

پیش‌بینی بارش ماهانه با استفاده از مدل‌های برنامه‌ریزی بیان ژن و ماشین بردار پشتیبان

دریافت مقاله: ۹۵/۶/۲۱ پذیرش نهایی: ۹۷/۲/۱۸

صفحات: ۹۱-۱۰۳

اباذر سلگی: دانشجوی دکتری هیدرولوژی و منابع آب دانشگاه شهید چمران اهواز، ایران^۱.

A-solgi@phdstu.scu.ac.ir

حیدر زارعی: استادیار و عضو هیئت علمی گروه هیدرولوژی و منابع آب دانشگاه شهید چمران اهواز، ایران.

zareih@scu.ac.ir

مهرنوش شهینی دارابی: کارشناس کنترل کیفیت شرکت آب غدیر اهواز، ایران.

shehnnidarabi.mehrnoush@gmail.com

صابر علیدادی ده کهنه: معاونت آبرسانی سازمان آب و برق خوزستان، ایران.

Alidadis@yahoo.co

چکیده

برآورد و پیش‌بینی بارش و دستیابی به مقدار رواناب ناشی از آن، نقش اساسی و مؤثری را در مدیریت و بهره‌برداری صحیح از حوضه، مدیریت سدها و مخازن، به حداقل رساندن خسارات ناشی از سیلاب، خشکسالی و مدیریت منابع آب ایفا می‌کند. عملکرد خوب مدل‌های هوشمند باعث افزایش استفاده از آنها برای پیش‌بینی پدیده‌های مختلف هیدرولوژیکی شده است. لذا در پژوهش حاضر، دو مدل هوشمند به نام‌های برنامه‌ریزی بیان ژن و ماشین بردار پشتیبان برای پیش‌بینی بارش ماهانه شهرستان نهاوند بکار گرفته شد و داده‌های مورد استفاده بارش، دما و رطوبت نسبی ماهانه ایستگاه وراینه در یک دوره ۳۲ ساله (۱۳۹۳-۱۳۶۲) بود. نتایج به دست آمده نشان داد که عملکرد هر دو مدل خوب و مشابه بوده (ضریب همبستگی حدود ۰/۹۲) ولی با توجه به بررسی معیارهای ارزیابی مختلف، مدل برنامه‌ریزی بیان ژن عملکرد کمی بهتری داشته است (جذر میانگین مربعات خطا به ترتیب ۰/۴۷۸ و ۰/۴۸۶). این در حالی است که مدل ماشین بردار پشتیبان دارای مزیت سهولت در اجرای مدل می‌باشد. به طور کلی می‌توان گفت که مدل برنامه‌ریزی بیان ژن برای مدل‌سازی و پیش‌بینی بارش ماهانه ایستگاه وراینه در شهرستان نهاوند مناسب تر بوده است.

کلید واژگان: پیش‌بینی بارش ماهانه، برنامه‌ریزی بیان ژن، ماشین بردار پشتیبان، شهرستان نهاوند.

۱. نویسنده مسئول: اهواز، میدان دانشگاه، دانشگاه شهید چمران اهواز ۰۹۱۸۹۴۹۵۷۹

مقدمه

پیش‌بینی هر مخاطره، موفقیت مدیریت بحران مربوط به آن را افزایش می‌دهد و این امکان، زمانی حاصل می‌شود که بتوان مدل‌های پیش‌بینی مناسب را در اختیار داشت. روش‌های مختلفی برای پیش‌بینی وقایع هیدرولوژیکی از جمله بارندگی به کار می‌رود. نتایج حاصل از بکارگیری هر یک از این روش‌ها همواره با مقداری خطا همراه می‌باشد. پیش‌بینی درست در سیگنال‌های هیدرولوژیکی نظیر بارندگی می‌تواند اطلاعات مفیدی را به منظور پیش‌بینی مقدار بارندگی و مدیریت منابع آب و خاک در یک حوضه ارائه دهد. علاوه بر این، پیش‌بینی درست در سیگنال‌های هیدرولوژیکی نقش مهمی را در کاهش اثرات خشکسالی بر سیستم‌های منابع آب ایفا می‌کند. سیستم‌های هیدرولوژی از فاکتورهای زیادی نظیر آب و هوا، پوشش گیاهی زمین، میزان نفوذپذیری، تبخیر و تعرق، و غیره که وابسته به اجزای استوکستیک، مقیاس‌های چند زمانه و ویژگی‌های غیرخطی بالا هستند، تأثیر می‌پذیرند. با وجود روابط غیرخطی، عدم قطعیت و عدم صراحت زیاد، ویژگی‌های متغیر زمانی و مکانی در سیستم گردش آبی، هیچ یک از مدل‌های آماری و مفهومی پیشنهاد شده به منظور الگوسازی دقیق بارش و رواناب نتوانسته‌اند به عنوان یک مدل برتر شناخته شوند. امروزه سیستم‌های هوشمند در پیش‌بینی یک چنین پدیده‌های پیچیده بسیار مورد استفاده قرار می‌گیرند. در سال‌های اخیر مدل‌های متعددی به منظور شبیه‌سازی فرآیندهای پیچیده هیدرولوژیکی توسعه پیدا کرده است. مدل‌های هوشمند همچون شبکه عصبی مصنوعی^۱ (ANN) و سیستم استنتاج فازی عصبی تطبیقی^۲ (ANFIS) توانایی نسبتاً خوبی در مدل‌سازی و پیش‌بینی سری‌های زمانی هیدرولوژیکی غیر خطی نشان داده‌اند (نورانی و کماسی، ۲۰۱۳: ۴۱). از جمله این مطالعات می‌توان به موارد زیر اشاره کرد:

سلگی و همکاران (۲۰۱۴: ۲۵۷) عملکرد دو مدل هوش مصنوعی، شبکه عصبی مصنوعی و سیستم استنتاج فازی عصبی تطبیقی را برای پیش‌بینی بارش مورد ارزیابی قرار دادند. نتایج آنها نشان داد که عملکرد دو مدل تقریباً مشابه بوده و مدل سیستم استنتاج فازی عصبی تطبیقی در برآورد نقاط حدی برتری نسبی دارد. خلیلی و همکاران (۱۳۸۷) پیش‌بینی بارش ایستگاه سینوپتیک مشهد را با استفاده از شبکه‌های عصبی پرسپترون چند لایه با دقت قابل قبولی نشان دادند. قلی‌زاده و دارند (۱۳۸۹) از شبکه عصبی مصنوعی برای پیش‌بینی بارش ماهانه تهران استفاده کردند. فلاح‌قاله‌ری و همکاران (۱۳۸۸). کاربرد دو مدل سیستم استنتاج فازی عصبی تطبیقی و شبکه عصبی مصنوعی را برای پیش‌بینی بارش در منطقه خراسان مورد مقایسه قرار دادند. نتایج آنها نشان داد که مدل شبکه عصبی مصنوعی موفق‌تر بوده است.

در سال‌های اخیر، با توجه به توانایی بالای مدل‌های ماشین بردار پشتیبان^۳ (SVM) و برنامه‌ریزی بیان ژن^۴ (GEP)، از این ابزارها نیز برای پیش‌بینی پدیده‌های مختلف هیدرولوژیکی استفاده شده است. که در ادامه به برخی از این مطالعات اشاره می‌شود.

1 -Artificial Neural Network(ANN)

2 -Adaptive Neuro Fuzzy Inference System(ANFIS)

3 -Support Vector Machine

4 -Gene Expression Programming

تریپاتی^۱ و همکاران (۲۰۰۶: ۶۲۱) از تکنیک ماشین بردار پشتیبان برای برآورد آماری بارندگی ماهانه در هند استفاده کردند. نتایج آنها نشان داد که مدل ماشین بردار پشتیبان به عنوان گزینه مناسب‌تر نسبت به سایر روش‌های معمول برای پیش‌بینی بارش به روش آماری قابل استفاده می‌باشد. کاشید و مایتی^۲ (۲۰۱۲: ۲۶) از روش برنامه‌ریزی بیان‌ژن برای پیش‌بینی بارش ماهانه در منطقه موسمی هند استفاده کردند.

پیش‌بینی و شبیه‌سازی سطح آب زیرزمینی بوسیله برنامه‌ریزی ژنتیک^۳ (GP) برای ۳ چاه مشاهده‌ای در کرج ایران صورت گرفت و با مدل ANFIS مورد مقایسه قرار گرفت. نتایج حاصل نشان داد که پیش‌بینی و شبیه سازی توسط روش GP یک ابزار مؤثر در تعیین سطح آب زیرزمینی است. (Fallah-Mehdipour et al. 2532013).

پیش‌بینی نوسانات سطح آب زیرزمینی با اثرات هواشناسی با مطالعه تکنیک‌های مختلف ANN، ANFIS، SVM و GEP انجام شد. چندین ترکیب مختلف با داده‌های سطح آب زیرزمینی، بارش و تبخیر ایستگاه چاه Hongcheon در کره جنوبی در یک دوره ۸ ساله (۲۰۰۱-۲۰۰۸) استفاده شد. براساس نتایج مشخص شد که مدل GEP عملکرد بهتری نسبت به روش‌های دیگر داشت (Shiri et al. 2013: 32).

احمدی و همکاران (۱۳۹۳) مقایسه عملکرد دو مدل برنامه‌ریزی ژنتیک و ماشین بردار پشتیبان را برای پیش‌بینی جریان روزانه رودخانه باراندوز چای مورد بررسی قرار دادند و اعلام نمودند که مدل برنامه‌ریزی بیان ژن عملکرد تقریباً بهتری داشته است.

با توجه به مطالعات صورت گرفته مشخص می‌شود که مطالعات کمی در زمینه استفاده از مدل‌های برنامه‌ریزی بیان ژن و ماشین بردار پشتیبان برای پیش‌بینی بارش صورت گرفته است. همچنین کاربرد موفق مدل‌های برنامه‌ریزی بیان ژن و ماشین بردار پشتیبان در بررسی پدیده‌های غیرخطی باعث شد در این تحقیق به بررسی بارش شهرستان نهاوند با استفاده از این مدل‌ها پرداخته شود با توجه به کاهش بارش‌های شهرستان نهاوند در چند سال گذشته و توجه به نقش بارش و تأثیر آن بر محیط زیست شهرستان موجب شد این بررسی صورت گیرد. همچنین در این تحقیق علاوه بر پارامتر بارش از پارامترهای دما و رطوبت نسبی نیز استفاده شده است تا اثر آنها بر پیش‌بینی بارش مورد بررسی قرار گیرد.

روش تحقیق


منطقه مورد مطالعه

ایستگاه وراینه شامل ۳ ایستگاه باران‌سنجی، تبخیرسنجی و هیدرومتری به نام وراینه می‌باشد. که در شهرستان نهاوند در موقعیت جغرافیایی ۴۸ درجه و ۲۴ دقیقه و ۱۵ ثانیه طول شرقی و ۳۴ درجه و ۰۴ دقیقه و ۳۲ ثانیه عرض شمالی قرار دارند شکل (۱). این ایستگاه در سال ۱۳۴۸ تأسیس شده است و دارای ارتفاع ۱۷۹۵ متر از سطح دریا با میانگین بارش سالانه دراز مدت ۵۲۱ میلیمتر می‌باشد.

1 - Tripathi

2- Kashid and Maity

3- Genetic Programming



شکل (۱): موقعیت ایستگاه وراینه در شهرستان نهاوند، استان همدان و ایران.

آماده سازی اطلاعات

در این بررسی داده‌های بارش، دما و رطوبت نسبی در یک دوره ۳۲ ساله (۱۳۵۹-۱۳۹۰) از ایستگاه وراینه در شهرستان نهاوند دریافت شد جدول (۱). برای بررسی همگنی داده‌ها از ایستگاه وسج به عنوان ایستگاه کمکی استفاده شد. ۷۵ درصد از داده‌ها به عنوان داده‌های آموزش، ۲۵ درصد به عنوان داده‌های تست در نظر گرفته شد. با توجه به اینکه وارد کردن اطلاعات به صورت خام باعث کاهش سرعت و دقت مدل می‌شود لذا از روش استانداردسازی (نرمال‌سازی) داده‌ها استفاده شد. با این روش هر داده تبدیل به عددی بین صفر تا یک می‌شود. جهت انجام این کار با توجه به پیشنهاد سلگی و همکاران (۲۰۱۴) از رابطه (۱) برای استانداردسازی داده‌ها استفاده شد.

$$y = 0.5 + \left(0.5 \times \frac{x - \bar{x}}{x_{max} - x_{min}} \right) \quad \text{رابطه (۱)}$$

در این رابطه، X داده مورد نظر، $\bar{x}$ میانگین داده‌ها، $X_{\max}$ حداکثر داده‌ها، $X_{\min}$ حداقل داده‌ها و y داده استاندارد شده می‌باشد.

جدول (۱): پارامترهای ماهانه ایستگاه وراینه

ضریب تغییرات	انحراف معیار	حداقل	حداکثر	میانگین	واحد اندازه گیری	پارامترهای استفاده شده
۱/۱	۴۸/۳	۰/۰	۲۵۱	۴۴	میلیمتر (mm)	بارش
۰/۹	۹/۰	-۹	۲۶	۱۰	درجه سلسیوس (°C)	دما
۰/۲	۱۱/۱	۲۰	۸۷	۶۸	میلیمتر (mm)	رطوبت نسبی

ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان در سال ۱۹۹۲ توسط یک ریاضیدان روس به نام وپنیک^۱ بر پایه نظریه یادگیری آماری^۲ بنا گردیده است (Cortes and Vapnik 1995). ماشین بردار پشتیبان دسته‌بندی کننده‌ای است که جزء شاخه روش‌های کرنلی^۳ در یادگیری ماشین محسوب می‌شود. این نوع سیستم یادگیری هم برای دسته‌بندی و هم برای تخمین و برآورد تابع برازش داده‌ها به کار می‌رود، به طوری که کمترین خطا در دسته‌بندی داده‌ها و یا تابع برازش رخ دهد. در سال‌های اخیر استفاده از ماشین‌های بردار پشتیبان، بسیار مورد توجه قرار گرفته است. استفاده از ماشین بردار پشتیبان در کاربردهایی مانند تشخیص دست نوشته‌ها، تشخیص چهره و ... نتایج خوبی داشته است.

ماشین بردار پشتیبان غیرخطی

در این حالت از توابع کرنل استفاده می‌شود. به عنوان مثال تابع کرنل می‌تواند از رابطه (۲) بدست آید.

$$k(x, y) = (x \cdot y + 1)^d \quad d=2, 3, \dots \quad \text{رابطه (۲)}$$

$$k(x, y) = \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right)$$

$$k(x, y) = \tanh(x \cdot y + \theta)$$

$$k(x, y) = (x \cdot y)$$

این کرنل‌ها به ترتیب کرنل چندجمله‌ای^۴، کرنل گاوسی یا RBF، کرنل تانژانت هیپربولیک یا سیگموئید^۵ و کرنل خطی^۶ (Sujay Raghavendra and Paresh Chandra 2014). جهت کسب اطلاعات بیشتر در

1-Vapnik

2-Statistical Learning

3- kernel methods

4- Polynomial

5- Sigmoidal

6-Linear

این زمینه به منابع (Sujay Raghavendra and Paresh Chandra Cortes and Vapnik 1995, 2014) مراجعه شود.

برنامه‌ریزی بیان ژن (GEP)

روش برنامه‌ریزی بیان ژن (GEP) که شکل توسعه یافته برنامه‌ریزی ژنتیک می‌باشد توسط فریرا (۱۹۹۹) ارائه شد (Ferreira 2001). این روش جزء روش‌های الگوریتم گردشی محسوب می‌شود. این روش در ادامه سیر تکاملی مدل‌های هوشمند به وجود آمده است و مبنای آن براساس نظریه تکامل داروین استوار است (داننده مهر و مجدزاده، ۱۳۸۹). در این روش 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 راه حل‌هاست. 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 دستیابی به راه حل مطلوب و یا رسیدن نسل‌ها به تعداد معین، تکامل متوقف شده و بهترین راه حل ارائه می‌شود. اگر شرایط توقف یافت نشود، نخبه‌گزینی انجام می‌شود و باقی راه حل‌ها به فرآیندی گزینشی واگذار می‌شوند. این فرآیند برای چندین نسل تکرار می‌شود و با پیش رفتن نسل به جلو کیفیت جمعیت نیز به طور نسبی بهبود می‌یابد (Ferreira 2006). در برنامه‌ریزی بیان ژن از عملگرهای مختلفی مانند جهش و ترکیب استفاده می‌شود. 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 تک نقطه‌ای، دو نقطه‌ای و ژنی استفاده می‌شود. از آنجایی که 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 ترانهش را نام برد. در این روش پدیده‌های مختلف با استفاده از مجموعه‌ای از توابع و ترمینال‌ها، مدلسازی می‌شوند. مجموعه توابع، معمولاً شامل توابع 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 (Ferreira 2001).

جهت کسب اطلاعات بیشتر در این زمینه به منبع (Ferreira 2001, Beriro, Shiri and Kişi 2011, Shoaib, Shamseldin et al. 2015) مراجعه شود.

در این مطالعه برای اجرای مدل برنامه‌ریزی بیان ژن از برنامه GeneXpro Tools (v5) استفاده شده است که در آن انتخاب جمعیت‌های اولیه که همان الگوهای ورودی می‌باشد از اهمیت بالایی برخوردار است. با توجه به اینکه در این مطالعه علاوه بر پارامترهای مختلف ورودی (بارش، دما و رطوبت نسبی) توالی این پارامترها نیز در پیش‌بینی بارش مدنظر بوده است از ترکیب‌های مختلف مطابق جدول (۲) برای مدل برنامه‌ریزی بیان ژن و ماشین بردار پشتیبان استفاده شد.

جدول (۲): ترکیب‌های مختلف مدل SVM و GEP

ترکیب	ورودی	خروجی
۱	P(t-1), P(t)	P(t+1)
۲	P(t-2), P(t-1), P(t)	P(t+1)
۳	T(t-1), T(t), N(t-1), N(t)	P(t+1)
۴	T(t-2), T(t-1), T(t), N(t-2), N(t-1), N(t)	P(t+1)
۵	N(t-1), N(t), P(t-1), P(t)	P(t+1)
۶	N(t-2), N(t-1), N(t), P(t-2), P(t-1), P(t)	P(t+1)
۷	P(t-1), P(t), T(t-1), T(t)	P(t+1)
۸	P(t-2), P(t-1), P(t), T(t-2), T(t-1), T(t)	P(t+1)
۹	N(t), P(t), T(t)	P(t+1)
۱۰	T(t-1), T(t), N(t-1), N(t), P(t-1), P(t)	P(t+1)
۱۱	T(t-2), T(t-1), T(t), N(t-2), N(t-1), N(t), P(t-2), P(t-1), P(t)	P(t+1)

در جدول (۲)، $T(t)$ ، $P(t)$ ، $N(t)$ به ترتیب رطوبت‌نسبی، بارش و دمای ماهانه $N(t-1)$ ، $P(t-1)$ ، $T(t-1)$ به ترتیب رطوبت‌نسبی، بارش و دمای ماهانه با یک تأخیر زمانی، $N(t-1)$ ، $P(t-1)$ ، $T(t-1)$ به ترتیب رطوبت‌نسبی، بارش و دمای ماهانه با دو تأخیر زمانی و $P(t+1)$ بارش ماه آتی می‌باشد.

معیارهای ارزیابی مدل

منظور از ارزیابی مدل به دست آوردن میزان خطای مدل با توجه به داده‌های ورودی داده شده به مدل جهت آموزش و براساس معیارهای مختلف محاسبه خطا می‌باشد. در این پژوهش برای ارزیابی مدل از روابط (۳) و (۴) استفاده شد:

$$RMSE = \sqrt{\frac{\sum (P_{obs} - P_{pre})^2}{n}} \quad \text{رابطه (۳)}$$

$$R = \sqrt{1 - \frac{\sum_{i=1}^N (P_{obs} - P_{pre})^2}{\sum_{i=1}^N (P_{pre} - \bar{P})^2}} \quad \text{رابطه (۴)}$$

$$AIC = m \times \ln(RMSE) + 2(N_{par}) \quad \text{رابطه (۵)}$$

RMSE جذر میانگین مربعات خطاست، R ضریب همبستگی می‌باشد شاخص دیگری که در این تحقیق استفاده شده است شاخص آکائیک است که براساس این شاخص هر مدلی که شاخص آکائیک کمتری داشته باشد مناسب است. در این شاخص‌ها P_{obs} بارش مشاهده‌ای، P_{pre} بارش محاسباتی و $\bar{P}$ میانگین بارش مشاهده‌ای است. در رابطه (۵)، m تعداد داده‌های ورودی، N_{par} تعداد پارامترهای آموزش دیده می‌باشد.


نتایج

برای اجرای مدل ماشین بردار پشتیبان، ساختارهای مختلف مورد ارزیابی قرار گرفت. جهت انجام این کار، کرنل‌های مختلف و دیگر پارامترهای مدل مورد بررسی قرار گرفتند. نتایج بهترین ساختار در مدل ماشین بردار پشتیبان در جدول (۳) ارائه شده است. براساس این جدول مشاهده می‌شود که ترکیب ۱۰ که در آن از پارامترهای بارش، دما و رطوبت نسبی ماهانه با یک زمان تأخیر استفاده شده است نتیجه بهتری ارائه گردید. این در حالی است که وقتی تعداد تأخیرها افزایش پیدا کرد عملکرد مدل کاهش یافت. در این ترکیب برتر، ساختاری که کرنل آن RBF بوده و دارای ضریب همبستگی $0/92$ و جذرمیانگین مربعات خطای $0/0486$ بوده است بهترین نتیجه را داشته است. همان‌طوری که در جدول (۳) مشاهده می‌شود از بین پارامترهای استفاده شده، بارش بیشترین تأثیر را داشته است. همچنین با بررسی ترکیب‌های مختلف مشاهده می‌شود که کرنل RBF عملکرد بهتری نسبت به دیگر کرنل‌ها در مدل ماشین بردار پشتیبان داشته است.

جدول (۳): بهترین ساختار مدل ماشین بردار پشتیبان

ترکیب	پارامترهای مدل				ضریب همبستگی		جذر میانگین مربعات خطا	
	Kernel	Gama	Sin2	B	P-Degree	آموزش	تست	آموزش
۱	RBF	$0/860$	$2/439$	$0/299$	-----	$0/85$	$0/74$	$0/0498$
۲	Poly	$1/402$	$0/004$	$0/508$	۳	$0/89$	$0/80$	$0/0693$
۳	Poly	$0/001$	5238	$0/0202$	۳	$0/71$	$0/60$	$0/0879$
۴	RBF	$0/497$	$3/937$	$0/0242$	-----	$0/68$	$0/51$	$0/0947$
۵	RBF	$8/827$	$33/87$	$-2/660$	-----	$0/73$	$0/68$	$0/0809$
۶	RBF	$0/966$	$10/44$	$-0/475$	-----	$0/72$	$0/62$	$0/0864$
۷	RBF	$2/222$	$0/301$	$-0/079$	-----	$0/91$	$0/85$	$0/0595$
۸	Poly	$0/002$	265	$0/169$	۳	$0/92$	$0/83$	$0/0630$
۹	RBF	$1/004$	$3/801$	$1/347$	-----	$0/92$	$0/87$	$0/0562$
۱۰	RBF	$0/491$	$2/486$	$0/0611$	-----	$0/95$	$0/92$	$0/0486$
۱۱	Lin	$1/996$	-----	$-0/253$	-----	$0/95$	$0/86$	$0/0563$

نتیجه حاصل از ساختار برتر ترکیب ۱۰ در شکل (۲) ارائه شده است. همان‌طوری که در این شکل مشاهده می‌شود عملکرد مدل مناسب بوده است ولی مدل در برآورد مقادیر حداکثری بارش عملکرد بهتری در مقایسه با برآورد مقادیر حداقلی بارش داشته است.




شکل (۲): مقادیر بارش مشاهده‌ای در برابر مقادیر برآوردی مدل SVM.

نتایج حاصل از برآورد مقادیر بارش با استفاده از مدل برنامه‌ریزی بیان ژن در جدول (۴) ارائه شده است. در این مدل نیز ساختارهای متفاوت به ازای پارامترهای مختلف مدل مورد ارزیابی قرار گرفت. همان‌طوری که در جدول (۴) مشاهده می‌شود ترکیب ۱۰ دارای بهترین عملکرد بوده است. در این ترکیب برتر ضریب همبستگی ۰/۹۲ و جذرمیانگین مربعات خطا ۰/۰۴۷۸ بدست آمد. نتیجه حاصل از این ترکیب برتر در شکل ۳ ارائه شده است. براساس شکل (۳) مشاهده می‌شود که عملکرد مدل مناسب بوده و مقادیر برآوردی به مقادیر مشاهداتی نزدیک می‌باشد. همان‌طوری که مشاهده می‌شود عملکرد مدل در برآورد مقادیر حداکثری نسبت به مقادیر حداقلی بهتر بوده است. چون مقادیر حداکثری برآورد شده توسط مدل به مقادیر مشاهداتی نزدیک‌تر می‌باشد.


جدول (۴): بهترین ساختار در ترکیب‌های مدل برنامه‌ریزی بیان ژن.

ترکیب	ضریب همبستگی (R)		جذر میانگین مربعات خطا (RMSE)	
	آموزش	تست	آموزش	تست
۱	۰/۸۶	۰/۷۷	۰/۰۴۹۲	۰/۰۷۱۴
۲	۰/۸۸	۰/۸۳	۰/۰۴۷۵	۰/۰۶۴۳
۳	۰/۸۱	۰/۶۵	۰/۰۵۴۷	۰/۰۸۴۰
۴	۰/۸۶	۰/۵۸	۰/۰۴۸۳	۰/۰۹۲۳
۵	۰/۸۱	۰/۷۲	۰/۰۵۴۷	۰/۰۷۶۹
۶	۰/۷۵	۰/۶۷	۰/۰۶۱۱	۰/۰۸۲۵
۷	۰/۸۹	۰/۸۴	۰/۰۴۵۸	۰/۰۶۲۱
۸	۰/۹۲	۰/۸۲	۰/۰۴۰۴	۰/۰۶۴۸
۹	۰/۹۳	۰/۸۶	۰/۰۳۷۷	۰/۰۵۸۳
۱۰	۰/۹۶	۰/۹۲	۰/۰۲۶۳	۰/۰۴۷۸
۱۱	۰/۹۵	۰/۸۹	۰/۰۳۱۲	۰/۰۵۲۲



شکل (۳): مقادیر بارش مشاهده‌ای در برابر مقادیر برآوردی مدل GEP

شکل (۴) ساختار درختی مدل برنامه‌ریزی بیان ژن را نشان می‌دهد. ساختار درختی کمک می‌کند که در هر مرحله جمعیت اولیه به صورت ساختار خطی ساده بیان شود و تمام تغییرات تنها بر روی ساختارهای ساده انجام گیرد، در نتیجه نیازی به ساختارهای نسبتاً پیچیده برای گسترش در هر مرحله نیست. در شکل (۴) مقادیر C مربوط به ضرایب برنامه‌ریزی بیان ژن و مقادیر d مربوط به پارامتر ورودی می‌باشد که با تأخیرهای مختلف ارائه شده است.



شکل (۴): نمایش ساختار درختی.

در پایان بهترین ساختار از مدل برنامه‌ریزی بیان ژن با بهترین ساختار از مدل ماشین بردار پشتیبان مورد مقایسه قرار گرفت که نتایج آن در جدول (۵) ارائه شده است. از آنجا که هر چه شاخص ضریب همبستگی بیشتر باشد آن مدل بهتر می‌باشد، براساس این شاخص عملکرد هر دو مدل یکسان است چون مقادیر تا دو رقم اعشار ارائه شده است در حالی که با توجه به شکل‌های (۲) و (۳) که مقادیر ضریب تعیین روی شکل (۴) دیده می‌شود که عملکرد مدل برنامه‌ریزی بیان ژن کمی بهتر بوده است. از آنجا که هر چه شاخص‌های آکائیک و جذر میانگین مربعات خطا کمتر باشند مدل مناسب‌تر است این نتیجه حاصل می‌شود که عملکرد هر دو مدل قابل قبول بوده ولی چون شاخص آکائیک و جذر میانگین مربعات خطای مدل برنامه‌ریزی بیان ژن کمی کمتر بوده است به عنوان مدل برتر مشخص شده است. به طور کلی با توجه به نتایج جدول (۵) این نتیجه حاصل می‌شود که عملکرد هر دو مدل مشابه و قابل قبول بوده است ولی مدل برنامه‌ریزی بیان ژن با توجه به معیارهای ارزیابی عملکرد کمی بهتری داشته است. این نکته را باید خاطر نشان نمود که علی‌رغم عملکرد کمی بهتر مدل برنامه‌ریزی بیان ژن، اجرای مدل ماشین بردار پشتیبان با سهولت بهتری صورت می‌گیرد. نتایج این تحقیق با نتایج شیری و همکاران (۲۰۱۳) که اعلام نمودند عملکرد مدل برنامه‌ریزی بیان ژن نسبت به مدل ماشین بردار پشتیبان برای پیش‌بینی سطح آب زیرزمینی بهتر می‌باشد، مبنی بر عملکرد بهتر مدل برنامه‌ریزی بیان ژن نسبت به مدل ماشین بردار پشتیبان منطبق می‌باشد.

جدول (۵): مقایسه مدل‌های استفاده شده در این تحقیق

مدل	ضریب همبستگی		جذر میانگین مربعات خطا		معیار آکائیک	
	(R)		(RMSE)		(AIC)	
	آموزش	تست	آموزش	تست	آموزش	تست
SVM	۰/۹۵	۰/۹۲	۰/۰۳۱۶	۰/۰۴۸۶	۵۶۱/۶۴	۱۸۰/۹۳
GEP	۰/۹۶	۰/۹۲	۰/۰۲۶۳	۰/۰۴۷۸	۵۶۱/۰۹	۱۸۰/۸۸

نتیجه‌گیری

در این تحقیق از دو مدل برنامه‌ریزی بیان ژن و ماشین بردار پشتیبان برای مدل‌سازی بارش ایستگاه وراینه در شهرستان نهاوند استفاده شد. بررسی ساختارهای مختلف نشان داد که در ترکیبی که پارامترهای بارش، دما و رطوبت نسبی ماهانه به همراه این پارامترها با یک گام زمانی تأخیر استفاده شد عملکرد بهتری نسبت به دیگر ترکیب‌ها، حاصل شد. همچنین با مقایسه نتایج حاصل از دو مدل، مشاهده شد که عملکرد هر دو مدل مشابه و خوب بوده است ولی مدل برنامه‌ریزی بیان ژن دارای عملکرد نسبتاً بهتری بوده است. پس به طور کلی می‌توان گفت که مدل برنامه‌ریزی بیان ژن مدل مناسبی برای مدل‌سازی و پیش‌بینی بارش ماهانه در ایستگاه وراینه در شهرستان نهاوند می‌باشد. در این تحقیق از داده‌های رطوبت نسبی و دما نیز علاوه بر بارش استفاده شد که در ساختارهای برتر هر دو مدل مشاهده شد که پارامترهای رطوبت نسبی و دما باعث بهتر شدن نتایج مدل‌سازی شده است پس پیشنهاد می‌شود در مطالعات پیش‌بینی و مدل‌سازی بارش علاوه بر پارامتر بارش از دو پارامتر

دما و رطوبت نسبی نیز استفاده گردد. همچنین پیشنهاد می شود این تحقیق با بررسی عملکرد مدل ترکیبی آنها با تبدیل موجک نیز صورت پذیرد.

منابع

- احمدی، فرشاد، رادمنش، فریدون، میرعباسی نجف آبادی، رسول (۱۳۹۳). مقایسه روشهای برنامه ریزی ژنتیک و ماشین بردار پشتیبان در پیش بینی جریان روزانه رودخانه (مطالعه موردی: رودخانه باراندوز چای). نشریه آب و خاک (علوم و صنایع کشاورزی). ۶(۲۸): ۱۱۷۱-۱۱۶۲.
- خلیلی، نجمه، خداشناس، سیدرضا، داوری، کامران، موسوی بایگی، سیدمحمد (۱۳۷۸). پیش بینی بارش ماهانه با استفاده از شبکه های عصبی مصنوعی (مطالعه موردی: ایستگاه سینوپتیک مشهد). نشریه آب و خاک (علوم و صنایع کشاورزی). ۲۲(۱): ۸۹-۹۹.
- داننده مهر، علی، مجدزاده، محمدرضا. (۱۳۸۹). بررسی تأثیرتوالی دبی روزانه در پیش بینی جریان رودخانه ها با استفاده از برنامه ریزی ژنتیک. نشریه آب و خاک (علوم و صنایع کشاورزی). ۲۴(۲): ۳۲۵-۳۳۳.
- فالح قاله‌ری، غلامحسین، موسوی بایگی، سید محمد، حبیبی نوخندان، مجید. (۱۳۸۸). مقایسه نتایج به دست آمده از کاربرد سیستم استنتاج فازی ممدانی و شبکه های عصبی مصنوعی در پیش بینی بارش فصلی (مطالعه موردیک منطقه خراسان). مجله تحقیقات منابع آب ایران. ۵(۲): ۴۰-۵۲.
- قلی زاده، محمدحسین، دارند، محمد. (۱۳۸۹). پیش بینی بارش ماهانه با استفاده از شبکه های عصبی مصنوعی (مورد: تهران). پژوهش های جغرافیای طبیعی. ۷۱(۴۲): ۵۱-۶۳.
- Beriro, D.J., Abrahart, R.J., Paul Nathanail, C. (2013). "Comparison of genetic program-ming with neuro-fuzzy systems for predicting short-term water table depth fluctuations" by Jalal Shiri & Ozgur Kisi [Computers and Geosciences (2011) 1692-1701]. Computers & Geosciences 56: 216-220.
- Cortes, C., Vapnik. V. (1995). Support-Vector Networks. Machine Learning 20: 273-295.
- Fallah-Mehdipour, E., Bozorg Haddad, O., Mariño, M.A. (2013). Prediction and simula-tion of monthly groundwater levels by genetic programming. Journal of Hydro-environment Research 7(4): 253-260.
- Ferreira, C. (2001). Gene expression program-ming a new adaptive algorithm for solving problems. Complex Systems 13(2): 87-129.
- Ferreira, C. (2006). Gene expression program-ming: mathematical modeling by an artificial intelligence Springer-Verlag. Germany.
- Kashid, S.S., Maity, R. (2012). Prediction of monthly rainfall on homogeneous monsoon regions of India based on large scale circulation patterns using Genetic Programming. Journal of Hydrology 454-455: 26-41.
- Nourani, V., Komasi, M. (2013). A geomo-rphology-based ANFIS model for multi-station modeling of rainfall-runoff process. Journal of Hydrology 490: 41-55.

- Shiri, J., Kişi, Ö. (2011). **Comparison of genetic programming with neuro-fuzzy systems for predicting short-term water table depth fluctuations.** Computers & Geosciences 37(10): 1692-1701.
- Shiri, J., Kisi, O., Yoon, H., Lee, K.K., Hossein Nazemi, A. (2013). **Predicting groundwater level fluctuations with meteorological effect implications—A comparative study among soft computing techniques.** Computers & Geosciences 56(0): 32-44.
- Shoaib, M., Shamseldin, A.Y., Melville, B.W Khan, M.M. (2015). **Runoff Forecasting using HybridWavelet Gene Expression Programming(WGEP) Approach.** Journal of Hydrology 527 326-344.
- Solgi, A., Nourani V., Pourhaghi, A. (2014). **Forecasting Daily Precipitation Using Hybrid Model of Wavelet-Artificial Neural Network and Comparison with Adaptive Neuro Fuzzy Inference System (Case Study: Verayneh Station, Nahavand).** Advances in Civil Engineering 2014: 1-12.
- Solgi, A., Radmanesh, F., Pourhaghi, A., Bagherian Marzouni, M. (2014). **Evaluation of Artificial Intelligence Systems Performance in Precipitation Forecasting.** TI Journals Agriculture Science Developments 3(7): 256-264.
- Sujay Raghavendra, N., Paresh Chandra, D. (2014). **Support vector machine applications in the field of hydrology: A review.** Applied Soft Computing 19: 372-386.
- Tripathi, S., Srinivas, V.V., Nanjundiah, R. S. (2006). **Downscaling of precipitation for climate change scenarios: A support vector machine approach.** Journal of Hydrology 330(3-4): 621-640.