. Design and operation of farm irrigation system. *American Society of Agricultural Engineers*. Pp: 591-598.
- 17-Lansey K.E. and Mays L.W. 1989. Optimization model for water distribution system design. *Journal of Hydraulic Engineering*, 115(10):1401-1418.
- 18-Luong H.T. and Nagarur N.N. 2001. Optimal replacement policy for single pipes in water distribution networks. *Water Resources Research*, 37(12):3285-3293.
- 19-MATLAB. 2008. Neural Network toolbox user's guide. The MathWorks Inc, 3 Apple Hill Drive Natick, MA.
- 20-Nemes A., Rawls W.J. and Pachepsky Y.A. 2006. Use of the nonparametric nearest neighbor approach to estimate soil hydraulic properties. *Soil Science Society of America Journal* 70, 327-336.
- 21-Rajagopalan B. and Lall U. 1999. A k-nearest-neighbor simulator for daily precipitation and other variables. *Water Resources Research* 35 (10), 3089-3101.
- 22-Shamir U. 1974. Optimal design and operation of water distribution systems. *Water Resources Research*, 10(1):27-36, 1974.
- 23-Sharma A. and Lall U. 1999. A nonparametric approach for daily rainfall simulation. *Math Comput Simulat.* 48. 361-371.
- 24-Solomon K. 1979. Variability of sprinkler coefficient of uniformity test results. *Transactions, ASAE*, 22: 1078-1080.
- 25-Todini E. 2000. Real-time flood forecasting: operational experience and recent advances. In: Marsalek, J., et al. (Eds.), *Flood Issues in Contemporary Water Management*. Kluwer Academic Publisher, The Netherlands, pp. 261-270.
- 26-Tolson B.A., Maier H.R., Simpson A.R., and Lence B.J. 2004. Genetic algorithms for reliability-based optimization of water distribution systems. *Journal of Water Resources Planning and Management*, 130(1):63-72.
- 27-Varma K.V.K., Narasimhan S., and Bhallamudi S.M. 1997. Optimal design of water distribution systems using an NLP method. *Journal of Environmental Engineering*, 123(4): 381-388.
- 28-Watanatada T. 1973. Least-cost design of water distribution systems. *Journal of the Hydraulics Division*, 99(9):1497-1513.
- 29-Wilson D.R. and Martinez T.R. 2000. Reduction techniques for exemplar-based learning algorithms. *Machine*

- Learning. 38(3). 257-286.
- 30-Wu W., Xing E.P., Myers C., Mian I.S. and Bissell M.J. 2005. Evaluation of normalization methods for cDNA microarray data by K-NN classification. *Bioinformatics* 6, 191.
- 31-Young K.C. 1994. A multivariate chain model for simulating climatic parameters with daily data. *J. Appl. Meteorol.*, 33(6), 661-671.

Archive of SID



Estimating Hydraulic Performance of Pressurized Irrigation System Using Artificial Neural Networks and Nonparametric Regression

B. Ababaei^{1*}-V. R. Verdinejad²

Received:07-01-2013

Accepted:11-08-2013

Abstract

In this research, replacement of hydraulic models with statistical models and artificial neural networks were studied in order to estimate the criteria of pressurized irrigation systems hydraulic performance. The Coefficient of Uniformity of Christiansen (CU) was accepted as a hydraulic performance index. Using an automated algorithm, the values of this index were calculated for different combinations of inlet pressure, number and spacing of outlets, pipe roughness coefficient, inside diameter, slope, outlets nominal outflow and pressure and the exponent of the formula of outlet outflows (x) (4320 different combinations). Two different architecture of artificial neural networks were studied including a multi-layer perceptron (MLP) model and a generalize regression model (GRNN). Again, K-nearest neighbor (KNN) algorithm, as a nonparametric regression model was analyzed too. The results showed that MLP model could estimate the CU values of pressurized irrigation system laterals very closely (2-3% error) using its hydraulic and physical characteristics. The performance of GRNN model was also acceptable, especially related to the whole data set. But, the KNN algorithm was unable to predict standard deviation of CU values, although it was capable in estimating the mean value. The deviations of the KNN algorithm were the largest among all the models. The lowest values of error indices of the KNN algorithm was related to the K values of 10 and 15. The results of this study revealed the possibility of simplification of sophisticated hydraulic models by replacing the whole or some parts of these models with simpler statistical models and artificial neural networks. This is very interesting because of the complexity of hydraulic models, especially in optimization processes of irrigation systems.

Keywords: Pressurized Irrigating, Hydraulic Performance, Artificial Neural Networks, K-Nearest Neighbors

1- Young Researchers Club and Elites, Science and Research Branch, Islamic Azad University, Tehran, Iran
(*-Corresponding Author Email: behnam.ab@gmail.com)

2- Assistant Professor, Department of Water Engineering, Faculty of Agriculture, Urmia University, Urmia, Iran