

پیش بینی بارش ماهانه با استفاده از مدل‌های برنامه‌ریزی ژنتیک و ماشین بردار پشتیبان

میلاد شرفی^{۱*}، سعید صمدیان فرد^۲، سجاد هاشمی^۳

۱. دانشجوی کارشناسی، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز

۲. استادیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز

۳. دانشجوی کارشناسی ارشد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز

تاریخ دریافت: ۹۹/۱۱

تاریخ پذیرش: ۹۹/۱۲

نوع مقاله: پژوهشی

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 و خشکسالی و مدیریت منابع آب ایفا می‌کند. عملکرد مطلوب مدل‌های هوشمند باعث افزایش استفاده از آن‌ها برای پیش‌بینی پدیده‌های مختلف هیدرولوژیکی شده است. لذا در این پژوهش، دو مدل هوشمند برنامه‌ریزی ژنتیک و ماشین بردار پشتیبان برای پیش‌بینی بارش ماهانه استان اردبیل به کار گرفته شده و از داده‌های بارش، دما و رطوبت نسبی در مقیاس ماهانه به‌عنوان پارامترهای ورودی مدل‌ها استفاده شد. نتایج به دست آمده نشان داد که عملکرد هر دو مدل خوب و تقریباً یکسان بوده (میانگین خطای مطلق به ترتیب ۰٫۸ و ۰٫۷۲۱) ولی با توجه به ارزیابی‌های انجام شده مدل رگرسیون بردار پشتیبان عملکرد نسبتاً بهتری داشته است (ضریب همبستگی ۰٫۹۹۹). به طور کلی می‌توان گفت که مدل رگرسیون بردار پشتیبان برای مدل‌سازی و پیش‌بینی بارش ماهانه استان اردبیل مناسب تر بوده است.

واژه‌های کلیدی: بارش ماهانه، برنامه‌ریزی ژنتیک، تابع برازش، ضریب همبستگی، ماشین بردار پشتیبان.

مقدمه

محاسبه مقدار متوسط بارندگی در هر حوضه و برآورد میزان بارش در مناطق فاقد آمار، نقش تعیین کننده‌ای بر محاسبات بیلان آب و دقت محاسبات مدل‌های مختلف هیدرولوژیکی دارد. تأثیر مستقیم بارش در زندگی انسان‌ها و نقش آن در توسعه کشورها، سبب گسترش روش‌ها و الگوریتم‌های برآورد بارش در میان متخصصان گردیده است. در اغلب مطالعات هیدرواقليمی آگاهی از مقدار بارندگی یک منطقه نسبتاً وسیع که میزان بارندگی مناطق مختلف آن به وسیله چند ایستگاه باران سنجی اندازه‌گیری شده است، ضروری می‌باشد (Kumari et al., 2016). و همچنین بارش‌های صورت گرفته در آن از نظر توزیع مکانی و زمانی بسیار نامناسب بوده تا جایی که در بعضی مناطق، کل بارش یک سال فقط در عرض چند ساعت اتفاق می‌افتد. بنابراین مدیریت صحیح منابع آب در ایران امری ضروری به نظر می‌رسد. پیش‌بینی این پدیده برای اهداف مختلفی از قبیل تخمین سیلاب، خشکسالی، آبخیزداری، گردشگری، کشاورزی و برنامه‌ریزی آبی اهمیت زیادی دارد پیش‌بینی مدل‌ها باعث می‌شود اطلاعات مشاهدات در زمان اولیه بهتر جذب شوند و وابستگی مدل‌ها را با فرآیندهای پارامتر نشده غیر دقیق، کاهش دهد و در این راه خطاهای سیستماتیک را کاهش می‌دهد (Palmer, 2020).

همانطور که اشاره شد، پیش‌بینی وقوع بارش به ویژه در مقیاس روزانه، با استفاده از داده‌های هواشناسی روز یا روزهای قبل، کمک شایانی به مدیریت سیل، برنامه‌ریزی انواع فعالیت‌های کشاورزی، گردشگری و هواشناسی می‌کند. روش‌های هوش مصنوعی، جزو سیستم‌های دینامیکی بوده و با تجزیه و تحلیل داده‌های ورودی و نتایج نظیر آن‌ها و بدون در نظر گرفتن فرآیند فیزیکی حاکم بر سیستم، قادر به ایجاد رابطه بین متغیر وابسته و مستقل هستند. Ghani و همکاران (۲۰۱۴)، با استفاده از الگوریتم بیان ژن به تخمین داده‌های بازسازی شده بارش پرداختند و توانایی بالای این مدل را اعلام کردند.

^۱ نویسنده مسئول: میلاد شرفی Miladsharafi1@gmail.com

علیائی و همکاران (۱۳۹۸)، دو روش شبکه‌های عصبی مصنوعی و الگوریتم ژنتیک را در مدلسازی سرعت نفوذ آب به خاک در تحقیقات مختلف به کار گرفتند و در روش تلفیقی، الگوریتم ژنتیک با افزایش بسیار زیاد سرعت همگرایی به سمت مدل دقیق و پایداری شبکه عصبی نتایج بهتری ارائه نمود. بابا علی و دهقانی (۱۳۹۶)، کارایی سه روش برنامه‌ریزی بیان ژن، سیستم استنتاج فازی-عصبی و شبکه عصبی مصنوعی را در برآورد بارش ماهانه برای حوضه کاکا رضا بررسی کردند و اظهار داشتند که مدل برنامه‌ریزی بیان ژن، توانایی بالایی در تخمین بارش ماهانه دارد. Mekanik و همکاران (۲۰۱۳) با بررسی پیش‌بینی بارش فصل بهار در حوضه ویکتوریای استرالیا با استفاده از روش‌های شبکه عصبی و رگرسیون چندگانه، نشان دادند که روش شبکه عصبی مصنوعی، عملکرد بهتری در پیش‌بینی بارش دارد. Chuge و Regulwar (۲۰۱۳) با استفاده از روش شبکه عصبی مصنوعی به تخمین داده‌های بارش پرداخته و بر کاربرد شبکه عصبی مصنوعی در این موضوع تاکید کردند. هدف این پژوهش، مطالعه پیش‌بینی وقوع بارش روزانه به کمک مدل‌های هوشمند ماشین بردار پشتیبان، شبکه عصبی مصنوعی و درخت تصمیم است. در سال‌های اخیر، با توجه به توانایی بالای مدل‌های یادگیری ماشینی برای پیش‌بینی پدیده‌های مختلف هیدرولوژیکی استفاده شده است که در ادامه چند مورد آورده شده است:

Triphati و همکاران (۲۰۰۶)، 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. Moghaddamnia و همکاران (۲۰۰۹)، بین تکنیک‌های شبکه عصبی مصنوعی و فازی-عصبی در برآورد تبخیر از تشت یک ایستگاه هواشناسی منطقه سیستان مقایساتی را انجام دادند. نتایج تحقیقات آن‌ها نشان‌دهنده کارایی خوب روش ANN در برآورد تبخیر از تشت بود. Kisi (۲۰۰۹) عملکرد روش‌های رگرسیون چندمتغیره، ANN و معادله تجربی استفان-استیوارت را برای مدل‌سازی تبخیر ماهانه سه ناحیه ایالات کالیفرنیا مقایسه کرد. نتایج ارزیابی روش‌های مختلف نشان داد که شبکه‌های عصبی RBNN و MLP در مقایسه با روش‌های رگرسیون خطی چند متغیره و معادل تجربی از کارایی و دقت بیشتری برخوردارند. در مطالعه‌ی دیگری، پیش‌بینی و شبیه‌سازی سطح آب زیرزمینی به-وسیله برنامه‌ریزی ژنتیک (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 شبیه‌سازی توسط روش GP بک ابزار مؤثر در تعیین سطح آب زیرزمینی است (Fallah-Mehdipour et al., 2013).


با توجه به مطالعات صورت گرفته مشخص می‌شود که مطالعات کمی در زمینه استفاده از مدل‌های برنامه‌ریزی ژنتیک و ماشین بردار پشتیبان برای پیش‌بینی بارش ماهانه صورت گرفته است. با در نظر گرفتن کاهش بارش‌های استان اردبیل در چند سال گذشته و توجه به نقش بارش و تأثیر آن بر محیط زیست این استان و همچنین کاربرد موفق مدل‌های برنامه‌ریزی ژنتیک و ماشین بردار پشتیبان در بررسی پدیده‌های غیرخطی، این امر باعث شد که در این تحقیق به پیش‌بینی بارش استان اردبیل با استفاده از مدل‌های مذکور پرداخته شود. 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.

مواد و روش‌ها

منطقه مورد مطالعه

استان اردبیل یکی از استان‌های ایران است که در شمال غربی این کشور در منطقه آذربایجان ایران واقع شده است. مساحت این استان ۱۷۹۵۳ کیلومتر مربع (حدوداً ۱،۰۹ درصد از مساحت کل کشور) می‌باشد. این استان از لحاظ جغرافیایی در موقعیت ۳۷/۴۵ تا ۳۹/۴۲ عرض شمالی و ۴۷/۳۰ تا ۴۸/۵۵ طول شرقی قرار گرفته و از شمال با جمهوری آذربایجان، از شرق با استان گیلان، از جنوب با استان زنجان و از غرب به استان آذربایجان شرقی محدود شده است. استان اردبیل در محور طول جغرافیایی با گسترش (۱ درجه و ۳۵ دقیقه)، همراه با عامل ارتفاع دشت‌ها و کوهستان‌های آن در ترکیبی هماهنگ با همجواری دریای خزر بوده و گستردگی زیاد در جهت شمال-جنوب در عرض جغرافیایی (۲ درجه و ۳۱ دقیقه) تنوع آب و هوایی زیادی به استان اردبیل بخشیده است. (Faizipour et al., 2015). شکل (۱) موقعیت منطقه مورد مطالعه را نشان می-

دهد. در این پژوهش با استفاده داده های هواشناسی بارش، دما و رطوبت نسبی ایستگاه هواشناسی اردبیل، مقادیر بارش ماهانه اردبیل با استفاده از روش های برنامه ریزی ژنتیک و رگرسیون بردار پشتیبان در ۱۱ ترکیب مختلف داده های ورودی پیش بینی شد. جدول (۱) پارامترهای آماری داده های مورد استفاده را نشان می دهد. در جدول (۲) نیز ترکیب های مختلف ورودی مدل های GP و SVR آورده شده است.



شکل (۱): موقعیت استان اردبیل در ایران

جدول (۱): پارامترهای آماری ماهانه داده های مورد استفاده

پارامتر	واحد	میانگین	حداکثر	حداقل	انحراف معیار	ضریب تغییرات
بارش (P)	Mm	۲۲/۴۹۵	۱۵۰/۸	۰	۸,۳۱	۰/۳۳
دمای میانگین (T)	°C	۱۱	۲۲,۴۵	-۹	۷/۴۲	۰/۸۱
رطوبت نسبی (RH)	%	۷۳/۳۳۵	۹۰	۱۷	۷/۲۵	۰/۱۴

جدول (۲): ترکیب های مختلف ورودی مدل های GP و SVR

شماره مدل	پارامترهای ورودی	پارامتر خروجی
۱	P_{t-1}, P_t	P_{t+1}
۲	P_{t-2}, P_t	P_{t+1}
۳	P_{t-2}, P_{t-1}	P_{t+1}
۴	RH_{t-1}, RH_t	P_{t+1}
۵	RH_{t-2}, RH_t	P_{t+1}
۶	RH_{t-2}, RH_{t-1}	P_{t+1}
۷	T_{t-1}, T_t	P_{t+1}
۸	T_{t-2}, T_t	P_{t+1}
۹	T_{t-2}, T_{t-1}	P_{t+1}
۱۰	T_{t-3}, T_{t-1}	P_{t+1}
۱۱	T_{t-3}, T_{t-2}	P_{t+1}

برنامه‌ریزی ژنتیک (GP)

برنامه‌ریزی ژنتیک تعمیم یافته الگوریتم ژنتیک می‌باشد، که برای اولین بار در سال ۱۹۹۲ توسط Koza، بر اساس تئوری داروین ارائه شد. به این ترتیب که جمعیتی در جهت تکامل به صورت انتخابی، جمعیت نامناسب را رها کرده و فرزندانی اصلاح شده ایجاد می‌کنند. برنامه‌ریزی ژنتیک یک تکنیک برنامه‌ریزی خودکار می‌باشد که راه حل مسئله را با استفاده از برنامه کامپیوتری ارائه می‌کند. روش برنامه‌ریزی ژنتیک جدیدترین شیوه از بین روش‌های الگوریتم تکاملی می‌باشد که به دلیل دارا دقت بودن کافی، از کاربرد بیشتری برخوردار است (Alvisi et al., 2005). در این روش در ابتدای فرآیند هیچ گونه رابطه تابعی در نظر گرفته نشده و این روش قادر به بهینه‌سازی ساختار مدل و مولفه‌های آن می‌باشد. برنامه‌ریزی ژنتیک بر خلاف الگوریتم ژنتیک روی ساختار درختی فرمول‌ها به جای سلسله ارقام دودویی عمل می‌کند. ساختارهای درختی از مجموعه توابع (عملگرهای ریاضی مورد استفاده در فرمول‌ها) و ترمینال‌ها (متغیرهای مسئله و اعداد ثابت) ایجاد می‌شوند. قبل از مراحل اجرایی برنامه‌ریزی ژنتیک گام‌های مقدماتی زیر باید توسط کاربر تعیین شوند. (صمدیان‌فرد و دلیرحسین‌نیا، ۱۳۹۴):

۱. مجموعه ترمینال‌ها (متغیرهای مسئله، اعداد ثابت تصادفی)
۲. مجموعه عملگرهای ریاضی مورد استفاده در فرمول‌ها
۳. انتخاب تابع برازش مناسب (RMSE, MSE, R, ...)، برای سنجش برازش فرمول‌ها
۴. تعیین پارامترهای کنترل کننده اجرای برنامه (اندازه جمعیت، احتمال مربوط به کارگیری عمل‌های ژنتیکی و جزئیات دیگر مربوط به اجرای برنامه)
۵. معیار پایان و ارائه نتایج اجرای برنامه (مثل، تعداد تولید جمعیت جدید، تعیین یک مقدار مشخص برای برازش فرمول‌ها، که اگر میزان برازش برابر یا بیشتر از آن مقدار شد، اجرا متوقف شود).

رگرسیون بردار پشتیبان (SVR)

ماشین بردار پشتیبان یک روش یادگیری بر پایه تئوری یادگیری آماری است، که Boser و همکاران در سال ۱۹۹۲ میلادی معرفی کردند. اولین کاربرد این مدل در مسائل مدلسازی بارش و رواناب توسط Dibike و همکاران (۲۰۰۱) ارائه شده است. در واقع می‌توان گفت که ماشین بردار پشتیبان سیستم یادگیری کارآمدی است که به منظور رسیدن به یک جواب بهینه از اصل استقرایی کمینه‌سازی خطای ساختاری استفاده می‌کند (Bilandi et al., 2014). مدل SVM یک الگوریتم محاسبات نرم تحت نظارت است که همزمان خطاهای برآورد و پیچیدگی مدل را به حداقل می‌رساند (Benimam et al., 2020)، آن‌ها همچنین با کمک توابع کرنل، طبقه‌بندی کننده‌های غیرخطی را معرفی نمودند. بعدها با استفاده از نتایج کارهای Boser و همکاران اصول اساسی ماشین بردار پشتیبان به وجود آمد و در نهایت Vapnik در سال ۱۹۹۵ ماشین بردار پشتیبان را بر اساس رگرسیون گسترش داد (Vapnik, 1995). به طور کلی ماشین بردار پشتیبان برای طبقه‌بندی مسائل دو یا چند کلاسه به صورت خطی یا غیرخطی و رگرسیون مورد استفاده قرار می‌گیرد. در این روش، داده‌ها به دو دسته آموزش و آزمایش تقسیم می‌شوند.

در یک مدل رگرسیونی ماشین بردار پشتیبان لازم است وابستگی تابعی وابسته y به مجموعه‌ای از متغیرهای مستقل X تخمین زده شود. فرض بر این است که مانند دیگر مسائل رگرسیونی، رابطه بین متغیرهای وابسته و مستقل توسط یک تابع معین f به علاوه یک مقدار اضافی Noise مشخص شود (Hamel, 2009).

$$y = f(x) + Noise \quad (1)$$

بنابراین موضوع اصلی، پیدا کردن فرم تابع f است که بتواند به صورت صحیح، موارد جدیدی را که ماشین بردار پشتیبان تاکنون تجربه نکرده است، پیش بینی کند. این تابع به وسیله آموزش مدل ماشین بردار پشتیبان، بر روی یک مجموعه داده به-عنوان مجموعه آموزش که شامل فرآیندی به منظور بهینه سازی دائمی تابع خطا است، قایل دسترسی است. تابع خطا در روش رگرسیون بردار پشتیبان که به صورت گسترده در مسائل رگرسیونی کاربرد دارد، به صورت رابطه (۲) تعریف می‌شود، (Ahmadi et al., 2014):

$$\frac{1}{2}W^T W + C \sum_{i=1}^N \xi_i + C \sum_{i=1}^N \xi_i^* \quad (2)$$

معیار های 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 پارامترهای آماری ضریب همبستگی (R)، جذر میانگین مربعات خطا (RMSE) و شاخص پراکندگی (SI) استفاده شده است.

$$R = \frac{\left(\sum_{i=1}^n O_i P_i - \frac{1}{n} \sum_{i=1}^n O_i \sum_{i=1}^n P_i \right)}{\left(\sum_{i=1}^n O_i^2 - \frac{1}{n} \left(\sum_{i=1}^n O_i \right)^2 \right) \left(\sum_{i=1}^n P_i^2 - \frac{1}{n} \left(\sum_{i=1}^n P_i \right)^2 \right)} \quad (3)$$

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

$$SI = \frac{RMSE}{\bar{O}} \quad (5)$$

در روابط (۳) تا (۵)، n تعداد داده‌ها، O_i و P_i به ترتیب مقادیر مشاهداتی و پیش‌بینی شده بارش ماهانه هستند.


نتایج و بحث

در این تحقیق مقادیر بارش ماهانه ایستگاه اردبیل با استفاده از روش‌های هوشمند برنامه‌ریزی ژنتیک، رگرسیون بردار پشتیبان و با به‌کارگیری سری‌های زمانی داده‌های هواشناسی (بارش، دما و رطوبت نسبی) به‌عنوان پارامترهای ورودی مدل‌ها در ۱۱ ترکیب مختلف مدل‌سازی گردید. نتایج به‌دست آمده از هر یک از مدل‌ها با استفاده از شاخص‌های آماری ضریب همبستگی، جذر میانگین مربعات خطا و شاخص پراکندگی با مقادیر مشاهداتی بارش ماهانه مقایسه گردیده و مدل‌های برتر انتخاب شدند. جدول (۳) مقادیر پارامترهای آماری مدل‌های مورد استفاده را نشان می‌دهد.

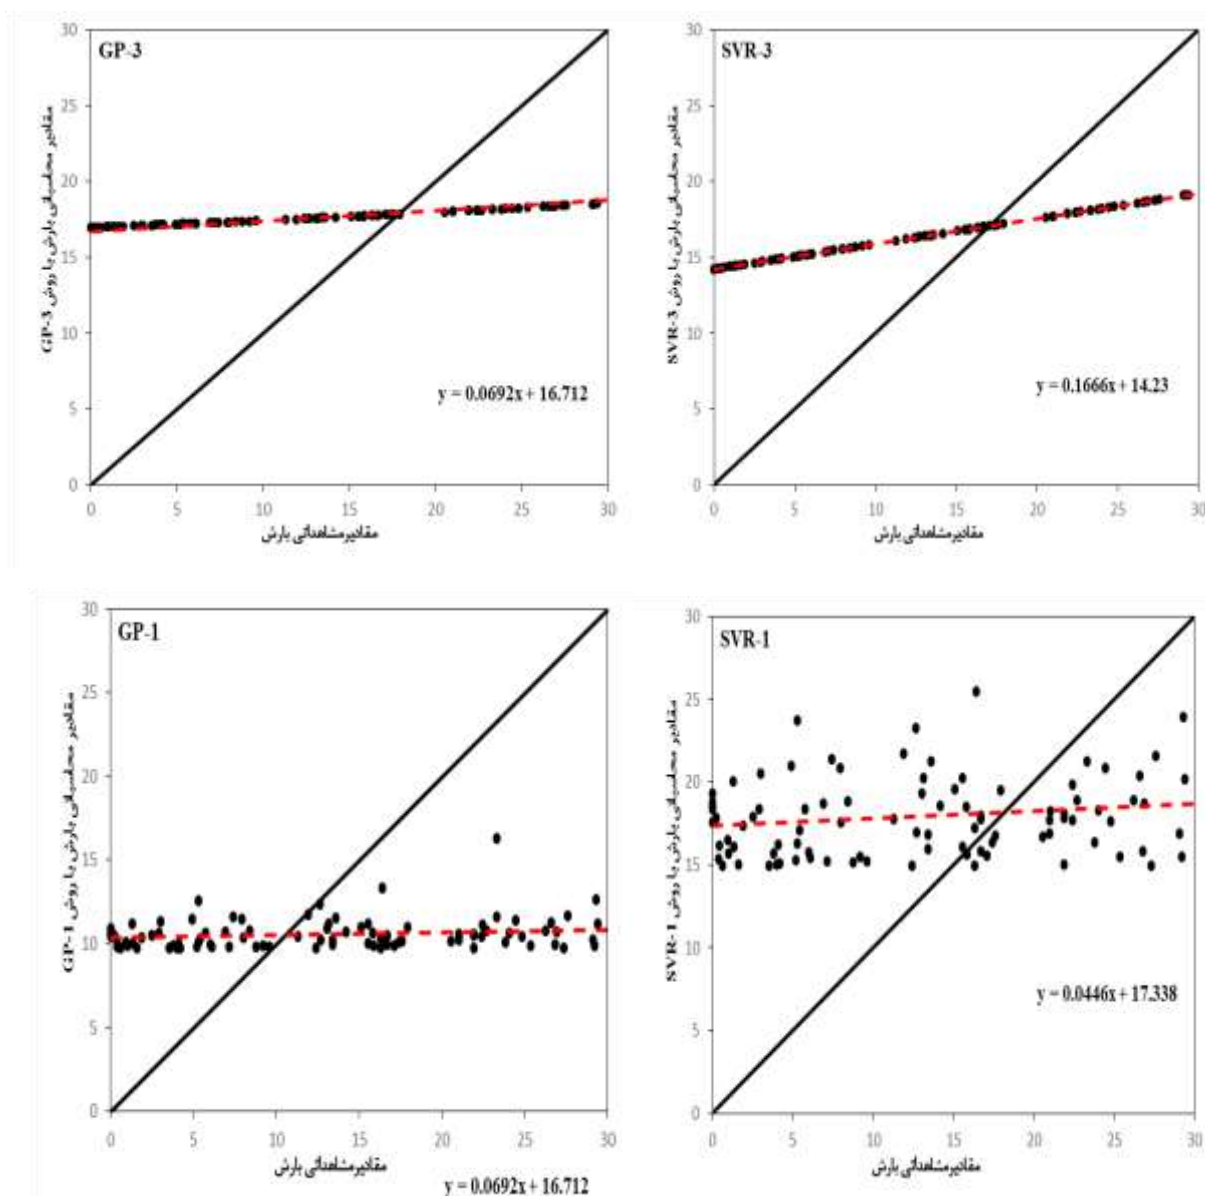
جدول (۳): پارامترهای آماری

شماره مدل	SVR			GP		
	MAE	RMSE	R	MAE	RMSE	R
۱	۰/۸۳۳	۱۶/۱۱۷	۰/۲۵۶	۰/۹۵۶	۱۸/۴۹۳	۰/۲۵۵
۲	۰/۸۶۷	۱۶/۷۵۹	-۰/۲۵۶	۱/۱۶۶	۲۲/۵۵۵	-۰/۰۶۶
۳	۰/۷۲۱	۱۲/۲۷۶	۰/۹۹۹	۰/۸	۱۷/۸۴۶	۰/۹۷۹
۴	۲/۸۸۴	۵۲/۶۸۱	۰/۰۹۵	۲/۸۷۷	۵۶/۴۷۲	۰/۰۷۹
۵	۲/۸۹۱	۵۵/۹۰۱	۰/۰۹۵	۳/۱۳۱	۶۰/۵۵۴	۰/۰۸۳
۶	۲/۸۸۷	۵۵/۸۳۷	۰/۰۱۵	۳/۰۷۶	۵۹/۴۸۸	۰/۰۲۶
۷	۱/۰۲۸	۱۹/۸۹۰	-۰/۰۴۷	۱/۱۵	۲۲/۲۴۷	-۰/۰۴۹
۸	۰/۹۷۶	۱۸/۸۷۱	-۰/۰۴۷	۱/۲۳۱	۲۳/۸۰۱	-۰/۰۰۲
۹	۱/۰۳۴	۲۰/۰۰۲	-۰/۰۵۳	۱/۲۰۱	۲۳/۲۲۹	-۰/۰۶۵
۱۰	۰/۹۸۱	۱۸/۹۷۴	-۰/۰۵۳	۱/۲۲۴	۲۳/۶۶۵	-۰/۰۸۱
۱۱	۱/۰۴۱	۲۰/۱۴۰	-۰/۰۶۶	۱/۱۳	۲۱/۸۵۲	-۰/۰۸۵

با توجه به نتایج به دست آمده (جدول ۳)، مدل GP-3 با ضریب همبستگی ۰/۹۷۹، جذر میانگین مربعات خطای ۱۷/۸۴۶ و شاخص پراکندگی ۰/۸، بهترین مدل در روش برنامه‌ریزی ژنتیک شناخته شد. مدل GP-1 نیز با دارا بودن ضریب همبستگی ۰/۲۵۵، جذر میانگین مربعات خطای ۱۸/۴۹۳ و شاخص پراکندگی ۰/۹۵۶ رتبه دوم را در این روش به خود اختصاص داد. در روش ماشین بردار پشتیبان نیز مدل SVR-3 دارای ضریب همبستگی ۰/۹۹۹، جذر میانگین مربعات خطای ۱۲/۲۷۶ و شاخص پراکندگی ۰/۷۲۱ بوده و بهترین عملکرد را در بین مدل‌های SVR داشته است. در رتبه دوم این روش، مدل SVR-1 با ضریب همبستگی ۰/۲۵۶، جذر میانگین مربعات خطای ۱۶/۱۱۷ و شاخص پراکندگی ۰/۸۳۳ قرار گرفت. نتایج این تحقیق نشان می‌دهد که عملکرد هر دو مدل برنامه‌ریزی ژنتیک و ماشین بردار پشتیبان خوب و مشابه بوده (میانگین خطای مطلق به ترتیب ۰،۸، ۰،۷۲۱ و ضریب همبستگی ۰،۹۷۹، ۰،۹۹۹)، ولی با توجه به بررسی معیارهای ارزیابی مختلف، مدل برنامه‌ریزی ماشین بردار پشتیبان عملکردی کمی بهتر داشته است (ضریب همبستگی ۰،۹۹۹)، به علاوه مدل ماشین بردار پشتیبان دارای مزیت سهولت در اجرای مدل نیز می‌باشد نتایج این تحقیق با Tabatabaei و همکاران (۲۰۱۸)، که اعلام نمودند عملکرد مدل ماشین بردار پشتیبان در مدل سازی دمای میانگین نسبت به سایر روش‌ها از عملکرد بهتر و خطای کمتری برخوردار است و نتایج تحقیق Sedighi و همکاران (۲۰۱۶)، مبنی بر عملکرد بهتر مدل ماشین بردار پشتیبان، نسبت به مدل برنامه‌ریزی ژنتیک منطبق می‌باشد. از شکل (۲) نمودار تغییرات زمانی بارش ماهانه با استفاده از بهترین مدل - های مورد مطالعه را نشان می‌دهد. همچنین در شکل (۳) نمودارهای پراکنش مقادیر محاسباتی بارش با استفاده از بهترین مدل‌های مورد مطالعه آورده شده است.



شکل (۲): نمودار تغییرات زمانی بارش ماهانه با استفاده از بهترین مدل‌های مورد مطالعه



شکل (۳): نمودارهای پراکنش مقادیر محاسباتی بارش با استفاده از بهترین مدل‌های مورد مطالعه

روند اشاره شده در مورد بالا بودن دقت در مدل‌های برتر از شکل‌های (۲) و (۳) نیز قابل نتیجه‌گیری است. به طور کلی از شکل‌های (۲) و (۳) می‌توان چنین استنباط کرد که در روش‌های رگرسیون بردار پشتیبان و برنامه‌ریزی ژنتیک، مدل‌هایی با ورودی سری‌های زمانی بارش، عملکرد مناسب‌تری داشته‌اند و می‌توان مقدار بارش ماهانه منطقه مورد مطالعه را با استفاده از مدل‌های مذکور با دقت نسبتاً بالایی پیش‌بینی کرد.

نتیجه‌گیری

در این پژوهش با استفاده از روش‌های هوشمند برنامه‌ریزی ژنتیک و رگرسیون بردار پشتیبان مقادیر بارش ماهانه ایستگاه اردبیل برآورد گردید، که ورودی روش‌های مذکور شامل سری‌های زمانی داده‌های هواشناسی بارش، دما و رطوبت نسبی در ۱۱ ترکیب متفاوت بود. نتایج به‌دست آمده با استفاده از پارامترهای آماری مورد مقایسه قرار گرفت و مشخص شد که در هر دو روش، مدل‌هایی که از سری‌های زمانی بارش به‌عنوان داده ورودی استفاده کردند، نتایج دقیق‌تری نسبت به سایر مدل‌ها ارائه دادند. همچنین نتیجه گرفته شد که در مقایسه مدل‌های برتر دو روش برنامه‌ریزی ژنتیک و رگرسیون بردار پشتیبان، مدل‌های SVR عملکرد مطلوب‌تری را ارائه دادند.

منابع

۱. باباعلی ح. ر. و ر. دهقانی (۱۳۹۶). مقایسه مدل‌های هوشمند در تخمین بارش ماهانه حوضه کاکارضا، اکوهیدرولوژی، ۱۴(۱)، ۱-۱۱.
۲. صمدیان فرد، س. و ر. دلیر حسن نیا (۱۳۹۴). پیش بینی جریان رودخانه شهرچای در حوضه آبریز دریاچه ارومیه با استفاده از برنامه ریزی ژنتیک و مدل درختی M5، نشریه آب و خاک (علوم و صنایع کشاورزی)، ۲۹(۵)، ۱۱۹۰-۱۲۰۶.
۳. علیائی، م.، ع. باریکلو و م. ثروتی (۱۳۹۸)، ارزیابی عملکرد شبکه‌های عصبی مصنوعی با تلفیق الگوریتم ژنتیک در برآورد سرعت نفوذ آب به خاک (مطالعه موردی: منطقه خداآفرین استان آذربایجان شرقی)، تحقیقات آب و خاک ایران، دوره ۵۰، شماره ۵.
4. Ahmadi F., Radmanesh F. and Mir Abbasi M. (2014). *Comparison of Genetic Planning Methods and Support Vector Machines in Predicting Daily River Flow (Case Study: Barandozchay River)*, Journal of Water and Soil (Crop Science and Technology), No. 6, 2014, pp. 1162-1171.
5. Alvisi S., Mascellani G., Franchini M. and Bardossy A. (2005). *Water level forecasting through fuzzy logic and artificial neural network approaches*. J Hydrol Earth Sys Sci., 2:1107-1145.
6. Benimam H., Si-Moussa C., Laidi M. and Hanini S. (2020)b. *Modeling the activity coefficient at infinite dilution of water in ionic liquids using artificial neural networks and support vector machines*. Neural Comput. Appl. 32 (12), 8635–8653.
7. Bilandi M., Khashei siouki E. and Sadeghi Tabas S. (2014). *Daily Runoff Prediction with Minimal Squares Model of Support Vector Machine*. (Is-Svm15) Journal of Soil and Water Conservation Research, No. 6, pp 293-3,4.
8. Boser B.E., Guyon I.M. and Vapnik V.N. (1992). *A training algorithm for optimal margin classifiers*. In D.Haussler, editor, 5th Annual ACM Workshop on COLT , pages 144-152, Pittsburgh, PA.
9. Chuge H. K. and Regulwar D.G. (2013). *Artificial Neural Network Method for Estimation of Missing Data*. International Journal of Advanced Technology in Civil Engineering, 2(1): pp 1-4.
10. Dibike Y., Velickov S., Solomatine D. and Abbott M. (2001). *Model induction with of support vector machines: Introduction and applications*. J. Comp. Civil Engin. 15: 3. 208-216.
11. Faizipour N. S., Aboli S. and Dindar M. (2015). *Climatic Zoning of Ardabil Province with Geographic Information System (GIS)*, 2nd International Conference and 5th National Conference on Tourism, Geography and Sustainable Environment, Hamedan, Iran.
12. Fallah-Mehdipour E., Bozorg Haddad O. and Marino M.A. (2013). *Prediction and simulation of monthly groundwater levels by genetic programming*. Journal of Hydro-environment Research 7(4), pp 253-260.
13. Ghani N.Z.C., Hasan Z.A. and Liang A.T. (2014). *Estimation of missing rainfall data using GEP: case study of Raja River, Alor Setar, Kedah*. Advances in artificial intelligence, pp 1-5.
14. Hamel L. (2009). *Knowledge Discovery with Support Vector Machines*. Hoboken. N.J. John Wiley.
15. Kisi O. (2009). *Modeling monthly evaporation using two different neural computing techniques*. Irrigatin science, 27(5), pp 417-430.
16. Koza J.R. (1992). *Genetic Programming: On the Programming of Computers by Means of Natural Selection*. Cambridge, MIT Press.
17. Kumari M., Basistha A., Bakimchandra O. and Singh C. K. (2016). *Comparison of Spatial Interpolation Methods for Mapping Rainfall in Indian Himalayas of Uttarakhand Region*. Geostatistical and Geospatial Approaches for the Characterization of Natural Resources in the Environment; pp 159-168.
18. Mekanik F., Imteaz M.A., Gato-Trinida S. and Elmahdi A. (2013). *Multiple Regression and Artificial Neural Network For Long Term Rainfall Forecasting Using Large Scale Climate Modes*. Journal of Hydrology, 503, pp 11-21.
19. Moghaddamnia A., Ghafari Gousheh M., Piri J., Amin S. and Han D. (2009). *Evaporation estimation using artificial neural networks and adaptive neuro-fuzzy inference system techniques*. Advances in Water Resources, 32(1), pp 88-97.
20. Palmer T. (2020). *A vision for numerical weather prediction in 2030*. arXiv preprint arXiv:2007.04830.

21. Sedighi F., Vafakhah M. and Javadi M. R. (2016). *Rainfall-Runoff modeling using support vector machine in snow-affected watershed*. Arabian Journal for Science and Engineering. 41: 10. 4065-4076.
22. Tabatabaei S.M., Nazeri Tahroudi M. and Dastourani M. (2018). *Performance comparison of GP, ANN, BCSD and SVM models for temperature simulation*. Journal of Meteorology and Atmospheric Sciences, Volume 1, Issue 1, pp 53-64.
23. Tripathi S., Srinivas V.V. and Nanjundiah R.S. (2006). *Downscaling of precipitation for climate change scenarios: a support vector machine approach*. Journal of hydrology, 330(3-4), 621-640.
24. Vapnik V. (1995). *The Nature of Statistical Learning Theory*. Springer, New York.

Monthly rainfall Forecasting using genetic programming and support vector machine

Milad Sharafi^{1*} Saeed Samadianfard² Sajjad Hashemi³

^{1*} Corresponding author, Undergraduate student, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Iran

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

³ Master student, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Iran

Received: 2021/02

Accepted: 2021/03

Abstract

Rainfall and runoff estimation play a fundamental and effective role in the management and proper operation of the watershed, dams and reservoirs management, minimizing the damage caused by floods and droughts, and water resources management. The optimal performance of intelligent models has increased their use to predict various hydrological phenomena. Therefore, in this study, two intelligent models including, genetic programming and support vector machine were used to forecast the monthly precipitation of Ardabil province. For this purpose, precipitation, temperature, and relative humidity on a monthly scale were considered as the input parameters of the models. The results showed that the performances of both models were good and almost the same (mean absolute error of 0.8 and 0.721, respectively), but according to the evaluations, the support vector regression model had a relatively better performance (correlation coefficient 0.999) compared to another model. In general, it can be concluded that the support vector regression model has been more suitable for modeling and forecasting monthly precipitation in Ardabil province.

Keywords: Monthly rainfall, Genetic programming, Fitting function, Correlation coefficient, Support vector machine.

^{1*} Miladsharafi1@gmail.com