تحقیقات منابع آب ایران
Iran-Water Resources Research

سال یازدهم، شماره ۲، پائیز ۱۳۹۴
Volume 11, No. 2, Fall 2015 (IR-WRR)
۱۴۶-۱۵۰

یادداشت فنی

# مدل‌سازی بارش-رواناب با استفاده از مدل‌های هوشمند هیبریدی

محمدعلی قربانی[۱]، عاطفه ازانی[۲*]
و سمیه محمودی وانعلیا[۲]

## چکیده

بارش-رواناب یکی از فرایندهای مهم در مطالعات منابع آب بشمار می‌رود. در این تحقیق فرآیند بارش-رواناب روزانه در حوضه آبریز بالیخلوچای با استفاده از ماشین بردار پشتیبان، شبکه‌های عصبی مصنوعی، هیبرید موجک-ماشین بردار پشتیبان و هیبرید موجک-شبکه عصبی مورد مطالعه و مقایسه قرار گرفته است. داده‌های بارش-رواناب روزانه در طول دوره آماری (۱۳۷۹-۱۳۸۷) برای آموزش و صحت‌سنجی مدل‌ها مورد استفاده قرار گرفت. در حالت کلی نتایج حاکی از دقت قابل قبول هر چهار روش می‌باشد. از لحاظ اولویت نیز مدل هیبرید موجک-شبکه عصبی با بیشترین دقت و کمترین خطا در اولویت اول و مدل‌های هیبرید موجک-ماشین بردار پشتیبان، شبکه عصبی مصنوعی و ماشین بردار پشتیبان بترتیب در اولویت‌های بعدی قرار گرفتند.

***کلمات کلیدی:*** بارش-رواناب، تبدیل موجک، شبکه عصبی مصنوعی، ماشین بردار پشتیبان، هیبرید.

تاریخ دریافت مقاله: ۹۳/۴/۲۴
تاریخ پذیرش مقاله: ۹۳/۹/۳

۱- دکتری منابع آب، دانشیار گروه مهندسی آب، دانشگاه تبریز، تبریز، ایران.
۲-دانشجوی سابق کارشناسی ارشد، گروه مهندسی آب، دانشگاه تبریز، تبریز، ایران.
*- نویسنده مسئول

**Technical Note**

# Rainfall-Runoff Modeling Using Hybrid Intelligent Models

*M.A. Ghorbani [1] , A. Azani [2]**
*and S. Mahmoudi Vanolya [2]*

## Abstract

Rainfall-Runoff is considered one of the most important processes in water resources studies. In this study, to simulate the daily rainfall-runoff process of Balikhluchay Basin, four hybrid models of Support Vector Machine, Artificial Neural Networks, Wavelet-Support Vector Machine, and Wavelet-Neural Networks have been applied and compared. Daily Rainfall-runoff data for the period of 2000 to 2008, have been used for training and testing the models. In general, the results indicated acceptable accuracy of all the models. In terms of priority, the hybrid model of Wavelet-Neural Network with the highest accuracy and lowest errors was in the first rank and the Hybrid models of Wavelet-Support Vector Machines, Artificial Neural Networks and Support Vector Machines, were in next priorities.

***Keywords:*** Rainfall-Runoff, Wavelet Transform, Artificial Neural Networks, Support Vector Machines, Hybrid

Received: July 15, 2014
Accepted: November 24, 2014

1- Associate Professor, Department of Water Engineering, University of Tabriz, Tabriz, Iran Email: Ghorbani@tabrizu.ac.ir
2-MS.c graduate student, Department of Water Engineering, University of Tabriz, Tabriz, Iran
*- Corresponding Author

## ۱- مقدمه

در دهه‌های اخیر، پیش‌بینی و مدل‌سازی جریان رودخانه‌ها به منظور برنامه‌ریزی و مدیریت منابع آب بسیار حائز اهمیت بوده‌است. خاصیت غیرخطی فرآیند بارش-رواناب و پیچیده بودن مدل‌های فیزیکی از دلایلی است که باعث شده محققان به سوی مدل‌های هوشمند رو آورند. مطالعات متعددی در زمینه مدل‌سازی فرایند بارش- رواناب صورت گرفته است. اسکندری‌نیا (۱۳۸۷)، از شبکه عصبی مصنوعی برای برآورد دبی رودخانه بختیاری استفاده نمود. وی با به‌کارگیری شبکه پرسپترون چند لایه (MLP)[1] در مدل‌سازی بارش-رواناب به این نتیجه رسید که با اضافه نمودن بارش روزهای قبل به ورودی مدل بهبود قابل توجهی در نتایج حاصل می‌گردد. نصری و همکاران (۱۳۸۸) از مدل شبکه عصبی مصنوعی چندلایه به‌منظور پیش‌بینی رواناب روزانه حوضه آبریز پلاسجان زاینده‌رود استفاده نمودند. در نتیجه این تحقیق شبکه عصبی مصنوعی با چهار لایه مخفی عملکرد بهتری به‌همراه داشت. طوفانی و همکاران (۱۳۹۰) تبدیل موجک را در جهت پیش‌بینی بارندگی ماهانه ایستگاه زرینگل به‌کار گرفتند. نتایج همبستگی بالایی را میان داده‌های مشاهداتی و محاسباتی نشان داد. میسرا و همکاران (۲۰۰۹) با مقایسه مدل ماشین بردار پشتیبان با شبکه عصبی مصنوعی به پیش‌بینی رواناب و بار رسوب در هند پرداختند. نتایج نشان داد ماشین بردار پشتیبان هم در زمینه پیش‌بینی رواناب و هم بار رسوب نسبت به شبکه عصبی مصنوعی دارای عملکرد بهتری می‌باشد. آداموسکی (۲۰۱۳) با مقایسه ماشین بردار پشتیبان و شبکه عصبی مصنوعی در مدل‌سازی بارش- رواناب حوضه کوهستانی دهرادان در یوتارانچال هندوستان، با محاسبه معیارهای R، RMSE، Slope، Intercept، MBE و EF توانایی مدل ماشین بردار پشتیبان در پیش‌بینی رواناب مستقیم، جریان پایه و جریان کل این منطقه را نتیجه گرفتند. افزون بر مطالعات ذکر شده می‌توان به تحقیقات انجام شده توسط نوری و همکاران (۱۳۸۹) و لفدانی و همکاران (۲۰۱۳) با هدف پیش بینی رواناب اشاره کرد.

لذا با توجه به موارد فوق هدف از این تحقیق، بررسی عملکرد مدل ماشین بردار پشتیبان درکنار مدل شبکه عصبی مصنوعی و توسعه مدل‌ها از طریق هیبرید آنها با تبدیل موجک، به منظور مدل‌سازی بارش- رواناب روزانه رودخانه بالیخ‌لوچای، یکی از سرشاخه‌های مهم و دائمی رودخانه قره‌سو در شمال‌غرب کشور می‌باشد.

## ۲- مواد و روش‌ها

### ۲-۱- منطقه مورد مطالعه و اطلاعات مورد استفاده

حوضه آبریز بالیخ‌لوچای در جنوب‌غربی شهرستان اردبیل با مساحتی بالغ بر ۱۰۴۴ کیلومترمربع، ۶ درصد از سطح استان را به خود اختصاص داده است. رودخانه اصلی این واحد به طول ۶۸ کیلومتر می‌باشد. موقعیت حوضه بالیخ‌لوچای و ایستگاه پل الماس با طول جغرافیایی ′۱۱ °۴۸ و عرض جغرافیایی □۰۸ °۳۸ در شکل ۱ نشان داده شده است. داده‌های بارش-رواناب روزانه این ایستگاه از شرکت آب منطقه‌ای استان اردبیل مربوط به بازه زمانی ۹ ساله (از سال ۱۳۷۹و تا سال ۱۳۸۷) اخذ گردیده که خصوصیات آماری بارش و رواناب روزانه این ایستگاه در بازه زمانی مورد مطالعه در جدول ۱ ارائه شده است.

### ۲-۲- ماشین بردار پشتیبان

ماشین بردار پشتیبان[2] یک سیستم یادگیری کارآمد بر مبنای تئوری بهینه‌سازی مقید است. هدف پیدا کردن فرم تابعی برای $f(x)$ است.

$$f(x) = W^T.\emptyset(x) + b \qquad (۱)$$

بردار ضرایب $W$ و ثابت $b$ و تابع کرنل $\emptyset$ در این رابطه با حل مسأله بهینه‌سازی محدب و با استفاده از روش لاگرانژین و اصل کمینه-سازی خطای ساختاری بدست می‌آیند.

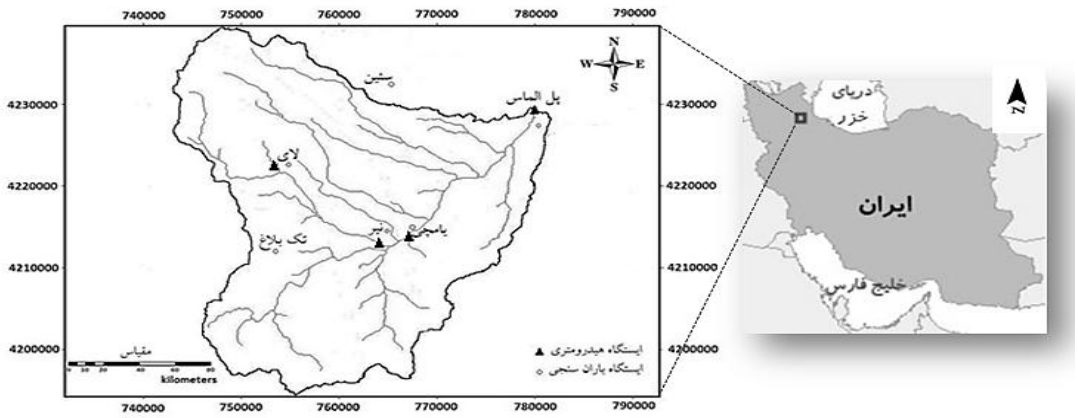


**شکل ۱- موقعیت ایستگاه پل الماس در حوضه بالیخ‌لوچای**

**جدول ۱- خصوصیات آماری بارش و رواناب روزانه پل الماس طی دوره آماری (۱۳۸۷- ۱۳۷۹)**

| داده | واحد | تعداد | حداقل | میانگین | حداکثر | انحراف معیار | چولگی |
|---|---|---|---|---|---|---|---|
| بارش | $mm$ | ۳۲۸۱ | ۰/۰۰ | ۱/۰۷ | ۲۶/۶۴ | ۲/۷۹ | ۴/۰۶ |
| رواناب | $m^3/s$ | ۳۲۸۱ | ۰/۰۰ | ۲/۲۲ | ۳۳/۰۰ | ۲/۲۰ | ۳/۴۹ |

در مطالعات بارش-رواناب عمدتاً از تابع RBF استفاده می‌شود زیرا ماشین بردار پشتیبان با این نوع تابع در مقایسه با سایر توابع از دقت بیشتری در شبیه‌سازی این پدیده برخوردار است (اسکندری و همکاران، ۱۳۸۹، Adamowski 2013; Misra et al., 2009 ) ، که رابطه آن به صورت (۲) می‌باشد.

$$K(x, x_i) = exp(-\frac{\|x-x_i\|^2}{\sigma^2}) \quad (۲)$$

برای انجام فرایند محاسبات کدی در محیط متلب نوشته شده است.

### ۲-۳- شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی بر اساس استنباط از سیستم عصبی بیولوژیکی استوار است. این شیوه از ساختاری نرونی و هوشمند با الگوبرداری مناسب از نرون‌های موجود در مغز انسان سعی می‌کند تا از طریق توابع تعریف شده ریاضی رفتار درون‌سلولی نرون‌های مغز را شبیه‌سازی کند (نوری و همکاران، ۱۳۸۶).

این مدل بر اساس یادگیری فرآیند حل مسئله و به عبارتی رسیدن به خروجی از طریق یافتن رابطه نهفته در فرآیند مورد نظر کار می‌کند. در میان نمونه‌های متعدد شبکه‌های عصبی، شبکه انتشار به عقب دارای کاربرد بیشتری می‌باشد (Lippman, 1987).

### ۲-۴- هیبرید موجک- ماشین بردار پشتیبان

تبدیل موجک یکی از تبدیل‌های ریاضی کارآمد در زمینه پردازش سیگنال است. موجک‌ها توابع ریاضی هستند که شکل مقیاس[۳]- زمان از سری‌های زمانی و روابط آنها را جهت آنالیز سری‌های زمانی ارائه می‌دهد. تحلیل موجکی قادر به نمایش جنبه‌های مختلف داده‌های متفاوت، نقاط شکست و ناپیوستگی‌ها می‌باشد (طوفانی و همکاران، ۱۳۹۰).

در مدل هیبرید موجک- ماشین بردار پشتیبان ابتدا آنالیز سری زمانی بوسیله تبدیل موجک صورت گرفته، سپس زیر سری‌ها به عنوان ورودی ماشین بردار پشتیبان درنظر گرفته می‌شوند.

### ۲-۵- هیبرید موجک- شبکه عصبی

به منظور طراحی یک شبکه عصبی موجکی می‌توان تابع محرک شبکه عصبی و موجک را جایگزین کرد. در صورتی که یک شبکه ساده با ورودی و خروجی منفرد در نظر گرفته شود، شبکه عصبی موجکی هر ورودی مانند $t$ را توسط ترکیبی از موجک‌های دختر که به واسطه مقیاس و انتقال موجک مادر به وجود آمده‌اند، تقریب می‌زند (نوری و همکاران، ۱۳۸۶). در این حالت خروجی شبکه موجکی از رابطه (۳) محاسبه می‌شود.

$$y(t) = \sum_{k=1}^{K} w_k \,.\, h_{a,b}(t) \quad (۳)$$

در این رابطه y(t) مقدار خروجی شبکه موجکی، $h_{a,b}(t)$ موجک دختر انتخاب شده، $w_k$ وزن‌های شبکه و $K$ تعداد نرون‌های شبکه است. در این تحقیق از معیارهای پرکاربرد در مهندسی آب شامل ضریب همبستگی[۴] $(R)$، ریشه میانگین مربعات خطا[۵] $(RMSE)$ و معیار نش ساتکلیف[۶] $(E)$ و بایاس[۷] که کم‌تخمینی و بیش‌تخمینی مدل را نشان می‌دهد، معیار جدید اختلاف شیب[۸] $(Sdiff)$، که اختلاف شیب خط برازش نمودار پراکنش مدل‌ها با خط نیمساز (۱:۱) را نشان می‌دهد (Misra et al., 2009) نیز استفاده گردید.

## ۳- نتایج و تحلیل نتایج

### ۳-۱- ساختار مدل

یکی از مهمترین مراحل در مدل‌سازی، انتخاب الگوی مناسبی از متغیرهای ورودی است. از این رو ابتدا ۱۵ الگو مورد بررسی قرار گرفت (جدول ۲). همچنین از داده‌های هواشناسی و هیدرومتری حوضه از ۳۲۸۲ رکورد ثبت شده طی بازه زمانی (۱۳۸۶-۱۳۷۹)، تعداد ۲۶۲۶ رکورد برای آموزش و تعداد ۶۵۶ رکورد باقی مانده برای صحت‌سنجی در نظر گرفته شد.

### ۳-۲- نتایج حاصل از مدل‌ها

برای مدل ماشین بردار پشتیبان تابع پایه شعاعی انتخاب گردید و مقادیر بهینه پارامترهای مورد نیاز مدل شامل $c$، $\sigma$ و $\varepsilon$ با استفاده از روش بهینه‌سازی سیمپلکس غیرخطی (Nelder and Mead, 1964) برابر ۶/۵۵۴، ۱۸/۹۷۶ و ۰/۰۰۱ بدست آمد. با توجه به نتایج ترکیب شماره (۶) به‌عنوان بهترین

**جدول ۲- الگوهای مختلف ورودی به مدل‌ها**

| ردیف | الگوها | ردیف | الگوها | خروجی |
|---|---|---|---|---|
| 1 | *P(t)* | 9 | *Q(t-1) Q(t-2)P(t) P(t-1)P(t-2)* | *Q(t)* |
| 2 | *P(t)P(t-1)* | 10 | *Q(t-1) Q(t-2) Q(t-3)P(t)* | *Q(t)* |
| 3 | *P(t) P(t-1)P(t-2)* | 11 | *Q(t-1) Q(t-2) Q(t-3)P(t)P(t-1)* | *Q(t)* |
| 4 | *Q(t-1)P(t)* | 12 | *Q(t-1) Q(t-2) Q(t-3)P(t) P(t-1)P(t-2)* | *Q(t)* |
| 5 | *Q(t-1)P(t)P(t-1)* | 13 | *Q(t-1) Q(t-2) Q(t-3)Q(t-4)P(t)* | *Q(t)* |
| 6 | *Q(t-1)P(t) P(t-1)P(t-2)* | 14 | *Q(t-1) Q(t-2) Q(t-3)Q(t-4)P(t)P(t-1)* | *Q(t)* |
| 7 | *Q(t-1) Q(t-2)P(t)* | 15 | *Q(t-1) Q(t-2) Q(t-3)Q(t-4)P(t) P(t-1)P(t-2)* | *Q(t)* |
| 8 | *Q(t-1) Q(t-2)P(t)P(t-1)* | | | *Q(t)* |

ترکیب انتخاب گردید، در شبکه عصبی مصنوعی از شبکه پرسپترون سه لایه با تعداد نرون‌های متفاوت و تابع تانژانت سیگموئید (متداول‌ترین شکل از توابع محرک) استفاده گردید. تعداد تکرارهای لازم در فرایند یادگیری شبکه ۱۰۰۰ در نظر گرفته شده است. تعداد نرون‌های موجود در لایه پنهان مدل‌های مختلف با سعی و خطا (۱ تا ۲۰ نرون) در جهت کاهش مقدار خطا مشخص گردید. در مدل هیبرید موجک-ماشین بردار پشتیبان، ترکیب بهینه مدل ماشین بردار پشتیبان انتخاب گردید. در روش‌های هیبریدی ابتدا با استفاده از آنالیز موجکی سری داده‌ها به سه زیر سری تجزیه و و موجک دابچیز[9] نوع چهار به‌عنوان پرکاربردترین موجک مادر (اعلمی و همکاران، ۱۳۹۳) انتخاب گردید. زیرسری‌های حاصل بعنوان ورودی ماشین بردار پشتیبان با تابع پایه شعاعی در نظر گرفته شد. به‌منظور مدل‌سازی جریان با استفاده از مدل هیبرید موجک-شبکه عصبی، نیز نتیجه بهینه مدل شبکه عصبی مصنوعی مورد توجه قرارگرفت.

نتایج نهایی مدل‌ها در جدول ۳ که به ترتیب اولویت از نظر دقت در مدل‌سازی بارش-رواناب می‌باشد علاوه بر تائید قابلیت هر چهار مدل، نشان از برتری مدل هیبرید موجک-شبکه عصبی با ضریب همبستگی ۰/۹۳۶، معیار بایاس ۰/۰۰۳ $m^3/s$، ریشه میانگین مربعات خطا ۰/۲۸۲ $m^3/s$، ضریب نش‌ساتکلیف ۰/۸۷۵ و اختلاف شیب ۰/۱۵۷ نسبت به سایر روش‌ها دارد. با وجود آنکه ماشین بردار پشتیبان نسبت به شبکه عصبی مصنوعی دقت کمتری داشته است، مدل هیبرید موجک- ماشین بردار پشتیبان با اختصاص دقت بیشتر نسبت به شبکه عصبی مصنوعی، عملکرد بهتری داشته است. این افزایش دقت می‌تواند به دلیل ترکیب قابلیت‌های برتر دو مدل به کار گرفته شده بعنوان مدل هیبرید باشد. چرا که با تبدیل موجک از طریق تجزیه کامل سری به مؤلفه‌های تشکیل دهنده آن، موج اصلی هموارتر و در نتیجه سری پیچیده به سری ساده تبدیل می‌شود و با این کار آنالیز راحت‌تر صورت می‌گیرد. بنابراین علاوه بر مدل هیبرید موجک-شبکه عصبی، ترکیب مدل ماشین بردار پشتیبان با آنالیز موجکی یک ایده جدید به منظور ایجاد مدلی توانمند می‌باشد. نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی و محاسباتی دبی، در محل پل الماس مربوط به مدل بهینه موجک- شبکه عصبی در مرحله صحت‌سنجی ترسیم گردیده است (شکل۲). در این شکل دیده می‌شود که مدل هیبرید موجک-شبکه عصبی اختلاف شیب کمی با خط نیمساز دارد. توانایی بالای این مدل در شبیه‌سازی بارش-رواناب ایستگاه پل الماس نیز قابل استنتاج می‌باشد.

## ۳-۳- نتیجه‌گیری

در این تحقیق پس از شبیه‌سازی بارش- رواناب روزانه ایستگاه پل الماس با استفاده از مدل‌های ماشین بردار پشتیبان با تابع کرنل پایه شعاعی و شبکه عصبی مصنوعی، هیبرید آنها با موجک نیز مورد بررسی قرار گرفت و نتایج حاصل از مدل‌ها با یکدیگر مقایسه شد. نتایج تحقیق حاضر و بسیاری از تحقیقات از جمله نوری و همکاران (۱۳۸۶) نشان داد که مدل‌های هیبریدی افزایش دقت یک مدل را به همراه خواهند داشت. اختلاف نتیجه این تحقیق با تحقیق میسرا و همکاران (۲۰۰۹) می‌تواند به دلیل ساختار ورودی متفاوت مدل‌ها باشد. با توجه به تحقیق آداموسکی (۲۰۱۳)، نیز می‌توان نتیجه گرفت در صورتی که خصوصیات مورفولوژی بعنوان ورودی مدل در نظر گرفته شود ماشین بردار پشتیبان و در غیر اینصورت شبکه عصبی مصنوعی جهت تخمین رواناب مورد استفاده قرار گیرد.

## پی نوشت‌ها

1-Multilayer Perceptron
2-Support Vector Machine
3-Scale
4-Correlation Coefficient
5-Root Mean Square Error
6-Nash Sutcliffe
7-Bias
8-Slope difference
9-Daubechise

**جدول۳- نتایج حاصل از مدل‌های به کاررفته درپیش‌بینی بارش-رواناب ایستگاه پل الماس**

| اولویت | مدل | ترکیب | آموزش | | | | | صحت‌سنجی | | | | |
|---|---|---|---|---|---|---|---|---|---|---|---|---|
| | | | *Sdiff* | *E* | *RMSE* ( $m^3/s$ ) | *Bias* ( $m^3/s$ ) | *R* | *Sdiff* | *E* | *RMSE* ( $m^3/s$ ) | *Bias* ( $m^3/s$ ) | *R* |
| ۱ | *W-ANN* | ۵ | ۰/۱۱۷ | ۰/۹۶۵ | ۰/۱۹۱ | -۰/۰۰۱ | ۰/۹۸۲ | ۰/۱۵۷ | ۰/۸۷۵ | ۰/۲۸۲ | ۰/۰۰۳ | ۰/۹۳۶ |
| ۲ | *W-SVM* | ۶ | ۰/۱۲۴ | ۰/۹۰۵ | ۰/۷۲۴ | ۰/۰۰۰ | ۰/۹۵۲ | ۰/۰۳۶ | ۰/۸۷۰ | ۰/۳۸۴ | ۰/۰۰۰ | ۰/۹۳۴ |
| ۳ | *ANN* | ۵ | ۰/۱۴۸ | ۰/۸۴۸ | ۰/۹۱۴ | ۰/۴۱۳ | ۰/۹۲۱ | ۰/۱۶۵ | ۰/۷۸۵ | ۰/۴۹۲ | ۰/۵۲۴ | ۰/۸۸۹ |
| ۴ | *SVM* | ۶ | ۰/۱۸۹ | ۰/۸۳۷ | ۰/۹۴۸ | ۰/۰۰۰ | ۰/۹۱۵ | ۰/۱۴۰ | ۰/۷۲۷ | ۰/۵۵۶ | ۰/۰۳۴ | ۰/۸۶۴ |

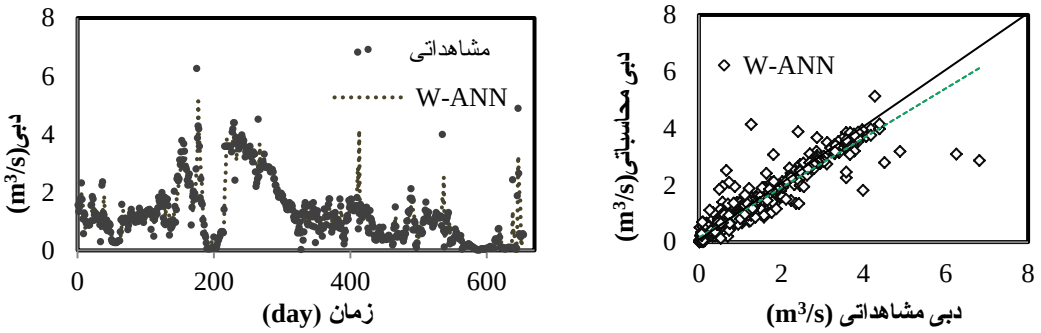


**شکل ۲- نمودارهای پراکنش و سری زمانی مقادیر مشاهداتی و محاسباتی مدل بهینه موجک- شبکه عصبی**

## ۵- مراجع


اسکندری ع، نوری ر (۱۳۸۹) توسعه مدلی مناسب بر مبنای شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای پیش بینی به هنگام اکسیژن خواهی بیو شیمیایی ۵ روزه. محیط شناسی سال سی و هشتم، شماره ۶۱: ۷۴-۷۶.

اسکندری‌نیا ا (۱۳۸۷) تأثیرعامل بارش پیشین در برآورد جریان رودخانه توسط مدل‌سازی هوشمند بارش-رواناب. مجموعه مقالات هشتمین کنگره بین‌المللی مهندسی عمران، شیراز، ایران، اردیبهشت ۱۳۸۸.

اعلمی م ت، صادق‌فام س، فاضلی‌فرد م ح، نقی‌پور ل (۱۳۹۳) مدل‌سازی سری داده‌ها. انتشارات دانشگاه تبریز. تبریز، ۲۹۹ صفحه.

طوفانی پ، مساعدی ا، فاخری فرد ا (۱۳۹۰) پیش‌بینی بارندگی با استفاده مستقیم از نظریه موجک، مطالعه موردی: ایستگاه باران‌سنجی زرینگل استان گلستان. نشریه آب وخاک (علوم و صنایع کشاورزی)، جلد۲۵، شماره ۵: ۱۲۲۶-۱۲۱۷.

نصری م. مدرس ر، دستورانی م ت (۱۳۸۸) کاربرد مدل شبکه عصبی در برآورد رواناب، مطالعه موردی: حوضه آبریز پلاسجان. فصلنامه آمایش محیط، جلد ۲، شماره ۵ : ۲۳-۳۷.

نوری ر، خاکپور ا، دهقانی م، فرخ‌نیا ا (۱۳۸۹) پیش‌بینی ماهانه جریان با استفاده از ماشین بردار پشتیبان بر مبنای آنالیز مؤلفه اصلی. نشریه آب و فاضلاب، جلد۲۲، شماره ۱ : ۱۱۸-۱۲۹.

نوری م، میرحسینی س م، زینال‌زاده ک، رهنما م ب (۱۳۸۶) الگوی جدید بارش-رواناب حوضه آبریز هلیل رود با استفاده از مدل هیبرید شبکه عصبی-موجک. نشریه زمین‌شناسی مهندسی، جلد ۲، شماره ۲: ۴۷۲-۴۵۱.

Adamowski J (2013) Using support vector regression to predict direct runoff, base flow and total flow in a mountainous watershed whit limited data in Uttaranchal, India. Versita 45: 71-83.

Lippman R (1987) An introduction to computing with neural nets. IEEE ASSP Mag 4, 4-22.

Misra D, Oommen T, Agarwal A, Mishra SK (2009) Application and analysis of Support Vector Machine based simulation for runoff and sediment yield. Biosystems Engineering 103: 527-535.

Nelder J A and Mead R (1964) ASimplex method for function minimization. The Computer Journal 308-313.

Lafadani E (2013) Stream flow simulation using SVM, ANFIS and NAM models (A Case Study). Caspian Journal of Applied Sciences Research 2: 86-93.