

## توسعه مدل تلفیقی غیرخطی پیش‌بینی خشکسالی مبتنی بر شبکه عصبی مصنوعی و تبدیلات موجک- مطالعه موردی: حوضه آبریز سد زاینده رود

احمد ابریشمچی، استاد دانشکده مهندسی عمران، دانشگاه صنعتی شریف- تهران، صندوق پستی ۹۳۱۳-۱۱۳۶۵  
Email: abrisham@sharif.edu

حسین مهدیخانی، کارشناس ارشد مهندسی منابع آب، دانشکده مهندسی عمران، دانشگاه صنعتی  
شریف- تهران، صندوق پستی ۹۳۱۳-۱۱۳۶۵

مسعود تجریشی، دانشیار دانشکده مهندسی عمران، دانشگاه صنعتی شریف- تهران، صندوق پستی ۹۳۱۳-۱۱۳۶۵  
Email: tajrishi@sharif.edu

چکیده

خشکسالی پدیده‌ای آرام و بخش طبیعی از اقلیم هر منطقه است. پیش‌بینی خشکسالی نقش مهمی در مدیریت منابع آب و کاهش خسارات خشکسالی ایفا می‌نماید. توانایی بالای شبکه‌های عصبی مصنوعی در مدل سازی و پیش‌بینی سری‌های زمانی نامانا و غیرخطی در مهندسی آب به اثبات رسیده است و تبدیلات موجک با تجزیه‌ساختن سری‌های زمانی به مؤلفه‌های قطعی و غیرقطعی سبب بهبود عملکرد شبکه‌های عصبی در پیش‌بینی ها می‌شود. در این مقاله مدل تلفیقی مبتنی بر شبکه‌های عصبی مصنوعی و تبدیلات موجک برای پیش‌بینی های ۱، ۳ و ۶ماهه خشکسالی ارائه می‌گردد. در مدل تلفیقی پیشنهاد شده، فحست سری‌های زمانی شاخص خشکسالی موثر ماهانه به زیر مؤلفه‌ها تجزیه شده و سپس این زیر مؤلفه به کمک مدل‌های شبکه عصبی مصنوعی پیش‌بینی می‌گردد. برای ساخت الگوهای ورودی شبکه از بارش ماهانه و شاخص بارش استاندارد شده نیز بهره گرفته شده است. نتایج به دست آمده از این مدل تلفیقی برای ۴ استان چلگرد، قلعه شاهرخ، دامنه فریدن و سد زاینده رود واقع در حوزه آبریز سد زاینده رود نشان دهنده کارایی این مدل‌های تلفیقی در بهبود دقت پیش‌بینی های ۱، ۳ و ۶ماهه خشکسالی نسبت به مدل‌های شبکه عصبی مصنوعی می‌باشد.

کلید واژه‌ها: ۱- خشکسالی هواشناختی- ۲- پیش‌بینی- ۳- شاخص خشکسالی مؤثر- ۴- شبکه عصبی مصنوعی- ۵- تبدیلات موجک- ۶- حوزه آبریز سد زاینده رود

### ۱- مقدمه

خشکسالی را می‌توان پدیده‌ای گذرآ، تکرار شونده و جزئی جدا ناشدنی از اقلیم هر منطقه دانست. اغلب، خشکسالی با یک کاهش قابل ملاحظه بارش نسبت به متوسط بلند مدت بارندگی آغاز می‌گردد و با گذر زمان سبب کاهش رطوبت خاک و در ادامه افت منابع آبهای سطحی و زیر سطحی می‌شود. خشکسالی‌ها نسبت به سایر پدیده‌های اقلیمی همچون سیل و طوفان بیشترین خسارات اقتصادی، اجتماعی و زیست محیطی را به جوامع وارد ساخته است.

با توجه به موقعیت حفره‌ای ایران و واقع شدن این کشور در کمریند خشک و نیمه خشک کره زمین، خشکسالی یکی از مخرب‌ترین بلایای طبیعی این کشور حساب می‌آید. تلخی تجربه خشکسالی‌های سال‌های ۱۳۷۷ تا ۱۳۸۰ کشور رفته به دست فراموشی سپرده می‌شود. طبق آمار سازمان ملل طی این سالها، خشکسالی بیش از  $\frac{1}{3}$  عمیلیارد دلار بر کشور خسارت وارد کرده است<sup>[۱]</sup>. وضعیت اقلیمی ایران و ابعاد خسارات خشکسالی‌های آن، نقش پر اهمیت پیش‌بینی خشکسالی در مدیریت منابع آب را نشان می‌دهد.

به طور سنتی در چندین دهه اخیر برای پیش‌بینی فرایندهای هواشناختی و هیدرولوژیکی همچون بارش، دبی ماهانه و یا سالانه رودخانه‌ها، سیلانها و خشکسالی‌ها از رگرسیون‌های چند متغیره و مدل‌های استوکاستیک ARMA و ARIMA به طور گسترده استفاده می‌گردد<sup>[۲، ۳، ۴]</sup>. این مدل‌ها فرایندها را به صورت خطی مدل‌سازی می‌کنند؛ بنابراین، برای سری‌های مانا قابلیت‌های خود را نشان داده‌اند، لکن در توصیف مشخصه‌های ناما و غیرخطی سری‌های زمانی غالباً ناتوانند. با عنایت به اینکه مشخصه‌های غیرخطی و نامانای سری‌های زمانی فرایندهای هواشناختی و هیدرولوژیکی نقش ویژه‌ای در پیش‌بینی ها دارند، رسیدن به مدل‌هایی که بتوانند چنین مشخصه‌هایی را در نظر گیرد برای هیدرولوژیست‌ها ضروری است.

در سال‌های اخیر، شبکه‌های عصبی مصنوعی<sup>۱</sup>، توانایی خود را در مدل‌سازی و پیش‌بینی سری‌های زمانی غیرخطی و نامانای فرایندهای هواشناختی و هیدرولوژیکی با توجه به ماهیت غیرخطی و انعطاف‌پذیری این نوع مدل‌ها در مهندسی آب به اثبات رسانده‌اند<sup>[۵]</sup>. کاربرد گسترده این مدل‌ها در منابع به تفصیل ذکر شده است<sup>[۶-۱۵]</sup>. در مدل‌های آماری و دینامیکی سعی براین است که با ایجاد یک رابطه ریاضی، ارتباط بین اطلاعات مفروض به نام ورودی و اطلاعات دیگر یعنی خروجی، بیان شود. در این روابط صریح ریاضی، محدودیت وجود دارد که یک مدل دینامیکی صریح اگر بخواهد از دقت بالایی برخوردار باشد باید پارامترهای ورودی آن زیاد باشد و یا برد زمانی پیش‌بینی آن کم گردد؛ اما مدل‌های ANN با پردازش غیرخطی اطلاعات به روش خودسازماندهی، در عملیاتی موازی در تعداد زیادی از سلول‌های عصبی، ارتباط بین اطلاعات ورودی و خروجی را در سطح بالایی از دقت شبیه‌سازی می‌کنند و بدون ساختن و یا ایجاد رابطه صریح ریاضی می‌توانند با آموزشی که دیده اند رفتار سیستم را پیش‌بینی کنند. در واقع، مدل‌های ANN یک سیستم پردازش موازی اطلاعات با تقلیدی بسیار ساده از سیستم عصبی بیولوژیکی مغز انسان می‌باشند<sup>[۱۶]</sup>.

امروزه در پیش‌بینی سری‌های زمانی، رویکردهای تجزیه<sup>۲</sup> سری زمانی به مؤلفه‌های اصلی آن- مؤلفه‌های قطعی یا فصلی و مؤلفه‌های تصادفی یا نامنظم - با اقبال مواجه شده‌است. مطالعات نشان می‌دهد پیش‌بینی با به کار گیری چنین رویکردی غالباً در توسعه مدل‌های پیش‌بینی و توصیف مشخصه‌های قطعی و تصادفی سری‌های زمانی بسیار مفید تر از تلاش جهت توسعه یک الگوی تنها است<sup>[۱۷]</sup>. اخیراً تبدیلات موجک یک ابزار کاربردی برای تحلیل تغییرات موضعی سری‌های زمانی شده است<sup>[۱۸]</sup>. بنابراین، استفاده از مدل‌های دورگه یا تلفیقی پیش‌بینی سری‌های زمانی مبتنی بر تبدیلات موجک و دیگر روش‌های مدل‌سازی همچون مدل‌های استوکاستیک، ANN و فازی به طور فزاینده‌ای در حال افزایش است؛ هرچند که از عمر آنها در هیدرولوژی چندانی نمی‌گذرد. این نوع مدل‌ها در گام اول داده‌ها را به کمک تبدیلات موجک پیش‌پردازش می‌نماید (تجزیه به مؤلفه‌های اصلی) و سپس بر روی این داده‌های پیش‌پردازش شده، عملیات پیش‌بینی را صورت می‌دهد<sup>[۱۹-۲۴]</sup>.

در این مطالعه، یک مدل تلفیقی مبتنی بر شبکه‌های عصبی مصنوعی و تبدیلات موجک جهت بهبود دقت پیش‌بینی خشکسالی هواشناختی ارائه شده‌است. در این مدل تلفیقی، نخست به کمک تبدیلات موجک سری‌های زمانی شاخص

<sup>1</sup> Artificial Neural Networks (ANN)

<sup>2</sup> Decomposition Approach

خشکسالی مؤثر<sup>۱</sup> ماهانه به مؤلفه‌های اصلی تجزیه شده و سپس این مؤلفه‌های اصلی به کمک مدل شبکه عصبی مصنوعی پیش‌بینی می‌گردد. و در نهایت به کمک این مؤلفه‌های تجزیه شده، سری زمانی اصلی بازسازی می‌گردد. برای ساخت الگوهای ورودی مدل ANN، از بارش ماهانه و شاخص بارش استاندارد شده<sup>۲</sup> نیز بهره گرفته شده است. برای ارزیابی نتایج مدلها از معیارهای  $R^2$  (مجذور ضریب همبستگی)، RMSE (جدول میانگین مربع خطای NMSE (میانگین مربع خطای نرمال شده) استفاده شده است. نتایج بدست آمده از این مدل تلفیقی برای<sup>۳</sup> ایستگاه چلگرد، قلعه شاهرخ، دامنه فریدن و سد زاینده رود واقع در حوزه آبریز سد زاینده رود نشان دهنده کارایی این مدل‌های تلفیقی در بهبود دقت پیش‌بینی های<sup>۴</sup> ۱، ۳ و ۶ ماهه خشکسالی نسبت به مدل‌های شبکه عصبی مصنوعی در منطقه مورد مطالعه می‌باشد.

## ۲-معرفی مدل تلفیقی پیش‌بینی بر شبكه عصبی و تبدیلات موجک

### ۲-۱-شبکه عصبی مصنوعی

بررسی‌های منابع علمی نشان می‌دهد، حدود ۹۰ درصد شبکه‌های عصبی مصنوعی که در مدل‌سازی و پیش‌بینی فرآیندهای هواشناختی و هیدرولوژیکی استفاده شده‌اند، شبکه‌های پرسپترون چندلایه<sup>۵</sup> با الگوریتم آموزش پس انتشار خطای<sup>۶</sup> می‌باشند. ثابت شده است که شبکه‌های MLP سه لایه برای انجام پیش‌بینی و شیوه‌سازی در مهندسی آب مناسب هستند[۲۵]. از این‌رو در این مطالعات از شبکه MLP سه لایه استفاده شده است.

### ۲-۲-تبدیلات موجک

هدف اصلی از به کارگیری تبدیلات موجک در تحلیل سری‌های زمانی، دست یافتن به نمایش کامل زمان-مقیاس پدیده‌های نامانا و گذران که در مقیاس‌های مختلف زمانی به وقوع می‌پیوندد، می‌باشد[۲۶]. اغلب سری‌های زمانی فرایندهای هیدرولوژیکی همچون بارش، سیلاب، جریان رودخانه و سری‌های زمانی شاخص‌های پایش خشکسالی گستته می‌باشند؛ از این‌رو، تبدیل موجک گستته همچون الگوریتم ملات<sup>۷</sup> و آتروس<sup>۸</sup> برای تجزیه و بازسازی سری‌های زمانی بکار گرفته می‌شود[۲۴-۲۹ و ۲۷-۲۹]. در این مطالعات برای پیش پردازش داده‌ها از الگوریتم ساده، سریع و در عین حال پرکاربرد آتروس بهره گرفته شده است. در این الگوریتم نخست با انتخاب یک فیلتر پایین گذر<sup>۹</sup> به کمک روابط (۱) و (۲)، سری زمانی به مؤلفه‌های قطعی و نامنظم خود تجزیه می‌شود. در نهایت به کمک رابطه (۳)، سری زمانی اصلی به کمک مؤلفه‌هایش بازسازی می‌شود.

$$C_i(k) = \sum_l h_0(l) C_{i-1}(k + 2^l) \quad (1)$$

$$W_i(k) = C_{i-1}(k) - C_i(k) \quad (2)$$

$$C_0(k) = f(k) = C_p(k) + \sum_{i=1}^p W_i(k) \quad (3)$$

در این روابط  $C_i(t)$  و  $W_i(t)$ : ضرایب تبدیل موجک گستته،  $h_0(l)$ : ضرایب فیلتر پایین گذر،  $i$ : مرحله تجزیه‌سازی و  $p$ : تعداد مراحل تجزیه‌سازی می‌باشد.  $C_i(t)$  بیانگر مشخصه‌های با فرکانس پایین یا مؤلفه‌های قطعی و فصلی و همچنین

<sup>1</sup> Effective Drought Index (EDI)

<sup>2</sup> Standardized Precipitation Index (SPI)

<sup>3</sup> Multi-Layer Perceptron (MLP)

<sup>4</sup> Error Back Propagation

<sup>5</sup> Mallat

<sup>6</sup> A trous

<sup>7</sup>: فیلتر پایین گذر (Low-Pass Filter): فیلتری است که تنها مؤلفه‌های با فرکانس پایین (مؤلفه قطعی یا فصلی) سری زمانی را از خود عبور می‌دهد و مقادیر مؤلفه‌های با فرکانس بالای (مؤلفه‌های تصادفی و نامنظم) سری زمانی را صفر می‌کند.

(١) بیانگر مشخصه‌های با فرکانس بالا یا مؤلفه‌های تصادفی و نامنظم سری زمانی می‌باشد. با توجه به سادگی محاسبه  $C_p(t)$ ، بسیاری از مشخصه‌های قابل توجه سری زمانی همچون، دوره<sup>١</sup>، دوره‌های پنهان<sup>٢</sup>، وابستگی‌ها<sup>٣</sup> و پرش<sup>٤</sup> براحتی توسط این مؤلفه‌های موجک مشخص می‌شوند.

### ۳-۲- توسعه مدل پیش‌بینی تلفیقی

برای ساخت مدل تلفیقی نخست، سری‌های زمانی در چند مرحله معین ( $p$ ) به کمک الگوریتم آتروس به مؤلفه‌های  $C_p(t)$ ،  $W_p(t)$ ، ...،  $W_2(t)$ ،  $W_1(t)$  تجزیه می‌شود. سپس مدل ANN برای پیش‌بینی هر یک از این مؤلفه‌ها با الگوهای مختلف ورودی ساخته می‌شود. پس از پیش‌بینی هر یک از مؤلفه‌ها به کمک ANN برای زمان‌های  $T$  دوره بعد، در نهایت سری زمانی اصلی به کمک مؤلفه‌های مدل شده بازسازی می‌گردد.

### ۳- مطالعه موردی [٣٠]

#### ۱- منطقه مورد مطالعه

منطقه مطالعاتی این پژوهش حوضه آبریز سد زاینده رود با مساحت ۵۰۳۴ کیلومترمربع می‌باشد که با توجه به کشاورزی گسترده دشت اصفهان و اهمیت سد زاینده رود در این منطقه، این ناحیه از اهمیت خاصی برخوردار می‌باشد. این محدود مناطق بالادست سد زاینده‌رود در حوضه آبریز زاینده‌رود، مناطق بالادست محل احداث تونل سوم کوهنگ در حوزه آبریز کارون علیا و بخش‌هایی از حوزه ذر که محدود به چشم‌لنگان می‌شود را شامل می‌شود.

#### ۲- پیش‌بینی خشکسالی در منطقه

دوره آماری مطالعات، ۳۲ ساله و از سال آبی ۱۳۴۹-۸۲۱ تا ۱۳۸۱-۵۰ می‌باشد و مقیاس زمانی آن روزانه و ماهانه در نظر گرفته شده است. ایستگاه‌های شاخص این مطالعات به کمک سه معیار، (۱) برخورداری از حداقل ۳۰ سال آمار بارش روزانه، (۲) پراکنش مناسب مکانی ایستگاهها و (۳) تراز ایستگاهها از سطح دریا، انتخاب گردیدند. به کمک این معیارها چهار ایستگاه بارانسنجی چلگرد، قلعه چاهرخ، دامنه فریدن و سد زاینده‌رود برای مطالعات مناسب تشخیص داده شدند. در اولین قدم، بارش، SPI و EDI ماهانه برای هر ایستگاه محاسبه گردید. سپس به کمک الگوریتم آتروس سری زمانی شاخص خشکسالی مؤثر تجزیه گردید. در این مطالعه از فیلتر پایین گذرهای B3-Spline استفاده شده و برای  $P$  نیز مقادیر یک و دو در نظر گرفته شد و سپس مدل ANN ساخته شد. برای تعیین معماری بهینه ANN (تعداد نرون‌های لایه ورودی و مخفی) شبکه‌هایی با معماری و ورودی متنوع مورد ارزیابی قرار گرفت. نکوبی مدل‌های ساخته شده به کمک معیارهای مجدور ضریب همبستگی ( $R^2$ )، جذر میانگین مربع خطاهای (RMSE) و میانگین مربع خطای نرمال شده (NMSE) مورد ارزیابی قرار گرفتند. برای آموزش و اعتبارسنجی مدل ورودهای شبکه به دو دسته تقسیم شدند؛ ۸۰ درصد داده‌ها به عنوان ورودی آموزش مدل و ۲۰ درصد از داده‌ها (مهر ۱۳۷۷ تا شهریور ۱۳۸۲) به عنوان ورودی اعتبار سنجی مدل در نظر گرفته شدند. یکی از مهم‌ترین پیش‌نیازها و گام‌های اصلی در بکارگیری ANN انتخاب ورودی‌های مؤثر است. از این‌رو، در این مطالعه ۲۲ نوع الگوی ورودی که ترکیبی از داده‌های بارش، SPI، EDI، ماهانه بود، برای هر یک از دوره‌های پیش‌بینی ۱، ۳ و ۶ ماهه به شرح ذیل تهیه گردید.

$$E_{(t+n)} = f(E_t, E_{t-1}) \quad \text{Input model 1}$$

$$E_{(t+n)} = f(E_t, E_{t-1}, E_{t-2}) \quad \text{Input model 2}$$

<sup>1</sup> Period

<sup>2</sup> Hidden Period

<sup>3</sup> Dependence

<sup>4</sup> Jump

$E_{(t+n)} = f(E_t, E_{t-1}, E_{t-2}, E_{t-3})$	<i>Input model 3</i>
$E_{(t+n)} = f(E_t, E_{t-1}, E_{t-2}, E_{t-3}, E_{t-4})$	<i>Input model 4</i>
$E_{(t+n)} = f((E_t, E_{t-1}), (R_t, R_{t-1}))$	<i>Input model 5</i>
$E_{(t+n)} = f((E_t, E_{t-1}, E_{t-2}), (R_t, R_{t-1}, R_{t-2}))$	<i>Input model 6</i>
$E_{(t+n)} = f((E_t, E_{t-1}, E_{t-2}, E_{t-3}), (R_t, R_{t-1}, R_{t-2}, R_{t-3}))$	<i>Input model 7</i>
$E_{(t+n)} = f((E_t, E_{t-1}, E_{t-2}, E_{t-3}, E_{t-4}), (R_t, R_{t-1}, R_{t-2}, R_{t-3}, R_{t-4}))$	<i>Input model 8</i>
$E_{(t+n)} = f((E_t, E_{t-1}), (R_t))$	<i>Input model 9</i>
$E_{(t+n)} = f((E_t, E_{t-1}, E_{t-2}), (R_t))$	<i>Input model 10</i>
$E_{(t+n)} = f((E_t, E_{t-1}, E_{t-2}, E_{t-3}), (R_t))$	<i>Input model 11</i>
$E_{(t+n)} = f((E_t, E_{t-1}, E_{t-2}, E_{t-3}, E_{t-4}), (R_t))$	<i>Input model 12</i>
$E_{(t+n)} = f((E_t, E_{t-1}, E_{t-2}, E_{t-12}), (R_t, R_{t-1}))$	<i>Input model 13</i>
$E_{(t+n)} = f(S_t, S_{t-1})$	<i>Input model 14</i>
$E_{(t+n)} = f(S_t, S_{t-1}, S_{t-2})$	<i>Input model 15</i>
$E_{(t+n)} = f(S_t, S_{t-1}, S_{t-2}, S_{t-3})$	<i>Input model 16</i>
$E_{(t+n)} = f((E_t, E_{t-1}), (S_t))$	<i>Input model 17</i>
$E_{(t+n)} = f((E_t, E_{t-1}, E_{t-2}), (S_t))$	<i>Input model 18</i>
$E_{(t+n)} = f((E_t, E_{t-1}, E_{t-2}, E_{t-3}), (S_t))$	<i>Input model 19</i>
$E_{(t+n)} = f((E_t, E_{t-1}), (R_t, R_{t-1}), (S_t, S_{t-1}))$	<i>Input model 20</i>
$E_{(t+n)} = f((E_t, E_{t-1}, E_{t-2}), (R_t, R_{t-1}, R_{t-2}), (S_t, S_{t-1}, S_{t-2}))$	<i>Input model 21</i>
$E_{(t+n)} = f((E_t, E_{t-1}, E_{t-2}, E_{t-3}), (R_t, R_{t-1}, R_{t-2}, R_{t-3}), (S_t, S_{t-1}, S_{t-2}, S_{t-3}))$	<i>Input model 22</i>

در مدل‌های فوق  $E_t$ ،  $S_t$  و  $R_t$  به ترتیب SPI و بارش ماهانه در ماه  $t$  و دوره پیش‌بینی می‌باشد.

### ۳-۴- نتایج مدل‌ها

بخشی از نتایج پیش‌بینی‌ها در جدولهای (۱) تا (۳) و شکل‌های (۱) تا (۳) ارائه شده است. مقایسه بین نتایج مدل‌های  $WNN-1$  و  $WNN-2$ <sup>۱</sup> به طور کلی نشان می‌دهد، مدل‌های تلفیقی در مجموع به طور قابل ملاحظه‌ای نتایج پیش‌بینی را بهبود بخشیده‌اند و از این میان، مدل‌های تلفیقی  $WNN-2$  نسبت به  $WNN-1$  به طور قابل ملاحظه‌ای سبب بهبود نتایج شده است.

جدول ۱- مقایسه نتایج انواع مدل‌های پیش‌بینی ۱ماهه-ایستگاه دامنه فریدن

فاز اعتبار سنجی				فاز آموزش				نوع مدل
NMSE	RMSE	$R^2$	الگوی ورودی	NMSE	RMSE	$R^2$	الگوی ورودی	
۰/۱۲	۰/۳۹	۰/۸۸	۲۲	۰/۱۷	۰/۱۴	۰/۸۳	۲۲	<b>ANN</b>
۰/۰۲	۰/۱۴	۰/۹۹	۲۲	۰/۰۲	۰/۱۲	۰/۹۸	۲۲	<b>WNN-1</b>
۰/۰۲	۰/۱۶	۰/۹۸	۲۱	۰/۰۳	۰/۱۴	۰/۹۸	۲۱	<b>WNN-2</b>

<sup>۱</sup> مدل تلفیقی شبکه عصبی مصنوعی و تبدیلات موجک با ۱ درجه تجزیه سازی

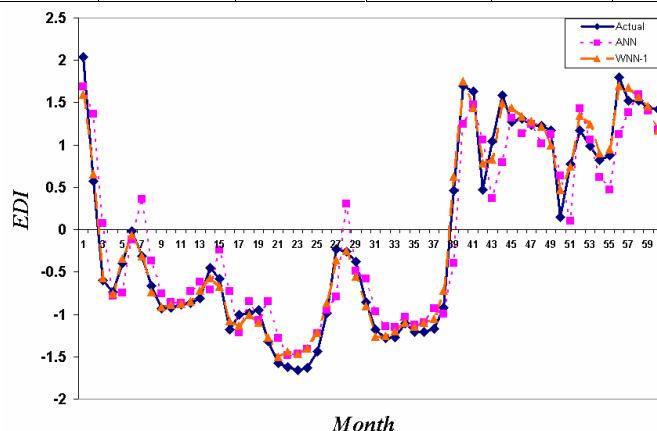
<sup>۲</sup> مدل تلفیقی شبکه عصبی مصنوعی و تبدیلات موجک با ۲ درجه تجزیه سازی

جدول ۲- مقایسه نتایج انواع مدل های پیش بینی ۳ماهه- ایستگاه چلگرد

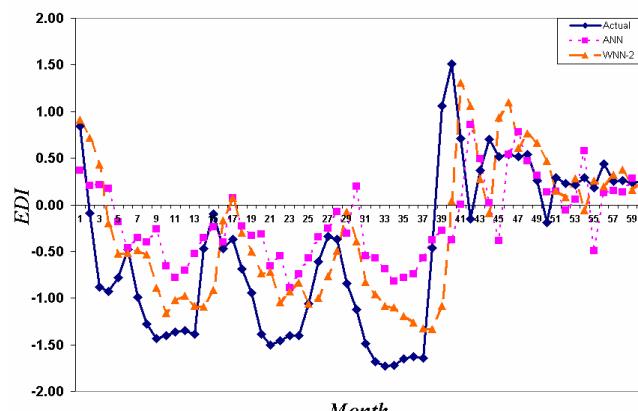
فاز اعتبار سنجی				فاز آموزش				
NMSE	RMSE	$R^2$	الگوی ورودی	NMSE	RMSE	$R^2$	الگوی ورودی	نوع مدل
۰/۶۱	۰/۶۷	۰/۴۹	۲۲	۰/۵۱	۰/۶۸	۰/۴۹	۲۲	ANN
۰/۳۷	۰/۵۲	۰/۶۴	۷	۰/۳۳	۰/۵۵	۰/۶۷	۲۲	WNN-1
۰/۲۵	۰/۰۹	۰/۹۲	۲۲	۰/۰۹	۰/۲۸	۰/۹۲	۲۲	WNN-2

جدول ۳- مقایسه نتایج انواع مدل های پیش بینی ۳ماهه- ایستگاه سد زاینده رود

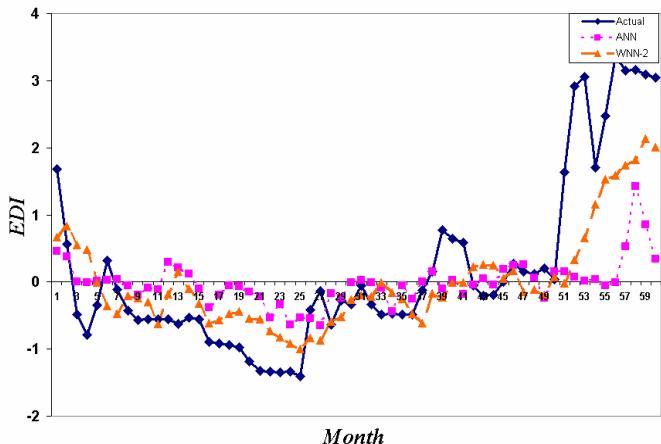
فاز اعتبار سنجی				فاز آموزش				
NMSE	RMSE	$R^2$	الگوی ورودی	NMSE	RMSE	$R^2$	الگوی ورودی	نوع مدل
۰/۷۷	۱/۱۹	۰/۳۸	۲۲	۰/۷۹	۰/۶۲	۰/۲۰	۲۲	ANN
۰/۷۵	۱/۰۷	۰/۴۷	۱۹	۰/۷۵	۰/۷۶	۰/۲۵	۲۲	WNN-1
۱/۴۲	۰/۸۰	۰/۷۴	۶	۰/۵۳	۰/۶۴	۰/۴۸	۲۲	WNN-2



شکل ۱- مقایسه نتایج پیش بینی ۱ماهه مدل های ANN و WNN-1 با مقادیر واقعی ایستگاه دامنه فریدن، مهر ۷۷ تا مهر ۱۲



شکل ۲- مقایسه نتایج پیش بینی ۳ماهه مدل های ANN و WNN-2 با مقادیر واقعی ایستگاه چلگرد، مهر ۷۷ تا مهر ۱۲



شکل ۳- مقایسه نتایج پیش‌بینی عماهه مدل‌های ANN و WNN-2 با مقادیر واقعی ایستگاه سد زاینده رود، مهر ۷۷ تا مهر ۱۴

#### ۴- نتیجه‌گیری [۳۰]

- مقایسه بین نتایج مدل‌های ANN-1 و WNN-2 به طور کلی نشان می‌دهد الگوهایی که بارش در ترکیب آن دخالتی نداشته است، ضعیف‌ترین نتایج را بدست داده‌اند. همچنین در مجموع الگوهای ورودی ۲۰، ۲۱ و ۲۲ بهترین نتایج پیش‌بینی را داشته‌اند و در این الگوها هرچه از داده‌های ماههای گذشته‌تر استفاده شده، نتایج پیش‌بینی دقیق‌تر شده‌است. در مجموع مدل‌های تلفیقی به طور قابل ملاحظه‌ای نتایج پیش‌بینی را بهبود بخشیده‌اند و از این میان، مدل‌های تلفیقی-2 WNN-2 نسبت به WNN-1 به طور قابل ملاحظه‌ای سبب بهبود نتایج شده است.
- در پیش‌بینی‌های ۱ماهه، مدل‌های تلفیقی به طور کلی با افزایش  $R^2$  از حدود ۰/۸۶ برای مدل‌های ANN به ۰/۹۸ و کاهش RMSE از حدود ۰/۳۶ تا حدود ۰/۱۵ کارایی خود را در اصلاح نتایج و قابل اعتماد بودن نتایج پیش‌بینی‌های ۱ماهه نشان داده‌اند.
- در پیش‌بینی‌های ۳ماهه، مدل‌های تلفیقی به طور کلی با افزایش  $R^2$  از حدود ۰/۶۰ برای مدل‌های ANN به ۰/۹۴ و کاهش RMSE از حدود ۰/۷۰ به حدود ۰/۳۲ کارایی خود را در اصلاح نتایج و قابل اعتماد بودن نتایج پیش‌بینی‌های ۳ماهه نشان داده‌اند.
- در پیش‌بینی‌های ۶ماهه، مدل‌های تلفیقی به طور کلی با افزایش  $R^2$  از حدود ۰/۳۵ برای مدل‌های ANN به حدود ۰/۷۰ و کاهش RMSE از حدود ۱/۰۰ به حدود ۰/۸۵ کارایی خود را در اصلاح نتایج پیش‌بینی نشان داده است. پایین بودن نسبی  $R^2$  وبالابودن مقدار RMSE میین قابلیت اعتماد نسبی این پیش‌بینی‌ها می‌باشد.

#### ۵- مراجع

- [1] United Nations, "Technical Mission on the Drought Situation in I.R.Iran, 2000", Mission Report, Tehran. I.R.Iran, August 2000. pp67.
- [2] Tao, P. C., and Delleur, J. M. (1976), "Seasonal and non-seasonal ARIMA models in hydrology", ASCE, Journal of hydraulics Div., 102, HY10, 1541-1559.
- [3] Salas, J. D. Boes, D.C., and Smith, R.A., (1980) "ARMA modeling of seasonal hydrologic series", ASCE, Journal of hydrology.
- [4] Montanari, A., Rosso, R., and Taqqu, M., (1997), "Fractionally differenced ARIMA models applied to hydrologic time series: Identification, estimation and simulation", Water Resource Research, 33, 1035.
- [5] ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, (2000), "Artificial neural networks in hydrology. I: Preliminary concepts", Journal of Hydrology. Eng. ASCE, 5 (2) 115-124

- [6] French MN, Krajewski WF, Cuykendall RR., (1992),"Rainfall forecasting in space and time using a neural network." , ASCE, Journal of Hydrology, 137:PP.1-31.
- [7] Half AH, Halff HM, Azmoodeh M., (1993), "Predicting runoff from rainfall using artificial neural networks", ASCE, Proc Engng Hydrol, .761-5.
- [8] Ramam, H, Sunilkumar, N, (1995),"Multivariate modeling of water resource time series using artificial neural network", Hydrologic Science Journal, 40(21), 145-163.
- [9] Tokar, A. S., Johnson, P. A., (1999),"Rainfall-Runoff Modeling Using Artificial Neural Networks", Journal of Hydrologic Engineering, July.
- [10] Zealand CM. Burn D. and Simonovic SP., (1999),"Short term stream flow forecasting using artificial neural networks", Journal of Hydrology, 214,32-48.
- [11] Luk, K.C., Ball, J.E., and Sharma, A., (2000),"A study of optimal model lag and spatial inputs to artificial neural network for rainfall forecasting", Journal of Hydrology, 227, 56-65.
- [12] Hu, T, Lam KC, Ng ST., (2001),"River flow time series prediction with a range dependent neural network." Hydrologic Science Journal, 46(5), 729-45.
- [13] Maier, H. R. and Dandy, G. C., (2000),"Neural networks for the prediction and forecasting of water resources variables; a review of modeling issues and applications", Environmental Modeling and Software, 15,101-124.
- [14] Birikundavyi S., Labib R., Trung HT. and Rousselle J., (2002),"Performance of neural networks in daily stream flow forecasting." Journal of Hydrologic Engineering, ASCE, 7(5): 392-398.
- [15] Bozorg Hadad, O, Sharifi, F., Alimohammadi, S., (2005),"Streemflow Forecasting using ANN", 73 rd Annual Meeting ICOLD, Paper NO.: 061-S2
- [16] Haykin, S., (1994), Neural Networks: A Comprehensive Foundation, Macmillan College Publishing,
- [17] Makridakis, S., Wheelwright, S. C., and McGee, V. E., (1983), Forecasting: Methods and Applications, Wiley, NY, 923.
- [18] Torrence, C., and Compo, G. P., (1998),"A practical guide to wavelet analysis"" Bulletin of the American Meteorological Society, 79(1), 61-78.
- [19] Shensa MJ., (1992), "Discrete wavelet transform: wedding the A Trou and Mallat algorithm", Journal of. IEEE Transactions on Signal Processing, 40:2464-2482.
- [20] Aussem, A., and Murtagh, F., (1997), "Combining neural network forecasts on wavelet-transformed time series." Connection Science, 9(1): 113-121.
- [21] Mallat, S. G., (1998), A Wavelet Tour of Signal Processing, Second Edition, San Diego, Academic Press, 577.
- [22] Wang W., Ding J., (2003),"Wavelet Network Model and Its Application to the prediction of Hydrology", Journal of Nature and Science, 1(1): 67-71.
- [23] Woong, K., Valdes, B., (2003), "A Nonlinear Model for Drought Forecasting Based On Conjunctive of Wavelet Transforms and Neural Networks", ASCE, Journal of Hydrologic Engineering, NOVEMBER/DECEMBER:319-328.
- [24] Mehdikhani, H., Abrishamchi, A., (2006), " Developing a Conjunctive Nonlinear Model for Inflow Prediction Using Wavelet Transforms & Artificial Neural Networks: A Case Study of Dez Reservoir Dam, Iran", Proceeding of ASCE- 2006 Operations Management Conference, California, 79-92.
- [25] Coulibaly P., Anctil F. and Bobee, B., (2000),"Daily reservoir inflow forecasting using artificial neural networks with stopped training approach." Journal of Hydrology, 230: 244-257.
- [26] Labat, D., Ababou, R., and Mangin, A., (2000),"Rainfall-runoff relationships for karstic springs. Part II: continuous wavelet and discrete orthogonal multi-resolution analyses." Journal of. Hydrology, 238, 149–178.
- [27] Dutilleux, P., (1989),"An implementation of the 'Algorithm A Trou' to compute the wavelet transform", in Wavelets, Time-frequency Methods and Phase Space, J. M. Combas, A. Grossman, and Ph. Tchamitchian, Eds. BertinL Springer, IPTI, 298-304.
- [28] Shensa, M. J., "Affine wavelets: Wedding the A trous and Mallat algorthms", to appear in IEEE Transactions on Acoustics. Speech and Signal Processing.
- [29] Zheng, G., Starck, J.L., Campbell, J.G., Murtagh, F., (1999), "The Wavelet Transform for Filtering Financial Data Streams", Journal of Computational Intelligence in Finance, Vol7, 18-35.
- [۳۰] [امهديخاني، ح.]، "توسيعه مدل غيرخطي پيش ييني خشکسالی مبتنی بر تبدیلات موجک و شبکه عصبی (مطالعه موردی: حوضه آبریز سد زاینده رود)"، پایان نامه کارشناسی ارشد، دانشکده عمران دانشگاه صنعتی شریف.