

## ارزیابی کارایی مدل‌های مختلف خطی و غیرخطی در پیش‌بینی بارندگی ماهانه در تغییرات اقلیم استان همدان

حامد نوذری<sup>۱</sup> و فاطمه توکلی<sup>۲</sup>

۱- دانشیار گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان (نویسنده مسوول: h.nozari@basu.ac.ir)

۲- دانشجوی دکتری مهندسی منابع آب، دانشکده کشاورزی، دانشگاه بوعلی سینا، همدان

تاریخ دریافت: ۹۷/۱/۲۴ تاریخ پذیرش: ۹۷/۱۰/۱۵

صفحه: ۱ تا ۱۲

### چکیده

در این پژوهش به منظور پیش‌بینی مقادیر ماهانه بارش از مدل‌های ماشینی بردار پشتیبان (SVM)، ماشین بردار پشتیبان تلفیق شده با تبدیل موجک (W-SVM) و ARMAX و ARIMA استفاده گردید. لذا از سری زمانی ماهانه ایستگاه‌های باران‌سنجی واقع در استان همدان طی یک دوره ۲۵ ساله (۱۳۷۰-۱۳۹۴) استفاده شد. این دوره ۲۵ ساله به ۱۷ سال برای آموزش، ۴ سال برای واسنجی و ۴ سال برای صحت‌سنجی مدل تقسیم شد. مقایسه آماری نتایج به کمک شاخص‌های ضریب همبستگی (r)، جذر میانگین مربعات خطا (RMSE) و خطای استاندارد (SE) صورت گرفت. نتایج نشان داد که به ترتیب مدل‌های ARIMA، ماشین بردار پشتیبان، ARMAX و ماشین بردار پشتیبان تلفیق شده با تبدیل موجک در رتبه‌های اول تا چهارم قرار دارند. همچنین مدل ماشینی بردار پشتیبان دارای پارامترهای قابل تنظیم کمتری نسبت به مدل‌های دیگر می‌باشد. لذا این مدل با سهولت بیشتر و در زمان کمتری قادر به پیش‌بینی بارش بوده و از این نظر نسبت به سایر روش‌ها ارجحیت دارد.

واژه‌های کلیدی: ARMAX، ARIMA، بارش، پیش‌بینی، ماشین بردار پشتیبان، موجک

### مقدمه

درجه حرارت مشابه با شبکه عصبی MLP رفتار نموده است ولی در پیش‌بینی کمینه درجه حرارت ضعیف عمل کرده است. طوفانی و همکاران (۳۳) به منظور پیش‌بینی بارش ماهانه در ایستگاه باران‌سنجی زرینگل از روش موجک استفاده نمودند و نتایج آن‌ها نشان داد که تجزیه سیگنال با موجک منجر به ساده‌تر شدن سیگنال بارندگی می‌گردد. به طوری که همبستگی میان داده‌های مشاهداتی و محاسباتی ۸۴ درصد به دست آمده و پیش‌بینی سیگنال بارندگی با دقت بیشتری صورت گرفته است.

کیسی و کایمن (۲۱) به منظور پیش‌بینی بارش روزانه در دو ایستگاه از میر و افیون در ترکیه از یک مدل ترکیبی از مدل ماشینی بردار پشتیبان و تبدیل موجک گسسته استفاده نمودند، نتایج پژوهش آن‌ها نشان داد که استفاده از مدل ترکیبی باعث افزایش دقت پیش‌بینی نسبت به مدل ماشینی بردار پشتیبان مستقل گردید.

حمیدی و همکاران (۱۴) به منظور پیش‌بینی بارش ماهانه ایستگاه‌های سینوپتیک فرودگاه و نوژه در غرب ایران از دو مدل ماشینی بردار پشتیبان و شبکه عصبی مصنوعی استفاده نمودند و دریافتند که ماشین بردار پشتیبان نسبت به شبکه عصبی از کارایی بیشتری برخوردار است.

مظفری و همکاران (۲۵) به منظور پیش‌بینی سری زمانی بارش ماهانه ایستگاه سینوپتیک کرمانشاه، از داده‌های پنج پارامتر اقلیمی، میانگین بارش ماهانه، میانگین رطوبت نسبی، میانگین حداکثر دما، میانگین حداقل دما و میانگین سرعت باد در دوره آماری ۴۰ ساله (۱۹۷۰-۲۰۱۰) و مدل شبکه عصبی و موجک استفاده نمودند. نتایج به دست آمده از تبدیل موجک- شبکه عصبی با نتایج حاصل از کاربرد شبکه عصبی، مقایسه شده و ملاحظه گردید که روش موجک- شبکه عصبی نسبت به روش شبکه عصبی دقت پیش‌بینی بالاتری

بارش به عنوان یک عنصر مهم از منابع آبی در تمام نقاط جهان از جمله مناطق خشک و نیمه‌خشک و یکی از پیچیده‌ترین و اتفاقی‌ترین پدیده‌های طبیعی شناخته شده و به دلیل تاثیر عوامل محسوس و یا غیرمحسوس دخیل در ایجاد این حادثه، روند آن از یک نظام قانونمند روشن به سوی یک ساختار پیچیده سوق داده شده است (۱۸). به دلیل ماهیت غیرخطی، عدم قطعیت، عدم صراحت زیاد و ویژگی‌های متغیر زمانی و مکانی در سیستم گردش آبی، هیچ یک از مدل‌های اقلیم‌شناسی مختلفی که جهت مدل‌سازی بارندگی پیشنهاد شده‌اند، نتوانسته‌اند به منظور الگوسازی دقیق بارش به عنوان یک مدل برتر و توانا شناخته شوند (۲۵).

از پژوهش‌های صورت گرفته در زمینه پیش‌بینی و الگوسازی بارش می‌توان به پژوهش‌های زیر اشاره نمود: اب و همکاران (۱)، داده‌های بارندگی سه ایستگاه باران‌سنجی واقع در شمال ایتالیا را به کمک سه روش مبتنی بر منطق فازی، شبکه عصبی مصنوعی و نسبت نرمال مورد بازسازی قرار دادند. نتایج این پژوهش نشان می‌دهد که روش فازی از توانایی بالاتری در بازسازی این داده‌ها نسبت به دو روش دیگر برخوردار است.

کالیلی و اورا (۷) به منظور تکمیل داده‌های گمشده بارش و درجه حرارت روزانه ۱۵ ایستگاه هواشناسی در شمال شرق کانادا از شبکه عصبی پرسپترون چند لایه (MLP) و انواع آن شامل TLFN و RBF و شبکه عصبی دینامیکی از نوع بازگشتی (RNN) و انواع آن شامل TDRNN و CFNN استفاده نمودند. نتایج این پژوهش نشان داد که شبکه عصبی MLP در تکمیل داده‌های گمشده بارش روزانه و هم چنین پیشینه و کمینه درجه حرارت نسبت به سایر شبکه‌ها موفق‌تر بوده و شبکه عصبی CFNN با اینکه در پیش‌بینی پیشینه

مصنوعی و مدل SARIMA صورت گرفته و در نهایت نتایج نشان داد که مدل ترکیبی موجک با شبکه عصبی و مدل SARIMA دارای عملکرد بهتری نسبت به مدل‌های شبکه عصبی و SARIMA در پیش‌بینی بارش است. بررسی پژوهش‌هایی که تاکنون صورت گرفته است، نشان می‌دهد مدل‌های ماشین بردار پشتیبان (SVM)<sup>۱</sup>، مدل ماشین بردار پشتیبان تلفیق شده با تبدیل موجک<sup>۲</sup>، مدل ARMAX و مدل خود همبسته با میانگین متحرک (ARIMA)<sup>۳</sup> از دقت قابل قبولی در مدلسازی و پیش‌بینی بارش برخوردار هستند. هدف از انجام پژوهش حاضر، ارزیابی و مقایسه عملکرد مدل‌های فوق در پیش‌بینی بارش ماهانه و معرفی مناسبترین مدل به منظور پیش‌بینی پارامتر مذکور بوده و نتایج آن قابل استفاده برای مدیران، برنامه‌ریزان و دست اندرکاران بخش آب خواهد بود. طول شرقی اقرار گرفته است. ایستگاه‌های انتخاب شده و مورد مطالعه در این پژوهش شامل ایستگاه‌های سد اکباتان، مریانج، آق کهریز، آقاجانلاغی است. که همگی در حوزه آبریز قره چای قرار دارند. در شکل (۱) موقعیت مکانی و در جداول (۱) و (۲) مشخصات این ایستگاه‌ها نشان داده شده است.

دارد و همچنین دقت پیش‌بینی در هر دو مدل با افزایش تعداد تأخیرها در نرون خروجی کاهش می‌یابد. شنیفی و همکاران (۳۲) به منظور برآورد بارش ماهانه در SERBIA از سه روش شبکه عصبی مصنوعی، الگوریتم ژنتیک و مدل ترکیبی موجک و ماشین بردار پشتیبان استفاده نموده و دریافتند که مدل ترکیبی موجک و ماشین بردار پشتیبان دارای عملکرد بهتری نسبت به دو مدل دیگر به این منظور است.

شفائی و همکاران (۳۱) به پیش‌بینی بارش در ایستگاه نهبوند با استفاده از مدل‌های SARIMA، شبکه عصبی مصنوعی و تبدیل موجک پرداختند. به این منظور سیگنال اصلی بارش به کمک تبدیل موجک به زیرسریهایی با فرکانس بالا و زیرسریه‌هایی با فرکانس پایین تقسیم شده و پیش‌بینی هریک از این سری‌ها به ترتیب به وسیله شبکه عصبی

### مواد و روش‌ها منطقه مورد مطالعه

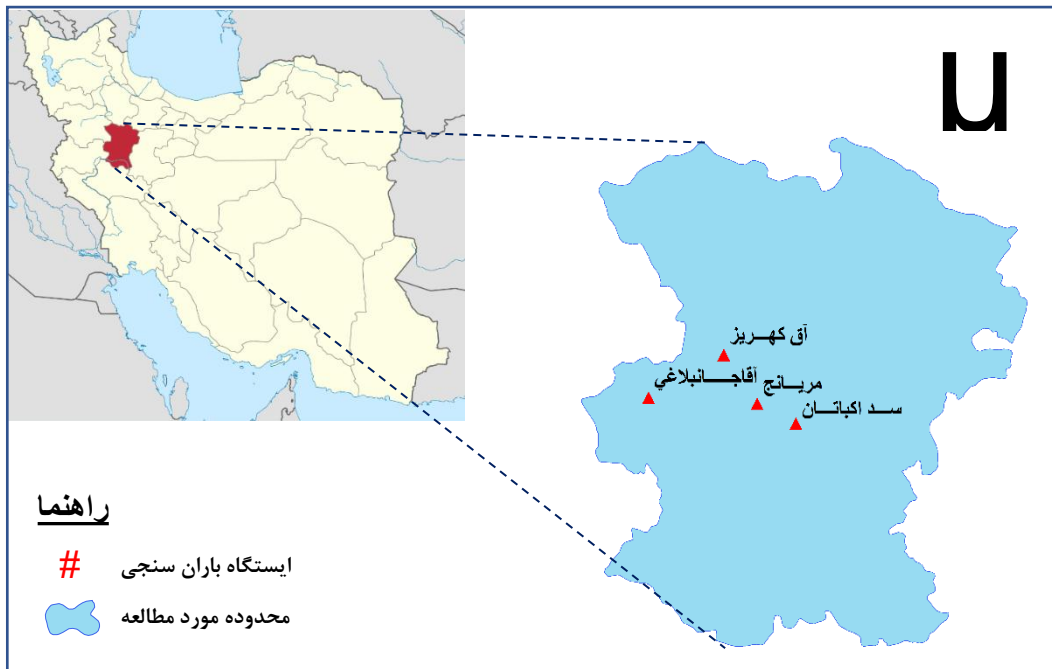
استان همدان با مساحت ۲۰ هزار و ۱۷۲ کیومترمربع، ۲/۱ درصد از کل مساحت کشور را در بر می‌گیرد. این استان بین مدارهای ۴۹ درجه و ۳۵ دقیقه تا ۵۹ درجه و ۳۳ دقیقه عرض شمالی و ۳۴ درجه و ۴۷ دقیقه تا ۳۴ درجه و ۴۹ دقیقه

جدول ۱- مشخصات ایستگاه‌های باران سنجی مورد مطالعه

ردیف	نام ایستگاه (-)	نوع ایستگاه (-)	طول جغرافیایی (درجه - دقیقه - ثانیه)	عرض جغرافیایی (درجه - دقیقه - ثانیه)	ارتفاع (متر)
۱	سد اکباتان	باران سنج ثابت	۱۱-۳۶-۴۸	۳۶-۴۵-۳۴	۱۹۵۷
۲	آقاجانلاغی	باران سنج معمولی	۰۷-۰۳-۴۸	۵۳-۵۰-۳۴	۱۸۰۲
۳	آق کهریز	باران سنج ثابت	۰۱-۲۰-۴۸	۴۰-۵۹-۳۴	۱۸۴۴
۴	مریانج	باران سنج معمولی	۲۸-۲۷-۴۸	۴۱-۴۹-۳۴	۱۸۴۱

جدول ۲- مشخصات آماری ایستگاه‌های باران سنجی مورد مطالعه

ردیف	نام ایستگاه (-)	طول دوره آماری (سال)	حداقل بارش (mm/month)	حداکثر بارش (mm/month)	متوسط بارش (mm/month)
۱	سد اکباتان	۱۳۹۴-۱۳۴۵	۰	۱۶۷	۲۸/۷
۲	آقاجانلاغی	۱۳۹۴-۱۳۴۵	۰	۱۹۶/۵	۲۹/۳
۳	آق کهریز	۱۳۹۴-۱۳۴۷	۰	۱۸۷	۲۷
۴	مریانج	۱۳۹۴-۱۳۷۰	۰	۱۸۷	۳۷/۴



شکل ۱- موقعیت مکانی ایستگاه‌های باران سنجی مورد مطالعه  
Figure 1. Location of the studied rain gauge stations

دو ویژگی برجسته قابلیت عمومی سازی عالی و سازگاری با داده‌های پراکنده و کم، موجب پیش‌بینی‌های ثمر بخش توسط ماشین بردار پشتیبان می‌شود (۳). ماشین بردار پشتیبان دارای دو نوع رگرسیون SVM-ε و SVM-ν می‌باشد که نوع دوم دارای کاربرد بیشتری در مسائل رگرسیونی است و در واقع این مدل تابع خطای زیر (رابطه ۱) را با در نظر گرفتن یکسری محدودیت‌ها (رابطه ۲) کمینه می‌کند (۱۳).

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

$$\begin{aligned} W^T \phi(x_i) + b - y_i &\leq \varepsilon + \xi_i^* \\ y_i - W^T \phi(x_i) - b &\leq \varepsilon + \xi_i \\ \xi_i^*, \xi_i &\geq 0 \end{aligned} \quad (2)$$

تبدیل موجک عبارت است از عملیاتی که از تغییر در توابع بنیادی یا موجک مادر یک تابع جدید به وجود می‌آید (۴). به وسیله دو عملگر انتقال و مقیاس، تغییر اندازه و تغییر محل موجک مادر در طول سیگنال مورد مطالعه، صورت گرفته و به صورت زیر (رابطه ۳) بیان می‌شود (۲۰).

$$\Psi_{a,b}(t) = |a|^{-1/2} \Psi\left(\frac{t-a}{b}\right), \quad b \in \mathbb{R}, a \in \mathbb{R}, a \neq 0 \quad (3)$$

هر موجک دارای سه مشخصه است که شرط مقبولیت نیز نامیده شده و عبارتند از تعداد نوسان محدود، بازگشت سریع به

### مدل ماشین بردار پشتیبان

ماشین بردار پشتیبان سیستم یادگیری کارآمدی است که به منظور رسیدن به یک جواب بهینه از اصل استقرایی کمینه‌سازی خطای ساختاری استفاده می‌کند (۸). اولین کاربرد این روش در مسائل آب به شبیه‌سازی بارش- رواناب توسط دیباک و همکاران بر می‌گردد (۱۵). ماشین بردار پشتیبان که برای اولین بار در سال ۱۹۹۸ توسط وینینگ معرفی گردید، در واقع یک طبقه کننده دو دویی است (۲۶).

در روابط بالا C ثابت گنجایش، W بردار ضرایب،  $\xi_i$  و  $\xi_i^*$  ضرایب کمبود، b ضریب ثابت، N الگوهای آموزش مدل و  $\phi$  تابع کرنل است. **تبدیل موجک**

در این رابطه a پارامتر مقیاس یا فرکانس، b پارامتر انتقال یا زمان و R محدوده اعداد حقیقی است.

سیگنال‌های زمانی که در اختیار هیدرولوژیست‌ها قرار دارند، سیگنال‌های زمانی گسسته هستند. تبدیل موجک گسسته به صورت زیر تعریف می‌گردد (۲۴):

$$W_f(a, b) = |a|^{-\frac{1}{2}\Delta t} \sum_{k=1}^N f(k\Delta t) \Psi^* \left( \frac{k\Delta t - b}{a} \right) \quad (۴)$$

#### مدل ARMAX

مدل ARMAX یک حالت توسعه یافته از مدل آرما بوده که به دلیل در نظر گرفتن سایر سری‌های زمانی به عنوان ورودی، از آن به عنوان یک مدل رگرسیون پویا نیز یاد شده و به صورت زیر قابل تعریف است (۲۳).

$$y_t = c + \sum_{i=1}^p \varphi_i y_{t-i} + \varepsilon_t + \sum_{j=1}^q \phi_j \varepsilon_{t-j} + \sum_{k=1}^n \beta_k x(t, k)$$

که  $\beta$  بردار ضرایب مربوط به ماتریس مولفه‌های رگرسیون  $x$  است. درعمل ضرایب  $(\varphi_i, \phi_j, \beta_k)$  به روش MLE تخمین زده می‌شوند.

در این روش بر خلاف روش‌های دیگر سری زمانی که در آن‌ها فقط از اطلاعات پارامتر مورد پیش‌بینی استفاده می‌شود، از پارامترهای دیگری نیز که با پارامتر مورد نظر همبستگی دارند استفاده می‌شود، که این عامل یک مزیت اساسی برای این روش نسبت به سایر روش‌های سری زمانی است (۲۷). به طور مثال در رابطه با بارش می‌توان از پارامترهایی نظیر میانگین رطوبت نسبی، میانگین حداکثر دما، میانگین حداقل دما و میانگین سرعت باد و سایر پارامترهای مرتبط نیز استفاده نمود.

#### معیارهای ارزیابی:

به منظور ارزیابی کارایی و دقت مدل‌های مورد استفاده در این پژوهش از چهار شاخص آماری ضریب همبستگی ( $r$ )، جذر میانگین مربعات خطا (RMSE)، خطای استاندارد (SE) و معیار اطلاعات (AIC) استفاده شد.

$$r = \frac{[\sum_{i=1}^n (p_i^p - \bar{p}_i^p)(p_i^o - \bar{p}_i^o)]}{\sqrt{\sum_{i=1}^n (p_i^p - \bar{p}_i^p)^2 \sum_{i=1}^n (p_i^o - \bar{p}_i^o)^2}} \quad (۱۰)$$

$$RMSE = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (p_i^o - p_i^p)^2} \quad (۱۱)$$

$$SE = \frac{RMSE}{\bar{x}} \quad (۱۲)$$

$$AIC(M) = n \ln \sigma_z^2 + 2M \quad (۱۳)$$

تعداد پارامترهای مدل،  $\sigma_z^2$  واریانس باقیمانده‌های مدل و  $n$  تعداد داده‌ها می‌باشد.

صفر در دو جهت مثبت و منفی در دامنه خود و میانگین. به صورت کلی تبدیل موجکی دارای دو شکل پیوسته (cwt) و گسسته (dwt) می‌باشد. در کاربردهای عملی اغلب

#### مدل‌های ARIMA

اساس این مدل‌ها در پایه زنجیره مارکوف<sup>۱</sup> بنا شده و جهت مدل‌سازی سالانه و یا فصلی سری‌های زمانی به کار می‌روند. استفاده از  $d$  امین تفاضل سری به منظور ایستاسازی و مدل‌سازی آن با مدل  $ARMA(p, q)$  باعث به وجود آمدن سری جدیدی از مدل‌های آماری تحت عنوان مدل‌های آرما  $ARIMA(p, d, q)$  شده است. استفاده از عملگر تفاضل فصلی با تاخیر  $\omega$  و برازش آنها با مدل‌های  $ARMA(p, q)$  باعث به وجود آمدن مدل‌های فصلی آرما  $ARIMA(P, D, Q)\omega$  و ترکیب مدل‌های فصلی و غیرفصلی، مدل‌های موسوم به آریمای مکرر (Multiplicative ARIMA) را تشکیل می‌دهند. مدل ساده ARIMA برای سری زمانی  $x_t$  از برازش مدل ARMA بر روی سری تفاضلات آن ( $u_t$ ) بدست می‌آید. در این حالت ARIMA به شکل زیر خواهد بود:

$$u_t = \sum_{i=1}^p \phi_i u_{t-i} + \varepsilon_t - \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (۵)$$

که در آن  $u$  سری حاصل حاصل از تفاضل  $d$ ام سری اصلی می‌باشد. در حالت کلی مدل‌های غیرفصلی  $ARIMA(p, d, q)$  را به صورت زیر می‌توان نشان داد:

$$\phi(B)(1-B)^d z_t = \theta(B)\varepsilon_t \quad (۶)$$

که در آن  $\phi(B)$  و  $\theta(B)$  به صورت زیر تعریف می‌گردد: (۱۷):

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad (۷)$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_p B^p \quad (۸)$$

در این روابط،  $p_i^o$  بارش مشاهداتی،  $p_i^p$  بارش شبیه‌سازی،  $\bar{p}_i^o$  میانگین بارش مشاهداتی،  $\bar{p}_i^p$  میانگین بارش شبیه‌سازی،  $M$

1- Markov chain

### نتایج و بحث

به منظور پیش‌بینی بارش ماهانه در ایستگاه‌های باران سنجی سد اکباتان، مربانج، آق کهریز و آقاجانبلاغی از سری زمانی بارش ماهانه این ایستگاه‌ها طی سال‌های ۱۳۷۰ تا ۱۳۹۴ استفاده شده که از این دوره آماری، ۱۷ سال (۱۳۷۰-۱۳۸۶) برای آموزش، ۴ سال (۱۳۸۷-۱۳۹۰) برای واسنجی و ۴ سال (۱۳۹۱-۱۳۹۴) به منظور صحت‌سنجی مدل‌ها در نظر گرفته شده است. به این منظور از مدل‌های ماشین بردار پشتیبان (SVM)، مدل ماشین بردار پشتیبان تلفیق شده با تبدیل موجک (W-SVM)، مدل ARMAX و مدل ARIMA استفاده گردید. قبل از استفاده از داده‌ها در مدل‌های مربوطه، سری زمانی بارش ماهانه ایستگاه‌های مورد مطالعه از نظر ایستایی و عدم وجود داده‌های پرت مورد آزمون قرار گرفت. ارزیابی عملکرد هر یک از مدل‌های مذکور در پیش‌بینی بارش ماهانه این ایستگاه‌ها به شرح زیر است.

#### پیش‌بینی به وسیله ماشین بردار پشتیبان:

مدل‌سازی بارش ماهانه توسط این مدل به وسیله نرم افزار MATLAB و در قالب سه مرحله‌ی "انتخاب تابع کرنل (Kernel) مناسب برای آموزش مدل"، "یافتن بهترین الگوی ورودی از تاخیرهای زمانی" و "پیش‌بینی" صورت گرفت. در مرحله اول با توجه به اینکه در مطالعات هیدرولوژی عمدتاً از تابع کرنل پایه شعاعی (RBF) استفاده می‌گردد (۱۰) و علاوه بر کرنل RBF، کرنل‌های خطی و چند جمله‌ای نیز

از پر کاربردترین توابع کرنل می‌باشند (۱۶)، لذا از توابع کرنل پایه شعاعی (RBF)، خطی (lin) و چندجمله‌ای (poly) استفاده شد.

در گام دوم، از داده‌های ماهانه بارش با توالی برگشتی تا ۱۲ ماه قبل به عنوان داده‌های آموزشی و به صورت ترکیب‌های مختلف مطابق با جدول (۳) استفاده شد. پیش‌بینی به کمک سه کرنل پایه شعاعی، خطی و چند جمله‌ای، در دوره آماری که برای واسنجی مدل‌ها در نظر گرفته شده بود، صورت گرفت. علاوه بر ارزیابی عملکرد الگوهای ورودی به کمک شاخص‌های آماری مناسب‌ترین تابع کرنل نیز در هر ایستگاه و به دنبال استفاده از هر الگوی ورودی شناسایی شد. به اختصار نتایج مربوط به کرنل و الگوی انتخابی در هر یک از ایستگاه‌های مورد مطالعه در جدول (۴) ارائه شده است.

در مرحله سوم نیز بارش ماهانه با استفاده از مدل ماشین بردار پشتیبان و بهره‌گیری از الگوی مناسب ورودی و همچنین تابع کرنل انتخاب شده در مرحله قبل، مورد پیش‌بینی قرار گرفت. ضمناً مقادیر مربوط به پارامترهای تنظیم‌کننده مدل و کرنل انتخابی به وسیله تابع LSSVM در نرم‌افزار Matlab برآورد شده است. نتایج محاسبه شاخص‌های آماری در مرحله صحت‌سنجی در جدول (۴) ارائه شده است.

جدول ۳- الگوی ورودی مدل

Table 3. Model input pattern

الگوی ورودی مدل در مقیاس ماهانه	شماره الگوی ورودی
$Q(t) = f\{Q(t-1)\}$	۱
$Q(t) = f\{Q(t-1), Q(t-2)\}$	۲
$Q(t) = f\{Q(t-1), \dots, Q(t-3)\}$	۳
$Q(t) = f\{Q(t-1), \dots, Q(t-4)\}$	۴
$Q(t) = f\{Q(t-1), \dots, Q(t-5)\}$	۵
$Q(t) = f\{Q(t-1), \dots, Q(t-6)\}$	۶
$Q(t) = f\{Q(t-1), \dots, Q(t-7)\}$	۷
$Q(t) = f\{Q(t-1), \dots, Q(t-8)\}$	۸
$Q(t) = f\{Q(t-1), \dots, Q(t-9)\}$	۹
$Q(t) = f\{Q(t-1), \dots, Q(t-10)\}$	۱۰
$Q(t) = f\{Q(t-1), \dots, Q(t-11)\}$	۱۱
$Q(t) = f\{Q(t-1), \dots, Q(t-12)\}$	۱۲

جدول ۴ - نتایج مربوط به پیش‌بینی بارش ماهانه در مرحله واسنجی و صحت‌سنجی به وسیله ماشین بردار پشتیبان  
Table 4. The results of monthly precipitation prediction in the calibration and validation step by a support vector machine

مرحله صحت‌سنجی			مرحله واسنجی			ساختار مدل		ایستگاه	
SE*** (-)	RMSE** (mm/month)	r* (-)	SE*** (-)	RMSE** (mm/month)	r* (-)	کرنل	شماره الگو	نام	نوع
۰/۸۹۸	۲۶/۸۷۸	۰/۶۰۱	۱/۰۱۲	۳۵/۷۹۸	۰/۶۱۷	RBF	۱۲	سد اکباتان	
۰/۷۶۷	۲۸/۵۷۶	۰/۶۴۰	۰/۹۱۰	۳۷/۲۹۱	۰/۵۸۴	RBF	۱۲	مریانج	باران سنجی
۱/۱۵۷	۲۸/۷۳۴	۰/۴۴۸	۱/۱۴۱	۳۲/۰۴۴	۰/۴۷۳	RBF	۱۲	آق کهریز	
۰/۹۲۷	۳۱/۹۸۰	۰/۶۳۷	۱/۰۹۰	۳۹/۵۵۷	۰/۵۳۴	RBF	۱۲	آقاجانبلای	

مرحله ۲ ابتدا به وسیله موجک هار و سطوح تجزیه ۱ تا ۷ به قسمت‌های تقریب و جزئیات تقسیم شده و سپس به‌منظور پیش‌بینی به ماشین بردار پشتیبان داده شدند.

در مرحله چهارم با توجه به استفاده بیشتر از موجک‌های هار، دابیچی<sup>۱</sup> و سیملت<sup>۲</sup> در علوم آب (۵) و همچنین از آنجایی که موجک میر جزء آن دسته از موجک‌هایی است که تمام خواص عمود، بای ارتوگونال و پشتیبانی همه‌جانبه را دارا بوده و در نتیجه به خوبی قابلیت اجرای تمام خواص موجک‌ها را برای پردازش و تجزیه موج دارد (۲۹)، از این چهار گروه مهم موجک در مدل‌سازی استفاده گردید. نتایج مربوط به انتخاب سطح تجزیه و موجک مناسب در مراحل سوم و چهارم در ایستگاه‌های مورد مطالعه در جدول (۵) ارائه شده است. و در نهایت بارش ماهانه به کمک مدل برازش داده شده در مرحله قبل پیش‌بینی شد. نتایج محاسبه شاخص‌های آماری در مرحله صحت‌سنجی در جدول (۵) آمده است.

### مدل ماشین بردار پشتیبان (svm) تلفیق شده با تبدیل موجک

مدل‌سازی بارش ماهانه توسط این مدل به وسیله نرم‌افزار MATLAB و در قالب پنج مرحله "انتخاب تابع کرنل مناسب مدل"، "یافتن بهترین الگوی ورودی از تاخیرهای زمانی"، "انتخاب مناسب‌ترین سطح تجزیه"، "انتخاب مناسب‌ترین موجک" و "پیش‌بینی" صورت گرفت.

در مرحله اول و دوم از توابع کرنل و الگوهای انتخاب شده در قسمت مدل ماشین بردار پشتیبان مستقل در هریک از ایستگاه‌های مورد مطالعه استفاده گردید.

در مرحله سوم برای انتخاب سطح تجزیه مناسب، نوع موجک مورد استفاده در تبدیل موجک به صورت ثابت، ساده‌ترین نوع موجک که همان موجک هار (HAAR) است، در نظر گرفته شد و سپس تاثیر سطوح تجزیه ۱ الی ۷ مورد بررسی قرار گرفت. به عبارت دیگر الگوی ورودی انتخابی در

جدول ۵- نتایج مربوط به پیش‌بینی بارش ماهانه در مرحله واسنجی و صحت‌سنجی به وسیله ماشین بردار پشتیبان تلفیق شده با تبدیل موجک  
Table 5. The results of monthly precipitation prediction in the calibration and validation step by a support vector machine integrated with wavelet transform

مرحله صحت‌سنجی			مرحله واسنجی			ساختار مدل		ایستگاه	
SE (-)	RMSE (mm/month)	r (-)	SE (-)	RMSE (mm/month)	r (-)	سطح تجزیه	موجک	نام	نوع
۰/۰۶۱	۱/۸۲۴	۰/۹۹۹	۰/۰۵۸	۲/۰۵۹	۰/۹۹۹	۲	Dmey	سد اکباتان	
۰/۰۴۵	۱/۶۶۲	۰/۹۹۸	۰/۰۵۴	۲/۲۰۳	۰/۹۹۹	۲	Dmey	مریانج	باران سنجی
۰/۰۵۵	۱/۳۷۸	۰/۹۹۸	۰/۰۵۷	۱/۶۰۴	۰/۹۹۹	۲	Dmey	آق کهریز	
۰/۰۶۷	۲/۳۰۷	۰/۹۹۷	۰/۰۶۵	۲/۳۶۳	۰/۹۹۹	۲	Dmey	آقاجانبلای	

واسنجی و صحت‌سنجی از یکدیگر مجزا شده‌اند. لذا در این حالت سیستم اریب بوده و نتایج پیش‌بینی به واقعیت بسیار نزدیک می‌شود. این در حالی است که در هنگام پیش‌بینی، داده‌های مشاهداتی سال‌های آتی در اختیار نیست تا بتوان سیگنال مورد نظر را از آن خارج نمود. بنابراین در این تحقیق به‌منظور رفع این مشکل، الگوریتم پیش‌بینی به نحوی تنظیم و بازنگری شد، که به هیچ وجه از بارش ماهی که قرار است مورد پیش‌بینی قرار گیرد در فرآیند تجزیه سیگنال استفاده نشود. در این حالت به کلی نتایج تغییر کرده و همانطور که در جدول (۶) ملاحظه می‌شود، نه تنها استفاده از موجک کمکی به پیش‌بینی بارش توسط ماشین بردار پشتیبان نکرد، بلکه دقت پیش‌بینی را نیز به شدت کاهش داد.

بررسی نتایج در دو مرحله واسنجی و صحت‌سنجی حاکی از دقت بسیار بالای مدل ماشین بردار پشتیبان تلفیق شده با تبدیل موجک در پیش‌بینی بارش بوده است. این امر با توجه به ماهیت تصادفی بارش از نظر زمانی و مکانی (۳۳) و با توجه به دلیل عدم قطعیت این پارامتر، خطایی این چنین کم و ضریب همبستگی بسیار بالا نیز دور از انتظار و غیر منطقی به نظر رسیده و در نتیجه اقدام به بررسی دوباره روند پیش‌بینی توسط این مدل، برای رفع مشکل گردید.

بررسی‌های بعدی به وضوح نشان داد که دلیل بروز چنین حالتی، استفاده مدل از داده‌های ماه‌های آینده در تجزیه سیگنال بوده است. در واقع گویی ابتدا کل سیگنال (تمامی داده‌های موجود در دوره آماری) به وسیله موجک مادر و سطح تجزیه مورد نظر تجزیه شده و سپس بخش‌های آموزش،



جدول ۶- نتایج مربوط به پیش‌بینی بارش در مرحله صحت‌سنجی به وسیله ماشین بردار پشتیبان تلفیق شده با تبدیل موجک اصلاح شده  
Table 6. Results of precipitation prediction in the validation step by a support vector machine integrated with modified wavelet transform

نوع ایستگاه	نام ایستگاه	موجک	سطح تجزیه	r (-)	RMSE (mm/month)	SE (-)
باران سنجی	سد اکباتان	Dmey	۲	-۰/۱۹۴	۴۲/۷۷۵	۱/۴۲۹
	مریانج	Dmey	۲	-۰/۲۲۵	۴۵/۴۳۵	۱/۲۲۰
	آق کهریز	Dmey	۲	-۰/۱۸۱	۳۸/۷۹۱	۱/۵۶۱
	آقاجنابلاغی	Dmey	۲	-۰/۲۱۷	۵۱/۵۷۸	۱/۴۹۵

### مدل ARMAX

مدل‌سازی بارش ماهانه توسط این روش، به وسیله ماژول Numxl در نرم‌افزار اکسل و در قالب سه مرحله "یافتن بهترین الگوی ورودی از تاخیرهای زمانی"، "یافتن بهترین ساختار مدل" و "پیش‌بینی" صورت گرفت. مرحله اول مشابه با اولین مرحله در قسمت مدل ماشین بردار پشتیبان انجام شد و آموزش مدل به کمک هریک از الگوهای ورودی ذکر شده در جدول (۳)، صورت گرفته و بعد از پیش‌بینی بارش ماهانه در دوره آماری که برای واسنجی مدل در نظر گرفته شده بود، این الگوهای ورودی به کمک سه شاخص آماری ضریب همبستگی، جذر میانگین مربعات خطا و خطای استاندارد مورد ارزیابی قرار گرفتند. در مرحله اول بهترین الگوی ورودی از تاخیرهای زمانی شناسایی شد و

در همه این الگوها از مدل  $ARMAX(1,1)$  به صورت پیش فرض برای آموزش مدل استفاده شد لذا در مرحله دوم سایر مراتب پارامترهای مدل ARMAX نیز برای الگوی انتخابی مورد ارزیابی قرار گرفت. اما به دلیل واسنجی پارامترهای مدل به دنبال انتخاب مراتب گوناگون، توسط خود برنامه، تفاوت معناداری در نتایج پیش‌بینی حاصل نشد. نتایج مربوط به انتخاب الگوی ورودی و ساختار مناسب در مراحل اول و دوم در ایستگاه‌های مورد مطالعه در جدول (۷) ارائه شده است. و نهایتاً در مرحله آخر بارش ماهانه در ایستگاه‌های مورد مطالعه در دوره آماری که برای صحت‌سنجی مدل در نظر گرفته شده بود، به کمک مدل برازش داده شده در مرحله قبل پیش‌بینی شد. نتایج محاسبه شاخص‌های آماری در مرحله صحت‌سنجی در جدول (۷) آمده است.

جدول ۷- نتایج مربوط به پیش‌بینی بارش در مرحله واسنجی و صحت‌سنجی به وسیله مدل armax  
Table 7. Results of precipitation prediction in the calibration and validation step by the armax model

مرحله صحت سنجی			مرحله واسنجی			ساختار مدل		ایستگاه	
SE (-)	RMSE (mm/month)	r (-)	SE (-)	RMSE (mm/month)	r (-)	ARMAX(p,q)	شماره الگو	نام	نوع
-۰/۹۱۰	۳۷/۲۴۳	-۰/۵۸۶	۱/۰۱۶	۳۵/۹۵۱	-۰/۶۱۴	ARMAX(1,1)	۱۲	سد اکباتان	باران سنجی
-۰/۸۲۹	۳۰/۸۵۹	-۰/۵۶۰	۰/۹۶۹	۳۹/۶۸۸	-۰/۴۹۷	ARMAX(1,1)	۱۲	مریانج	
۱/۰۷۷	۲۶/۷۵۷	-۰/۴۸۷	۱/۲۸۱	۳۵/۹۹۴	-۰/۳۹۵	ARMAX(1,1)	۱۲	آق کهریز	
-۰/۹۹۹	۲۸/۵۷۲	-۰/۵۵۴	۱/۱۱۱	۴۰/۳۲۹	-۰/۵۰۰	ARMAX(1,1)	۱۲	آقاجنابلاغی	

### مدل ARIMA

برای اجرای مدل استوکاستیک ARIMA از نرم‌افزار Minitab(17) استفاده شد. به طور کلی مراحل ساخت مدل‌های سری زمانی فرآیندی چند مرحله‌ای شامل "بررسی روند فصلی بودن داده‌ها"، "بررسی ایستایی داده‌ها در واریانس"، "بررسی ایستایی داده‌ها در میانگین"، "برازش الگو"، "تشخیص صحت الگو" و "پیش‌بینی" می‌باشد، در ادامه مراحل ساخت مدل ARIMA به منظور پیش‌بینی بارش در ایستگاه‌های مورد مطالعه تشریح خواهد شد. در مرحله اول به منظور بررسی روند فصلی بودن داده‌ها، نمودارهای خودهمبستگی (ACF) و خودهمبستگی جزئی (PACF) داده‌های مربوط به بارش در ایستگاه‌های مورد مطالعه رسم گردید و بعد از تشخیص روند فصلی در داده‌ها، از الگوی فصلی مدل ARIMA یا SARIMA در مدل‌سازی استفاده گردید.

در مرحله دوم به منظور بررسی ایستایی سری زمانی این پارامترها در واریانس از تبدیل باکس کاکس استفاده گردید و در صورت وجود نایستایی در سری‌ها، با استفاده از این تبدیل، سری‌های مورد نظر در واریانس ایستا شدند. در مرحله سوم مرتبه مناسب پارامترهای مدل ARIMA ابتدا با حدس اولیه‌ای به وسیله نمودارهای خودهمبستگی و خودهمبستگی جزئی و سپس سعی و خطا در جهت رسیدن به بیشترین مقدار ضریب همبستگی و کمترین مقدار جذر میانگین مربعات خطا، خطای استاندارد و معیار آکائیک در مرحله واسنجی انتخاب گردید که نتایج آن در جدول (۸) ارائه شده است. در مرحله چهارم جهت تشخیص صحت الگوی انتخابی، نمودارهای خودهمبستگی و خودهمبستگی جزئی برای باقی مانده‌های مدل رسم شده و به دنبال آن استقلال و تصادفی بودن باقیمانده‌ها و به بیان دیگر صحت الگوی انتخابی در

مرحله قبل به اثبات رسید. و نهایتاً در مرحله آخر بارش ماهانه در ایستگاه‌های مورد مطالعه به کمک مدل انتخاب و برازش داده شده در مرحله قبل، در دوره آماری که برای صحت‌سنجی مدل در نظر گرفته شده بود، مورد پیش‌بینی قرار گرفت. نتایج محاسبه شاخص‌های آماری در مرحله صحت‌سنجی در جدول (۸) آمده است.

جدول ۸- نتایج مربوط به پیش‌بینی بارش در مرحله واسنجی و صحت‌سنجی به وسیله مدل ARIMA

Table 8. Results of precipitation prediction in the calibration and validation step by the ARIMA model

مرحله صحت سنجی			مرحله واسنجی			ساختار مدل		ایستگاه	
SE (-)	RMSE (mm/month)	r (-)	SE (-)	RMSE (mm/month)	r (-)	AIC	SARIMA (p,d,q)(P,D,Q) <sub>12</sub>	نام	نوع
۰/۸۵۲	۲۵/۴۹۵	۰/۶۶۴	۰/۸۳۳	۳۴/۹۳۹	۰/۶۹۵	-۸۵۶/۹۵۰	SARIMA (1,0,1)(3,0,4) <sub>12</sub>	سد اکیاتان	باران سنجی
۰/۷۳۳	۳۷/۲۸۹	۰/۷۰۱	۰/۸۳۹	۳۱/۳۵۰	۰/۶۵۷	-۷۷۷/۳۵۸	SARIMA (1,0,0)(3,1,3) <sub>12</sub>	مریانج	
۱/۱۱۰	۳۷/۶۰۶	۰/۵۳۵	۰/۹۵۸	۲۶/۴۱۸	۰/۶۱۳	-۸۶۸/۶۶۳	SARIMA (2,0,0)(3,0,3) <sub>12</sub>	آق کهریز	
۰/۹۲۵	۳۱/۹۱۰	۰/۶۴۸	۰/۹۲۹	۲۹/۹۴۴	۰/۶۳۱	-۷۸۱/۵۲۶	SARIMA (1,0,1)(3,1,3) <sub>12</sub>	آقاجانبلای	

همچنین نتایج حاکی از کاهش خطای پیش‌بینی مدل ARIMA نسبت به مدل ARMAX در ایستگاه‌های مذکور به میزان ۱/۲، ۶/۲ و ۸ درصد می‌باشد. نتایج این پژوهش از لحاظ نتایج قابل قبول و رضایت بخش مدل ساریما در زمینه مدل‌سازی و پیش‌بینی بارش ماهانه با نتایج پژوهش‌های کیونجا و همکاران (۱۹) در کنیا، گراهام و میسرا (۱۱) در هندوستان، باری و همکاران (۲) در سیلت بنگلادش، دابرال و همکاران (۹) در هندوستان، صلاحی و ملکی مرشت (۳۰) در اردبیل، حاجی بیگلو و همکاران (۱۲) در بابا امان بجنورد، پاپالاسکاریس و همکاران (۲۸) در کاولا یونان، محمود و همکاران (۲۲) در بنگلادش و چودری و بیزوا (۶) در بنگال مطابقت دارد. همچنین نمودار مقادیر مشاهداتی و مقادیر پیش‌بینی شده بارش توسط مدل ARIMA در شکل (۲) ارائه شده است.

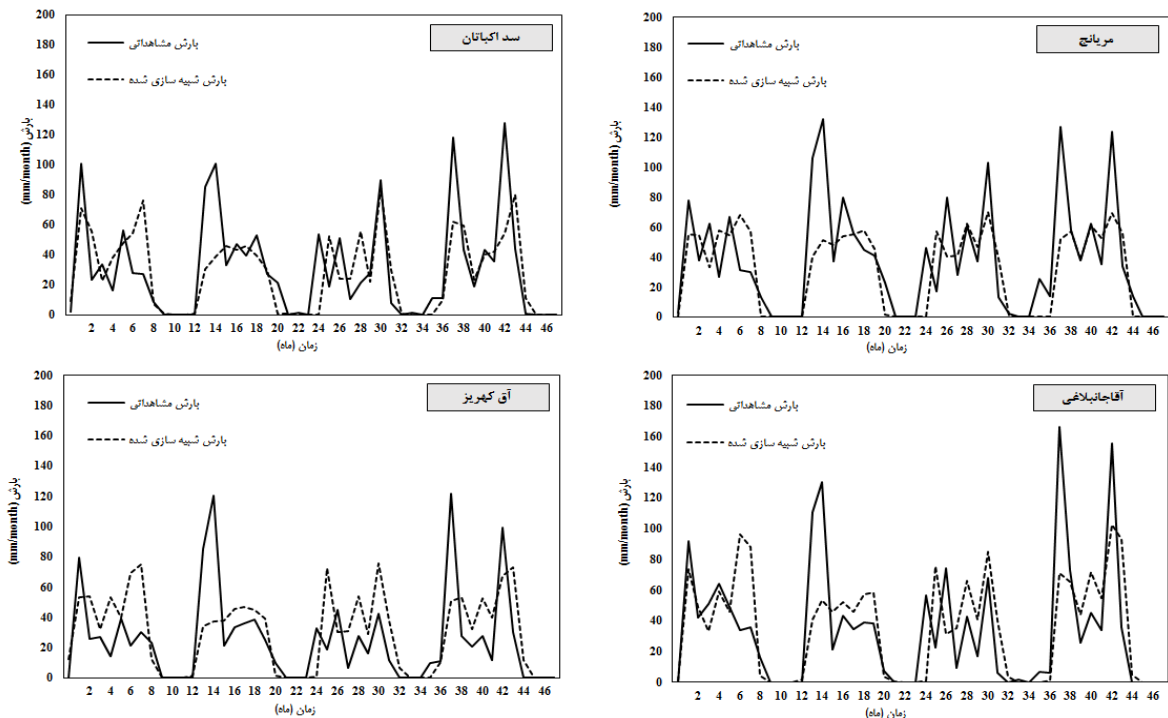
جهت مقایسه بهتر، خلاصه‌ای از نتایج پیش‌بینی بارش ماهانه به کمک مدل‌های مذکور در جدول (۹) ارائه شده است. همانطور که ملاحظه می‌شود مدل ARIMA در ایستگاه سد اکیاتان با  $r=0/664$  و  $RMSE=25/495$  و  $SE=0/852$  ایستگاه مریانج با  $r=0/701$  و  $RMSE=37/289$  و  $SE=0/733$  ایستگاه آق کهریز با  $r=0/535$  و  $RMSE=37/606$  و  $SE=1/110$  ایستگاه آقاجانبلای با  $r=0/648$  و  $RMSE=31/910$  و  $SE=0/925$  پس از آن مدل‌های ماشین بردار پشتیبان (SVM)، ARMAX و ماشین بردار پشتیبان تلفیق شده با تبدیل موجک (W-SVM) در رتبه‌های دوم تا چهارم قرار دارند. مقایسه شاخص‌های آماری نشان می‌دهد که مدل ARIMA توانسته است خطای پیش‌بینی را نسبت به مدل SVM در ایستگاه‌های سد اکیاتان، مریانج، آق کهریز و آقاجانبلای به ترتیب به میزان ۴/۶، ۳/۴، ۴/۷ و ۰/۲ درصد کاهش دهد.

جدول ۹- خلاصه نتایج پیش‌بینی بارش ماهانه در ایستگاه‌های مورد مطالعه

Table 9. Summary results of Monthly Precipitation prediction at Study Stations

آقاجانبلای			آق کهریز			مریانج			سد اکیاتان			مدل
SE	RMSE	r	SE	RMSE	r	SE	RMSE	r	SE	RMSE	r	
۰/۹۲۷	۳۱/۹۸۰	۰/۶۲۷	۱/۱۵۷	۲۸/۷۳۴	۰/۴۴۸	۰/۷۶۷	۲۸/۵۷۶	۰/۶۴۰	۰/۸۹۸	۲۶/۸۷۸	۰/۶۰۱	SVM
۱/۴۹۵	۵۱/۵۷۸	۰/۲۱۷	۱/۵۶۱	۳۸/۷۹۱	۰/۱۸۱	۱/۲۲۰	۴۵/۴۳۵	۰/۲۲۵	۱/۴۲۹	۴۲/۷۷۵	۰/۱۹۴	W-SVM
۰/۹۹۹	۲۸/۵۷۲	۰/۵۵۴	۱/۰۷۷	۲۶/۷۵۷	۰/۴۸۷	۰/۸۲۹	۳۰/۸۵۹	۰/۵۶۰	۰/۹۱۰	۳۷/۲۴۳	۰/۵۸۶	ARMAX
۰/۹۲۵	۳۱/۹۱۰	۰/۶۴۸	۱/۱۱۰	۳۷/۶۰۶	۰/۵۳۵	۰/۷۳۳	۳۷/۲۸۹	۰/۷۰۱	۰/۸۵۲	۲۵/۴۹۵	۰/۶۶۴	ARIMA





شکل ۲- مقایسه بارش مشاهداتی و پیش‌بینی شده توسط مدل ARIMA در مرحله صحت‌سنجی در ایستگاه‌های باران سنجی مورد مطالعه  
Figure 2. Comparison of observed and predicted precipitation by ARIMA model at validation step at the studied stations

مقادیر پیش‌بینی شده باشیم که این امر به هیچ وجه ناشی از خطا در انجام مراحل و یا عدم توانایی مدل‌های مذکور در پیش‌بینی نبوده و شرایط اقلیمی ایستگاه‌های مورد مطالعه به عنوان یک پارامتر مهم می‌تواند این موضوع را تحت الشعاع قرار دهد. کما اینکه در اقلیم‌های پر باران مدل‌های مورد استفاده نتایج بهتری را نشان می‌دهند.

علیرغم نتایج قابل قبول ارائه شده از پیش‌بینی بارش با استفاده از تبدیل موجک به عنوان یک پیش پردازش کننده اطلاعات در پژوهش‌های صورت گرفته تاکنون، این تبدیل نتوانست هیچ کمکی به مدل‌سازی بارش توسط ماشین بردار پشتیبان در شرایط واقعی کند که دلیل آن به صورت مفصل در قسمت بحث و نتایج بیان شده است. به نظر می‌رسد در تعداد زیادی از پژوهش‌هایی که تاکنون پیرامون این موضوع صورت گرفته است و روند تجزیه سیگنال به صورت یکجا برای کل دوره آماری مورد استفاده اعم از دوره واسنجی و صحت سنجی انجام شده است این مشکل وجود داشته است. گزارش مقادیر خطای پیش‌بینی به شدت ناچیز و همبستگی فوق العاده بالای مقادیر مشاهداتی و پیش‌بینی شده توسط این پژوهش‌ها می‌تواند دلیلی بر این ادعا باشد.

اگرچه از نظر مقایسه نتایج، مدل آریمای نسبت به مدل ماشین بردار پشتیبان از دقت بیشتری در پیش‌بینی بارش برخوردار بوده است اما به جرات می‌توان گفت که مدل ماشین بردار پشتیبان به دلیل داشتن پارامترهای قابل تنظیم کمتر نسبت به مدل آریمای، با سهولت بیشتر و در زمان کمتری قادر به پیش‌بینی بوده و از این نظر نسبت به سایر روش‌ها ارجحیت دارد.

به منظور مقایسه دقت و کارایی مدل‌های مذکور در پیش‌بینی بارش ماهانه در ایستگاه‌های باران‌سنجی سد اکباتان، مریانج، آق کهریز و آقاجانبلاغی پس از مدل‌سازی و آموزش هریک از این مدل‌ها، شاخص‌های آماری مورد نظر محاسبه شده و بر این اساس می‌توان نتایج حاصل از این پژوهش، در رابطه با پیش‌بینی بارش را به صورت زیر مطرح نمود:

در بین روش‌های پیش‌بینی مورد مطالعه، در مجموع و در تمامی ایستگاه‌های مورد مطالعه، به ترتیب مدل‌های ARIMA، ماشین بردار پشتیبان (SVM)، ARMAX و ماشین بردار پشتیبان تلفیق شده با تبدیل موجک (W-SVM) در رتبه‌های اول تا چهارم قرار دارند.

پس از مقایسه شاخص‌های آماری بصورت کمی، اختلاف بین شاخص‌های محاسبه شده از حیث معناداری آماری نیز مورد بررسی قرار گرفت. به این منظور از آزمون آنالیز واریانس (Anova) در نرم‌افزار اکسل استفاده شد. محاسبه آماره F در این آزمون نشان داد که برخلاف مقایسه کمی نتایج، شاخص‌های آماری برآورد شده مربوط به مدل‌های ARIMA، SVM و ARMAX دارای تفاوت‌های معناداری با یکدیگر نیستند و از این نظر می‌توان این سه مدل را در یک سطح از دقت قرار داد. تنها تفاوت معنادار بین شاخص‌های آماری هنگامی مشاهده شد که یکی از این سه مدل با مدل W-SVM مورد مقایسه قرار می‌گرفت که البته این اختلاف در نتایج کمی هم بسیار محسوس بود.

در برخی از پژوهش‌های صورت گرفته پیرامون پیش‌بینی بارش با استفاده از مدل‌های پیش‌بینی مورد استفاده در این پژوهش، ممکن است گاهی شاهد مقادیر کمتری از خطا در

منابع

1. Abebe, A.J., D.P. Solomatine and R.G.W. Venneker. 2000. Application of adaptive fuzzy rule-based models for reconstruction of missing precipitation events. *Hydrological Sciences Journal*, 45(3): 425-436.
2. Bari, S.H., M.T. Rahman, M.M. Hussain and S. Ray. 2015. Forecasting Monthly Precipitation in Sylhet City Using ARIMA Model. *Civil and Environmental Research*, 7(1): 69-77.
3. Behzad, M., K. Asghari and E.A. Coppola. 2010. Comparative Study of SVMs and ANNs in Aquifer Water Level Prediction, *Journal of Computing in Civil Engineering*, 24(5): 408-413.
4. Cannas, B., A. Fanni and G. Sias. 2005. River flow forecasting using neural networks and wavelet analysis. *Geophysical Research Abstracts*, Vol. 7, SRef-ID: 1607-7962/gra/EGU05-A-08651.
5. Cannas, B., A. Fanni, L. See and G. Sias. 2006. Data preprocessing for river flow forecasting using neural networks, Wavelet transforms and data partitioning. *Physics and Chemistry of the Earth* 31(18): 1164-1171.
6. Chowdhury, A. and A. Biswas. 2016. Development of a Monthly Rainfall Prediction Model Using Arima Techniques in Krishnanagar Sub-Division, Nadia District, West Bengal. *International Journal of Engineering Studies and Technical Approach*, 2(2): 18-26.
7. Coulibaly, F. and N.D. Evora. 2007. Comparison of neural network methods for infilling missing daily weather records. *Journal of Hydrology*, 341: 27-41.
8. Cristianini, N. and J. Shawe-Taylor. 2000. *An Introduction to Support Vector Machines* Cambridge University Press, New York, USA.
9. Dabral, P.P., T. Saring and D. Jhaharia. 2016. Time Series Models of Monthly Rainfall and Temperature to Detect Climate Change for Jorhat (Assam), India. *Global NEST Journal*, 18: 1-14
10. Dehghani, R., M.A. Ghorbani, M. TeshnehLab, A. Rikhtehgar gheasi and E. Asadi. 2015. Comparison and evaluation of bayesian neural network, gene expression programming, support vector machine and multiple linear regression in river discharge estimation (case study: Sufi Chay Basin). *Iranian of Irrigation & Water Engineering*, 5(20): 66-85 (In Persian).
11. Graham, A. and E.P. Mishra. 2017. Time series analysis model to forecast rainfall for Allahabad region. *Journal of Pharmacognosy and Phytochemistry*, 6(5): 1418-1421.
12. Hajibigloo, M., A. Ghazalsoflo and H. Alimirzaee. 2013. Discussion and Forecast Monthly Average Rainfall Techniques Using SARIMA (Case study: Pluviometry Station Babaaman Bojnourd). *Journal of Irrigation Science and Engineering*, 36(3): 41-54 (In Persian).
13. Hamel, L. 2009. *Knowledge Discovery with Support Vector Machines*, Hoboken, N.J. John Wiley.
14. Hamidi, O., J. Poorolajal, M. Sadeghifar, H. Abbasi, Z. Maryanaji, H.R. Faridi and L. Tapak. 2014. A comparative study of support vector machines and artificial neural networks for predicting precipitation in Iran. *Theoretical and Applied Climatology*, 119: 723-731
15. Isazadeh, M., H. Ahmadzadeh and M.A. Ghorbani. 2018. Assessment of Normalization of Monthly Runoff Probabilistic Distribution impact on SVM and ANN Models Performance in Monthly River Flows Simulation (A Case Study: ZarrinehRud River Basin). *Journal of Watershed Management Research*, 8(16): 22-33 (In Persian).
16. Isazadeh; M., H. Ahmadzadeh and M.A. Ghorbani. 2016. Assessment of kernel functions performance in river flow estimation using support vector machine. *Journal of Water and Soil Conservation*, 23(3): 69-89 (In Persian).
17. Karamouz, M. and S. Araghinejad. 2005. *Advanced Hydrology*. 2<sup>nd</sup> edn., Tehran Polytechnic Press, Tehran, Iran, 464.
18. Khosravi, M. and H. Shakiba. 2010. Precipitation forecasting using artificial neural networks in order to flood management. 4th International Congress of the Islamic Word Geographers (In Persian).
19. Kibunja, H.W., J.M. Kihoro, G.O. Orwa and W.O. Yodah. 2014. Forecasting Precipitation Using SARIMA Model: A Case Study of Mt. Kenya Region. *Mathematical Theory and Modeling*, 4(11): 50-58.
20. Kisi, O. 2009. Neural networks and wavelet conjunction model for intermittent streamflow forecasting. *J. of Hydrologic Engineering*, 14(8): 773-782.
21. Kisi, O. and M. Cimen. 2012. Precipitation forecasting by using wavelet-support vector machine conjunction model. *Engineering Applications of Artificial Intelligence*, 25(4): 783-792.
22. Mahmud, I., S.H. Bari and M. Rahman. 2017. Monthly rainfall forecast of Bangladesh using autoregressive integrated moving average method. *Environmental Engineering Research*, 22(2): 162-168.
23. Manzour, D. and M. Yadi Pour. 2016. Studying the Iranian Electricity Market Price with an ARMAX-GARCH Mode Quarterly. *Journal of Quantitative Economics*, 13(1): 97-117.
24. Merry, R.J.E. 2005. *Wavelet Theory and Applications*. A literature study. Eindhoven University of Technology Department of Mechanical Engineering Control Systems Technology Group.

25. Mozafari, Gh.A., Sh. Shafiee and H.R. Hemati. 2016. Predicting monthly precipitation of Kermanshah synoptic station using the hybrid model of neural network and wavelet. *Journal of Water and Soil Conservation (Journal of Agricultural Sciences and Natural Resources)* 22(6): 135-152 (In Persian).
26. Najafi, A., S. Azizi Ghalati and M.H. Mokhtari. 2017. Assessment Kernel Support Vector Machines in Classification of Landuses (Case Study: Basin of Cheshmeh kileh-Chalkrod). *Journal of Watershed Management Research*, 8(15): 92-101 (In Persian).
27. Omidi, R., F. Radmanesh and H. Zarei. 2014. River flow predicting using stochastic models. *The First National Conference on Challenges on Water Resources and Agriculture, Esfahan* (In Persian).
28. Papalaskaris, T., T. Panagiotidis and A. Pantrakis. 2016. Stochastic Monthly Rainfall Time Series Analysis, Modeling and Forecasting in Kavala City, Greece, North-Eastern Mediterranean Basin. *Procedia Engineering*, 162: 254-263.
29. Rostami, M., A. Facheri Fard, M.A. Ghorbani, S. Darbandi and Y. Dinpajoh. 2012. River flow forecasting using wavelet analysis. *Irrigation Sciences and Engineering (Jise) (Scientific Journal of Agriculture)*, 35(2): 73-81 (In Persian).
30. Salahi, B. and R. Maleki Meresht. 2016. Forecasting and Analysis of Monthly Rainfalls in Ardabil Province by Arima, Autoregressive, and Winters Models. *Journal of Water and Soil*, 29(5): 1391-1450 (In Persian).
31. Shafaei, M., J. Adamowski, A. Fakheri-Fard, Y. Dinpashoh and K. Adamowski. 2016. A wavelet-SARIMA-ANN hybrid model for precipitation forecasting. *Journal of Water and Land Development*, 28(1): 27-36.
32. Shenify, M., A.S. Danesh, M. Gocić, R. Surya Taher, A.W. Abdul Wahab, A. Gani, S. Shamshirband and D. Petković. 2015. Precipitation Estimation Using Support Vector Machine with Discrete Wavelet Transform. *Water Resources Management*, 30(2): 641-652.
33. Toufani, P., A. Mosaedi and A. Fakheri Fard. 2011. Prediction of precipitation applying wavelet network model (case study: Zarringol station, Golestan province, Iran). *Journal of Water and Soil (Agricultural Sciences and Technology)*, 25(5): 1217-1226 (In Persian).

## Evaluation of the Efficiency of Linear and Nonlinear Models in Predicting Monthly Rainfall (Case Study: Hamedan Province)

Hamed Nozari<sup>1</sup> and Fatemeh Tavakoli<sup>2</sup>

---

1- Associate Professor, Water Engineering and Science Department, Bu-Ali Sina University,  
(Corresponding author: h.nozari@basu.ac.ir)

2- PhD Student Water Engineering and Science Department, Bu-Ali Sina University

Received: April 13, 2018                      Accepted: January 5, 2019

---

### Abstract

In this research, we used the support vector machine (SVM), support vector machine combine with wavelet transform (W-SVM), ARMAX and ARIMA models to predict the monthly values of precipitation. The study considers monthly time series data for precipitation stations located in Hamedan province during a 25-year period (1998-2016). The 25-year simulation period was divided into 17 years for training, 4 years for calibration and 4 years for validation. Statistical comparison of the results was done by using correlation coefficient ( $r$ ), root mean square error (RMSE), and standard error (SE). Results showed that ARIMA, Support Vector Machines, ARMAX and support vector machine combine with wavelet transform were ranked first to fourth, respectively. Furthermore, the support vector machine has fewer adjustable parameters than other models. So, the model is able to predict precipitation with greater ease and less time. For this reason, it is preferable to other methods.

**Keywords:** ARIMA, ARMAX, Precipitation, Prediction, Support Vector Machine, Wavelet